



RIO

PUC

Dissertação de Mestrado

Algoritmos de Otimização para Definição Assistida de Intervalos de Isolamento Crítico de Poços de Petróleo

Luiz de Abreu Henriques Neto

Pontifícia Universidade Católica do Rio de Janeiro
Centro Técnico Científico
Departamento de Informática

Rio de Janeiro, 18 de setembro de 2025



Pontifícia
Universidade
Católica do
Rio de Janeiro

Algoritmos de Otimização para Definição Assistida de Intervalos de Isolamento Crítico de Poços de Petróleo

Luiz de Abreu Henriques Neto

Orientação: Professor Paulo Ivson Netto Santos

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre em Informática pelo programa de Pós-Graduação em Informática no Departamento de Informática.

Rio de Janeiro, 18 de setembro de 2025



Pontifícia
Universidade
Católica do
Rio de Janeiro

Algoritmos de Otimização para Definição Assistida de Intervalos de Isolamento Crítico de Poços de Petróleo

Luiz de Abreu Henriques Neto

**Dissertação apresentada como requisito parcial para a obtenção do grau
de Mestre em Informática. Aprovada pela Comissão examinadora abaixo:**

Professor Paulo Ivson Netto Santos

Orientador

Departamento de Informática – PUC-Rio

Professor Hélio Côrtes Vieira Lopes

Departamento de Informática – PUC-Rio

Professor Rodrigo Goyannes Gusmão Caiado

Departamento de Engenharia Industrial – PUC-Rio

Rio de Janeiro, 18 de setembro de 2025



Pontifícia
Universidade
Católica do
Rio de Janeiro

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

Luiz de Abreu Henriques Neto

Graduou-se em Engenharia da Computação pelo Instituto Militar de Engenharia no Rio de Janeiro, Brasil. Atua há 12 anos como Engenheiro especialista na área de Reservatórios na Petróleo Brasileiro S.A., Petrobras.

Ficha Catalográfica

Neto, Luiz de Abreu Henriques

Algoritmos de Otimização para Definição Assistida de Intervalos de Isolamento Crítico de Poços de Petróleo / Luiz de Abreu Henriques Neto; orientador: Paulo Ivson Netto Santos. – 2025.

331 331 f: il. color. ; 30 cm

Dissertação (mestrado) - Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Informática, 2025.

Inclui bibliografia

1. Poços de Petróleo. 2. Intervalos de Isolamento Crítico. 3. Otimização. 4. Metaheurística. 5. Análise Multicritério. 6. Automatização. I. Santos, Paulo Ivson Netto. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Informática. III. Título.

CDD: 004

À minha filha, Sofia.

Agradecimentos

Na definição e construção do meu ser, agradeço:

A Deus — presença discreta e imensa —, pelo chão firme dos dias.

À minha esposa, Sarah, companheira de todos os caminhos: pela constância no dia a dia e pela mão estendida quando o mundo se inclina.

Aos meus pais, Carlos e Rosa, e à minha irmã, Bruna — mesmo longe, sempre perto — pela torcida tempestuosa e pelo apoio que não falha.

Em especial, à minha filha Sofia, que ainda mora no silêncio do ventre e já faz alvoroço de esperança: pelos pequenos sinais que me chegam como bilhetes de luz, que me sustentam quando os dias são ásperos e me empurram a seguir.

Na definição e construção da minha pesquisa, agradeço:

Ao meu orientador, Paulo, pela orientação criteriosa, pelo rigor acadêmico e pela disponibilidade constante, cujas contribuições foram determinantes para a qualidade e a conclusão deste trabalho.

Aos meus amigos, especialistas do setor de óleo e gás, que gentilmente participaram das entrevistas que fundamentaram as diretrizes técnicas deste estudo.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Se este trabalho chegou até aqui, foi porque muitos me emprestaram asas.

Resumo

Neto, Luiz de Abreu Henriques; Santos, Paulo Ivson Netto. **Algoritmos de Otimização para Definição Assistida de Intervalos de Isolamento Crítico de Poços de Petróleo**. Rio de Janeiro, 2025. 331p. Dissertação de Mestrado – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

Este trabalho tem como objetivo principal a avaliação e desenvolvimento de algoritmos de otimização para definição assistida dos Intervalos de Isolamento Crítico (IICs) em poços de petróleo. A abordagem proposta integra diretrizes operacionais, chamadas de "Regras de Ouro", com dados de perfilagem para otimizar o posicionamento dos IICs de maneira precisa e robusta. As diretrizes, baseadas em critérios como porosidade, saturação de hidrocarbonetos e permeabilidade, foram formuladas por meio de entrevistas semiestruturadas com especialistas, organizadas em matrizes multicritério (Multicriteria Decision Analysis - MCDA) e ranqueadas através do método Analytic Hierarchy Process (AHP).

A pesquisa avalia o desempenho de diferentes metaheurísticas — Genetic Algorithm (GA), Particle Swarm Optimization (PSO) e Differential Evolution (DE) — na resolução do problema, dada a complexidade dos dados e a interdependência entre as zonas de produção. Essas técnicas permitem explorar eficientemente o espaço de soluções, identificando configurações que atendem aos critérios estabelecidos.

Os resultados demonstraram que as metaheurísticas analisadas, quando adaptadas ao contexto do problema, são eficazes para a otimização do posicionamento dos IICs, gerando soluções viáveis, de alto valor técnico, e validadas por especialistas da área.

Conclui-se que o uso de algoritmos de otimização constitui uma ferramenta promissora para agilizar decisões e apoiar tecnicamente os profissionais envolvidos no planejamento de completação de poços.

Palavras-chave

Poços de Petróleo; Intervalos de Isolamento Crítico; Otimização; Metaheurística; Análise Multicritério; Automatização.

Abstract

Neto, Luiz de Abreu Henriques; Santos, Paulo Ivson Netto (Advisor). **Optimization Algorithms for the Assisted Determination of Critical Isolation Intervals in Oil Wells**. Rio de Janeiro, 2025. 331p. Dissertação de Mestrado – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

This work primarily aims to evaluate and develop optimization algorithms for the assisted definition of Critical Isolation Intervals (CIIs) in oil wells. The proposed approach integrates operational guidelines — referred to as “Golden Rules” — with well log data to optimize CII placement in a precise and robust manner. The guidelines, based on criteria such as porosity, hydrocarbon saturation, and permeability, were elicited through semi-structured interviews with experts, organized into multicriteria decision matrices (MCDA), and ranked using the Analytic Hierarchy Process (AHP).

The study assesses the performance of different metaheuristics — Genetic Algorithm (GA), Particle Swarm Optimization (PSO), and Differential Evolution (DE) — in solving the problem, given the complexity of the data and the interdependence among production zones. These techniques efficiently explore the solution space, identifying configurations that satisfy the established criteria.

The results show that the analyzed metaheuristics, when adapted to the problem context, are effective for optimizing CII placement, producing feasible, high-technical-value solutions validated by domain experts.

It is concluded that the use of optimization algorithms is a promising tool to expedite decision-making and provide technical support to professionals involved in well completion planning.

Keywords

Oil Wells; Critical Isolation Intervals; Optimization; Metaheuristics; Multicriteria Analysis; Automation.

Sumário

1	Introdução	1
1.1	Contextualização	1
1.2	Problema de Pesquisa	3
1.3	Justificativa	4
1.4	Objetivo	4
1.4.1	Objetivo Geral	4
1.4.2	Objetivos Específicos	5
1.5	Estrutura da Dissertação	5
2	Trabalhos Relacionados	6
3	Metodologia	9
3.1	Criação das Melhores Práticas para o Posicionamento dos IICs	10
3.1.1	Roteiro das Entrevistas	11
3.1.1.1	Definição da Pesquisa	11
3.1.1.2	Seleção dos Participantes	11
3.1.1.3	Blocos de Perguntas	12
3.1.2	Definição das Diretrizes	12
3.1.3	Ranqueamento das Diretrizes Otimizadoras	13
3.2	Avaliação de Algoritmos de Otimização para a Definição Assistida dos IICs	16
3.2.1	Criação da Base de Dados de Perfis Geológicos	17
3.2.2	Funções de Score Individuais	18
3.2.2.1	Função Sigmoide	19
3.2.2.2	Função Linear por Partes	19
3.2.2.3	Função Parabólica (Quadrática)	20
3.2.2.4	Função Tangente Hiperbólica	21
3.2.2.5	Função Gaussiana	21
3.2.2.6	Função Hiperbólica Inversa	22
3.2.2.7	Comparativo Geral das Funções de Score Avaliadas	22
3.2.2.8	Função de Equilíbrio via Desvio Relativo	23
3.2.2.9	Combinação de Funções de Score	24
3.2.3	Função-Objetivo	27
3.2.4	Algoritmos de Otimização	28
3.2.4.1	Genetic Algorithm (GA)	30
3.2.4.2	Differential Evolution (DE)	32
3.2.4.3	Particle Swarm Optimization (PSO)	33
3.2.5	Implementação dos Algoritmos de Otimização	35
3.2.6	Comparação dos Algoritmos de Otimização	35
3.2.7	Validação das Soluções	37
4	Resultados	38
4.1	Criação das Melhores Práticas para o Posicionamento dos IICs	38
4.1.1	Extrato das Entrevistas	39

4.1.1.1	Características Gerais da Pesquisa	39
4.1.1.2	Perfil dos Entrevistados	39
4.1.1.3	Fatores de Decisão para a Divisão em Zonas	40
4.1.1.4	Perfilagem e Fatores Quantitativos	40
4.1.1.5	Tecnologia e Inovação	41
4.1.2	Definição das Diretrizes	41
4.1.3	Ranqueamento das Diretrizes Otimizadoras	44
4.1.4	Definição dos Pesos	45
4.2	Avaliação de Algoritmos de Otimização para a Definição Assistida dos IICs	48
4.2.1	Funções de Score Individuais	48
4.2.2	Função-Objetivo	52
4.2.3	Implementação dos Algoritmos de Otimização	53
4.2.4	Soluções Encontradas da Definição Assistida dos IICs	56
4.2.5	Comparação dos Algoritmos de Otimização	72
4.2.6	Validação das Soluções	76
4.3	Desenvolvimento da Ferramenta <i>Welllog Viewer and Analyzer</i>	77
4.3.1	Descrição do Software	77
4.3.1.1	Finalidade	78
4.3.1.2	Requisitos Funcionais e Não Funcionais	78
4.3.2	Conformidade do Arquivo LAS para Uso no Software	79
4.3.3	Exemplos da Interface do Sistema	79
5	Considerações Finais	82
5.1	Conclusões da Pesquisa	82
5.2	Limitações	83
5.3	Sugestões para Trabalhos Futuros	83
	Referências bibliográficas	84
A	Roteiro da Entrevista com Especialistas	88
B	Soluções Encontradas da Definição Assistida dos IICs	91
B.1	Execução 1	91
B.2	Execução 2	100
B.3	Execução 3	108
B.4	Execução 4	116
B.5	Execução 5	124
B.6	Execução 6	130
B.7	Execução 7	138
B.8	Execução 8	142
B.9	Execução 9	148
B.10	Execução 10	154
B.11	Execução 11	163
B.12	Execução 12	172
B.13	Execução 13	179
B.14	Execução 14	188
B.15	Execução 15	194
B.16	Execução 16	198

B.17	Execução 17	207
B.18	Execução 18	214
B.19	Execução 19	223
B.20	Execução 20	229
B.21	Execução 21	235
B.22	Execução 22	241
B.23	Execução 23	244
B.24	Execução 24	247
B.25	Execução 25	253
B.26	Execução 26	259
B.27	Execução 27	263
B.28	Execução 28	272
B.29	Execução 29	281
B.30	Execução 30	290
C	Exemplo de Arquivo LAS Corretamente Formatado	299
D	Tabela de Correlação de Parâmetros de Perfis	303

Lista de Figuras

Figura 1.1	Conjunto de perfis geológicos de poço de petróleo	2
Figura 1.2	Esquema de completação de poço produtor de petróleo dividido em 3 zonas	3
Figura 3.1	Metodologia	9
Figura 3.2	Metodologia do AHP baseado em ranking	14
Figura 4.1	Gráficos das funções sigmoides das diretrizes otimizadoras	51
Figura 4.2	Função de score da diretriz otimizada C (Equilíbrio de Capacidade de Fluxo)	52
Figura 4.3	Comparação de Desempenho dos Algoritmos	56
Figura 4.4	Comparação das Melhores Soluções por Algoritmo	58
Figura 4.5	Comparação das 4 Melhores Soluções Distintas (DE)	59
Figura 4.6	Comparação das 4 Melhores Soluções Distintas (GA)	60
Figura 4.7	Comparação das 4 Melhores Soluções Distintas (PSO)	61
Figura 4.8	Divisão Ótima do Poço (DE - Differential Evolution)	62
Figura 4.9	Divisão Ótima do Poço (GA - Algoritmo Genético)	63
Figura 4.10	Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	64
Figura 4.11	Convergência dos Algoritmos ao Longo do Tempo	65
Figura 4.12	Convergência dos Algoritmos por Número de Avaliações	66
Figura 4.13	Convergência do Algoritmo DE – Soluções Viáveis	67
Figura 4.14	Convergência do Algoritmo GA – Soluções Viáveis	68
Figura 4.15	Convergência do Algoritmo PSO – Soluções Viáveis	69
Figura 4.16	Análise da Distribuição de Soluções Viáveis	70
Figura 4.17	Relação entre Tempo de Execução e Qualidade da Solução	71
Figura 4.18	Tela Inicial	79
Figura 4.19	Caixa de seleção do arquivo .las	80
Figura 4.20	Tabela de métricas dos dados de perfil	80
Figura 4.21	Visualizador e Analisador de Perfil de Poços	81
Figura B.1	Execução 1 - Comparação de Desempenho dos Algoritmos	91
Figura B.2	Execução 1 - Comparação das Melhores Soluções por Algoritmo	92
Figura B.3	Execução 1 - Comparação das 4 Melhores Soluções Distintas (DE)	92
Figura B.4	Execução 1 - Comparação das 4 Melhores Soluções Distintas (GA)	93
Figura B.5	Execução 1 - Comparação das 4 Melhores Soluções Distintas (PSO)	93
Figura B.6	Execução 1 - Divisão Ótima do Poço (DE - Differential Evolution)	94
Figura B.7	Execução 1 - Divisão Ótima do Poço (GA - Algoritmo Genético)	94

Figura B.8 Execução 1 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	95
Figura B.9 Execução 1 - Convergência dos Algoritmos ao Longo do Tempo	95
Figura B.10 Execução 1 - Convergência dos Algoritmos por Número de Avaliações	96
Figura B.11 Execução 1 - Convergência do Algoritmo DE – Soluções Viáveis	96
Figura B.12 Execução 1 - Convergência do Algoritmo GA – Soluções Viáveis	97
Figura B.13 Execução 1 - Convergência do Algoritmo PSO – Soluções Viáveis	97
Figura B.14 Execução 1 - Análise da Distribuição de Soluções Viáveis	98
Figura B.15 Execução 1 - Relação entre Tempo de Execução e Qualidade da Solução	99
Figura B.16 Execução 2 - Comparação de Desempenho dos Algoritmos	100
Figura B.17 Execução 2 - Comparação das Melhores Soluções por Algoritmo	100
Figura B.18 Execução 2 - Comparação das 4 Melhores Soluções Distintas (DE)	101
Figura B.19 Execução 2 - Comparação das 4 Melhores Soluções Distintas (GA)	101
Figura B.20 Execução 2 - Comparação das 4 Melhores Soluções Distintas (PSO)	102
Figura B.21 Execução 2 - Divisão Ótima do Poço (DE - Differential Evolution)	102
Figura B.22 Execução 2 - Divisão Ótima do Poço (GA - Algoritmo Genético)	103
Figura B.23 Execução 2 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	103
Figura B.24 Execução 2 - Convergência dos Algoritmos ao Longo do Tempo	104
Figura B.25 Execução 2 - Convergência dos Algoritmos por Número de Avaliações	104
Figura B.26 Execução 2 - Convergência do Algoritmo DE – Soluções Viáveis	105
Figura B.27 Execução 2 - Convergência do Algoritmo GA – Soluções Viáveis	105
Figura B.28 Execução 2 - Convergência do Algoritmo PSO – Soluções Viáveis	106
Figura B.29 Execução 2 - Análise da Distribuição de Soluções Viáveis	106
Figura B.30 Execução 2 - Relação entre Tempo de Execução e Qualidade da Solução	107
Figura B.31 Execução 3 - Comparação de Desempenho dos Algoritmos	108
Figura B.32 Execução 3 - Comparação das Melhores Soluções por Algoritmo	108
Figura B.33 Execução 3 - Comparação das 4 Melhores Soluções Distintas (DE)	109

Figura B.34 Execução 3 - Comparação das 4 Melhores Soluções Distintas (GA)	109
Figura B.35 Execução 3 - Comparação das 4 Melhores Soluções Distintas (PSO)	110
Figura B.36 Execução 3 - Divisão Ótima do Poço (DE - Differential Evolution)	110
Figura B.37 Execução 3 - Divisão Ótima do Poço (GA - Algoritmo Genético)	111
Figura B.38 Execução 3 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	111
Figura B.39 Execução 3 - Convergência dos Algoritmos ao Longo do Tempo	112
Figura B.40 Execução 3 - Convergência dos Algoritmos por Número de Avaliações	112
Figura B.41 Execução 3 - Convergência do Algoritmo DE – Soluções Viáveis	113
Figura B.42 Execução 3 - Convergência do Algoritmo GA – Soluções Viáveis	113
Figura B.43 Execução 3 - Convergência do Algoritmo PSO – Soluções Viáveis	114
Figura B.44 Execução 3 - Análise da Distribuição de Soluções Viáveis	114
Figura B.45 Execução 3 - Relação entre Tempo de Execução e Qualidade da Solução	115
Figura B.46 Execução 4 - Comparação de Desempenho dos Algoritmos	116
Figura B.47 Execução 4 - Comparação das Melhores Soluções por Algoritmo	116
Figura B.48 Execução 4 - Comparação das 4 Melhores Soluções Distintas (DE)	117
Figura B.49 Execução 4 - Comparação das 4 Melhores Soluções Distintas (GA)	117
Figura B.50 Execução 4 - Comparação das 4 Melhores Soluções Distintas (PSO)	118
Figura B.51 Execução 4 - Divisão Ótima do Poço (DE - Differential Evolution)	118
Figura B.52 Execução 4 - Divisão Ótima do Poço (GA - Algoritmo Genético)	119
Figura B.53 Execução 4 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	119
Figura B.54 Execução 4 - Convergência dos Algoritmos ao Longo do Tempo	120
Figura B.55 Execução 4 - Convergência dos Algoritmos por Número de Avaliações	120
Figura B.56 Execução 4 - Convergência do Algoritmo DE – Soluções Viáveis	121
Figura B.57 Execução 4 - Convergência do Algoritmo GA – Soluções Viáveis	121
Figura B.58 Execução 4 - Convergência do Algoritmo PSO – Soluções Viáveis	122

Figura B.59 Execução 4 - Análise da Distribuição de Soluções Viáveis	122
Figura B.60 Execução 4 - Relação entre Tempo de Execução e Qualidade da Solução	123
Figura B.61 Execução 5 - Comparação de Desempenho dos Algoritmos	124
Figura B.62 Execução 5 - Comparação das Melhores Soluções por Algoritmo	124
Figura B.63 Execução 5 - Comparação das 4 Melhores Soluções Distintas (DE)	125
Figura B.64 Execução 5 - Comparação das 4 Melhores Soluções Distintas (GA)	125
Figura B.65 Execução 5 - Divisão Ótima do Poço (DE - Differential Evolution)	126
Figura B.66 Execução 5 - Divisão Ótima do Poço (GA - Algoritmo Genético)	126
Figura B.67 Execução 5 - Convergência dos Algoritmos ao Longo do Tempo	127
Figura B.68 Execução 5 - Convergência dos Algoritmos por Número de Avaliações	127
Figura B.69 Execução 5 - Convergência do Algoritmo DE – Soluções Viáveis	128
Figura B.70 Execução 5 - Convergência do Algoritmo GA – Soluções Viáveis	128
Figura B.71 Execução 5 - Relação entre Tempo de Execução e Qualidade da Solução	129
Figura B.72 Execução 6 - Comparação de Desempenho dos Algoritmos	130
Figura B.73 Execução 6 - Comparação das Melhores Soluções por Algoritmo	130
Figura B.74 Execução 6 - Comparação das 4 Melhores Soluções Distintas (DE)	131
Figura B.75 Execução 6 - Comparação das 4 Melhores Soluções Distintas (GA)	131
Figura B.76 Execução 6 - Comparação das 4 Melhores Soluções Distintas (PSO)	132
Figura B.77 Execução 6 - Divisão Ótima do Poço (DE - Differential Evolution)	132
Figura B.78 Execução 6 - Divisão Ótima do Poço (GA - Algoritmo Genético)	133
Figura B.79 Execução 6 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	133
Figura B.80 Execução 6 - Convergência dos Algoritmos ao Longo do Tempo	134
Figura B.81 Execução 6 - Convergência dos Algoritmos por Número de Avaliações	134
Figura B.82 Execução 6 - Convergência do Algoritmo DE – Soluções Viáveis	135
Figura B.83 Execução 6 - Convergência do Algoritmo GA – Soluções Viáveis	135

Figura B.84 Execução 6 - Convergência do Algoritmo PSO – Soluções Viáveis	136
Figura B.85 Execução 6 - Análise da Distribuição de Soluções Viáveis	136
Figura B.86 Execução 6 - Relação entre Tempo de Execução e Qualidade da Solução	137
Figura B.87 Execução 7 - Comparação de Desempenho dos Algoritmos	138
Figura B.88 Execução 7 - Comparação das Melhores Soluções por Algoritmo	138
Figura B.89 Execução 7 - Comparação das 4 Melhores Soluções Distintas (GA)	139
Figura B.90 Execução 7 - Divisão Ótima do Poço (GA - Algoritmo Genético)	139
Figura B.91 Execução 7 - Convergência dos Algoritmos ao Longo do Tempo	140
Figura B.92 Execução 7 - Convergência dos Algoritmos por Número de Avaliações	140
Figura B.93 Execução 7 - Convergência do Algoritmo GA – Soluções Viáveis	141
Figura B.94 Execução 7 - Relação entre Tempo de Execução e Qualidade da Solução	141
Figura B.95 Execução 8 - Comparação de Desempenho dos Algoritmos	142
Figura B.96 Execução 8 - Comparação das Melhores Soluções por Algoritmo	142
Figura B.97 Execução 8 - Comparação das 4 Melhores Soluções Distintas (DE)	143
Figura B.98 Execução 8 - Comparação das 4 Melhores Soluções Distintas (GA)	143
Figura B.99 Execução 8 - Divisão Ótima do Poço (DE - Differential Evolution)	144
Figura B.100 Execução 8 - Divisão Ótima do Poço (GA - Algoritmo Genético)	144
Figura B.101 Execução 8 - Convergência dos Algoritmos ao Longo do Tempo	145
Figura B.102 Execução 8 - Convergência dos Algoritmos por Número de Avaliações	145
Figura B.103 Execução 8 - Convergência do Algoritmo DE – Soluções Viáveis	146
Figura B.104 Execução 8 - Convergência do Algoritmo GA – Soluções Viáveis	146
Figura B.105 Execução 8 - Relação entre Tempo de Execução e Qualidade da Solução	147
Figura B.106 Execução 9 - Comparação de Desempenho dos Algoritmos	148
Figura B.107 Execução 9 - Comparação das Melhores Soluções por Algoritmo	148
Figura B.108 Execução 9 - Comparação das 4 Melhores Soluções Distintas (DE)	149
Figura B.109 Execução 9 - Comparação das 4 Melhores Soluções Distintas (GA)	149

Figura B.110	Execução 9 - Divisão Ótima do Poço (DE - Differential Evolution)	150
Figura B.111	Execução 9 - Divisão Ótima do Poço (GA - Algoritmo Genético)	150
Figura B.112	Execução 9 - Convergência dos Algoritmos ao Longo do Tempo	151
Figura B.113	Execução 9 - Convergência dos Algoritmos por Número de Avaliações	151
Figura B.114	Execução 9 - Convergência do Algoritmo DE – Soluções Viáveis	152
Figura B.115	Execução 9 - Convergência do Algoritmo GA – Soluções Viáveis	152
Figura B.116	Execução 9 - Relação entre Tempo de Execução e Qualidade da Solução	153
Figura B.117	Execução 10 - Comparação de Desempenho dos Algoritmos	154
Figura B.118	Execução 10 - Comparação das Melhores Soluções por Algoritmo	154
Figura B.119	Execução 10 - Comparação das 4 Melhores Soluções Distintas (DE)	155
Figura B.120	Execução 10 - Comparação das 4 Melhores Soluções Distintas (GA)	155
Figura B.121	Execução 10 - Comparação das 4 Melhores Soluções Distintas (PSO)	156
Figura B.122	Execução 10 - Divisão Ótima do Poço (DE - Differential Evolution)	156
Figura B.123	Execução 10 - Divisão Ótima do Poço (GA - Algoritmo Genético)	157
Figura B.124	Execução 10 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	157
Figura B.125	Execução 10 - Convergência dos Algoritmos ao Longo do Tempo	158
Figura B.126	Execução 10 - Convergência dos Algoritmos por Número de Avaliações	158
Figura B.127	Execução 10 - Convergência do Algoritmo DE – Soluções Viáveis	159
Figura B.128	Execução 10 - Convergência do Algoritmo GA – Soluções Viáveis	159
Figura B.129	Execução 10 - Convergência do Algoritmo PSO – Soluções Viáveis	160
Figura B.130	Execução 10 - Análise da Distribuição de Soluções Viáveis	161
Figura B.131	Execução 10 - Relação entre Tempo de Execução e Qualidade da Solução	162
Figura B.132	Execução 11 - Comparação de Desempenho dos Algoritmos	163
Figura B.133	Execução 11 - Comparação das Melhores Soluções por Algoritmo	163
Figura B.134	Execução 11 - Comparação das 4 Melhores Soluções Distintas (DE)	164

Figura B.135	Execução 11 - Comparação das 4 Melhores Soluções Distintas (GA)	164
Figura B.136	Execução 11 - Comparação das 4 Melhores Soluções Distintas (PSO)	165
Figura B.137	Execução 11 - Divisão Ótima do Poço (DE - Differential Evolution)	165
Figura B.138	Execução 11 - Divisão Ótima do Poço (GA - Algoritmo Genético)	166
Figura B.139	Execução 11 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	166
Figura B.140	Execução 11 - Convergência dos Algoritmos ao Longo do Tempo	167
Figura B.141	Execução 11 - Convergência dos Algoritmos por Número de Avaliações	167
Figura B.142	Execução 11 - Convergência do Algoritmo DE – Soluções Viáveis	168
Figura B.143	Execução 11 - Convergência do Algoritmo GA – Soluções Viáveis	168
Figura B.144	Execução 11 - Convergência do Algoritmo PSO – Soluções Viáveis	169
Figura B.145	Execução 11 - Análise da Distribuição de Soluções Viáveis	170
Figura B.146	Execução 11 - Relação entre Tempo de Execução e Qualidade da Solução	171
Figura B.147	Execução 12 - Comparação de Desempenho dos Algoritmos	172
Figura B.148	Execução 12 - Comparação das Melhores Soluções por Algoritmo	172
Figura B.149	Execução 12 - Comparação das 4 Melhores Soluções Distintas (DE)	173
Figura B.150	Execução 12 - Comparação das 4 Melhores Soluções Distintas (PSO)	173
Figura B.151	Execução 12 - Divisão Ótima do Poço (DE - Differential Evolution)	174
Figura B.152	Execução 12 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	174
Figura B.153	Execução 12 - Convergência dos Algoritmos ao Longo do Tempo	175
Figura B.154	Execução 12 - Convergência dos Algoritmos por Número de Avaliações	175
Figura B.155	Execução 12 - Convergência do Algoritmo DE – Soluções Viáveis	176
Figura B.156	Execução 12 - Convergência do Algoritmo PSO – Soluções Viáveis	176
Figura B.157	Execução 12 - Análise da Distribuição de Soluções Viáveis	177
Figura B.158	Execução 12 - Relação entre Tempo de Execução e Qualidade da Solução	178
Figura B.159	Execução 13 - Comparação de Desempenho dos Algoritmos	179
Figura B.160	Execução 13 - Comparação das Melhores Soluções por Algoritmo	179

Figura B.161	Execução 13 - Comparação das 4 Melhores Soluções Distintas (DE)	180
Figura B.162	Execução 13 - Comparação das 4 Melhores Soluções Distintas (GA)	180
Figura B.163	Execução 13 - Comparação das 4 Melhores Soluções Distintas (PSO)	181
Figura B.164	Execução 13 - Divisão Ótima do Poço (DE - Differential Evolution)	181
Figura B.165	Execução 13 - Divisão Ótima do Poço (GA - Algoritmo Genético)	182
Figura B.166	Execução 13 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	182
Figura B.167	Execução 13 - Convergência dos Algoritmos ao Longo do Tempo	183
Figura B.168	Execução 13 - Convergência dos Algoritmos por Número de Avaliações	183
Figura B.169	Execução 13 - Convergência do Algoritmo DE – Soluções Viáveis	184
Figura B.170	Execução 13 - Convergência do Algoritmo GA – Soluções Viáveis	184
Figura B.171	Execução 13 - Convergência do Algoritmo PSO – Soluções Viáveis	185
Figura B.172	Execução 13 - Análise da Distribuição de Soluções Viáveis	186
Figura B.173	Execução 13 - Relação entre Tempo de Execução e Qualidade da Solução	187
Figura B.174	Execução 14 - Comparação de Desempenho dos Algoritmos	188
Figura B.175	Execução 14 - Comparação das Melhores Soluções por Algoritmo	188
Figura B.176	Execução 14 - Comparação das 4 Melhores Soluções Distintas (DE)	189
Figura B.177	Execução 14 - Comparação das 4 Melhores Soluções Distintas (GA)	189
Figura B.178	Execução 14 - Divisão Ótima do Poço (DE - Differential Evolution)	190
Figura B.179	Execução 14 - Divisão Ótima do Poço (GA - Algoritmo Genético)	190
Figura B.180	Execução 14 - Convergência dos Algoritmos ao Longo do Tempo	191
Figura B.181	Execução 14 - Convergência dos Algoritmos por Número de Avaliações	191
Figura B.182	Execução 14 - Convergência do Algoritmo DE – Soluções Viáveis	192
Figura B.183	Execução 14 - Convergência do Algoritmo GA – Soluções Viáveis	192
Figura B.184	Execução 14 - Relação entre Tempo de Execução e Qualidade da Solução	193
Figura B.185	Execução 15 - Comparação de Desempenho dos Algoritmos	194

Figura B.186	Execução 15 - Comparação das Melhores Soluções por Algoritmo	194
Figura B.187	Execução 15 - Comparação das 4 Melhores Soluções Distintas (DE)	195
Figura B.188	Execução 15 - Divisão Ótima do Poço (DE - Differential Evolution)	195
Figura B.189	Execução 15 - Convergência dos Algoritmos ao Longo do Tempo	196
Figura B.190	Execução 15 - Convergência dos Algoritmos por Número de Avaliações	196
Figura B.191	Execução 15 - Convergência do Algoritmo DE – Soluções Viáveis	197
Figura B.192	Execução 15 - Relação entre Tempo de Execução e Qualidade da Solução	197
Figura B.193	Execução 16 - Comparação de Desempenho dos Algoritmos	198
Figura B.194	Execução 16 - Comparação das Melhores Soluções por Algoritmo	198
Figura B.195	Execução 16 - Comparação das 4 Melhores Soluções Distintas (DE)	199
Figura B.196	Execução 16 - Comparação das 4 Melhores Soluções Distintas (GA)	199
Figura B.197	Execução 16 - Comparação das 4 Melhores Soluções Distintas (PSO)	200
Figura B.198	Execução 16 - Divisão Ótima do Poço (DE - Differential Evolution)	200
Figura B.199	Execução 16 - Divisão Ótima do Poço (GA - Algoritmo Genético)	201
Figura B.200	Execução 16 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	201
Figura B.201	Execução 16 - Convergência dos Algoritmos ao Longo do Tempo	202
Figura B.202	Execução 16 - Convergência dos Algoritmos por Número de Avaliações	202
Figura B.203	Execução 16 - Convergência do Algoritmo DE – Soluções Viáveis	203
Figura B.204	Execução 16 - Convergência do Algoritmo GA – Soluções Viáveis	203
Figura B.205	Execução 16 - Convergência do Algoritmo PSO – Soluções Viáveis	204
Figura B.206	Execução 16 - Análise da Distribuição de Soluções Viáveis	205
Figura B.207	Execução 16 - Relação entre Tempo de Execução e Qualidade da Solução	206
Figura B.208	Execução 17 - Comparação de Desempenho dos Algoritmos	207
Figura B.209	Execução 17 - Comparação das Melhores Soluções por Algoritmo	207
Figura B.210	Execução 17 - Comparação das 4 Melhores Soluções Distintas (GA)	208

Figura B.211	Execução 17 - Comparação das 4 Melhores Soluções Distintas (PSO)	208
Figura B.212	Execução 17 - Divisão Ótima do Poço (GA - Algoritmo Genético)	209
Figura B.213	Execução 17 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	209
Figura B.214	Execução 17 - Convergência dos Algoritmos ao Longo do Tempo	210
Figura B.215	Execução 17 - Convergência dos Algoritmos por Número de Avaliações	210
Figura B.216	Execução 17 - Convergência do Algoritmo GA – Soluções Viáveis	211
Figura B.217	Execução 17 - Convergência do Algoritmo PSO – Soluções Viáveis	211
Figura B.218	Execução 17 - Análise da Distribuição de Soluções Viáveis	212
Figura B.219	Execução 17 - Relação entre Tempo de Execução e Qualidade da Solução	213
Figura B.220	Execução 18 - Comparação de Desempenho dos Algoritmos	214
Figura B.221	Execução 18 - Comparação das Melhores Soluções por Algoritmo	214
Figura B.222	Execução 18 - Comparação das 4 Melhores Soluções Distintas (DE)	215
Figura B.223	Execução 18 - Comparação das 4 Melhores Soluções Distintas (GA)	215
Figura B.224	Execução 18 - Comparação das 4 Melhores Soluções Distintas (PSO)	216
Figura B.225	Execução 18 - Divisão Ótima do Poço (DE - Differential Evolution)	216
Figura B.226	Execução 18 - Divisão Ótima do Poço (GA - Algoritmo Genético)	217
Figura B.227	Execução 18 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	217
Figura B.228	Execução 18 - Convergência dos Algoritmos ao Longo do Tempo	218
Figura B.229	Execução 18 - Convergência dos Algoritmos por Número de Avaliações	218
Figura B.230	Execução 18 - Convergência do Algoritmo DE – Soluções Viáveis	219
Figura B.231	Execução 18 - Convergência do Algoritmo GA – Soluções Viáveis	219
Figura B.232	Execução 18 - Convergência do Algoritmo PSO – Soluções Viáveis	220
Figura B.233	Execução 18 - Análise da Distribuição de Soluções Viáveis	221
Figura B.234	Execução 18 - Relação entre Tempo de Execução e Qualidade da Solução	222
Figura B.235	Execução 19 - Comparação de Desempenho dos Algoritmos	223
Figura B.236	Execução 19 - Comparação das Melhores Soluções por Algoritmo	223

Figura B.237	Execução 19 - Comparação das 4 Melhores Soluções Distintas (DE)	224
Figura B.238	Execução 19 - Comparação das 4 Melhores Soluções Distintas (GA)	224
Figura B.239	Execução 19 - Divisão Ótima do Poço (DE - Differential Evolution)	225
Figura B.240	Execução 19 - Divisão Ótima do Poço (GA - Algoritmo Genético)	225
Figura B.241	Execução 19 - Convergência dos Algoritmos ao Longo do Tempo	226
Figura B.242	Execução 19 - Convergência dos Algoritmos por Número de Avaliações	226
Figura B.243	Execução 19 - Convergência do Algoritmo DE – Soluções Viáveis	227
Figura B.244	Execução 19 - Convergência do Algoritmo GA – Soluções Viáveis	227
Figura B.245	Execução 19 - Relação entre Tempo de Execução e Qualidade da Solução	228
Figura B.246	Execução 20 - Comparação de Desempenho dos Algoritmos	229
Figura B.247	Execução 20 - Comparação das Melhores Soluções por Algoritmo	229
Figura B.248	Execução 20 - Comparação das 4 Melhores Soluções Distintas (DE)	230
Figura B.249	Execução 20 - Comparação das 4 Melhores Soluções Distintas (GA)	230
Figura B.250	Execução 20 - Divisão Ótima do Poço (DE - Differential Evolution)	231
Figura B.251	Execução 20 - Divisão Ótima do Poço (GA - Algoritmo Genético)	231
Figura B.252	Execução 20 - Convergência dos Algoritmos ao Longo do Tempo	232
Figura B.253	Execução 20 - Convergência dos Algoritmos por Número de Avaliações	232
Figura B.254	Execução 20 - Convergência do Algoritmo DE – Soluções Viáveis	233
Figura B.255	Execução 20 - Convergência do Algoritmo GA – Soluções Viáveis	233
Figura B.256	Execução 20 - Relação entre Tempo de Execução e Qualidade da Solução	234
Figura B.257	Execução 21 - Comparação de Desempenho dos Algoritmos	235
Figura B.258	Execução 21 - Comparação das Melhores Soluções por Algoritmo	235
Figura B.259	Execução 21 - Comparação das 4 Melhores Soluções Distintas (DE)	236
Figura B.260	Execução 21 - Comparação das 4 Melhores Soluções Distintas (GA)	236
Figura B.261	Execução 21 - Divisão Ótima do Poço (DE - Differential Evolution)	237

Figura B.262	Execução 21 - Divisão Ótima do Poço (GA - Algoritmo Genético)	237
Figura B.263	Execução 21 - Convergência dos Algoritmos ao Longo do Tempo	238
Figura B.264	Execução 21 - Convergência dos Algoritmos por Número de Avaliações	238
Figura B.265	Execução 21 - Convergência do Algoritmo DE – Soluções Viáveis	239
Figura B.266	Execução 21 - Convergência do Algoritmo GA – Soluções Viáveis	239
Figura B.267	Execução 21 - Relação entre Tempo de Execução e Qualidade da Solução	240
Figura B.268	Execução 22 - Comparação de Desempenho dos Algoritmos	241
Figura B.269	Execução 22 - Comparação das Melhores Soluções por Algoritmo	241
Figura B.270	Execução 22 - Convergência dos Algoritmos ao Longo do Tempo	242
Figura B.271	Execução 22 - Convergência dos Algoritmos por Número de Avaliações	242
Figura B.272	Execução 22 - Relação entre Tempo de Execução e Qualidade da Solução	243
Figura B.273	Execução 23 - Comparação de Desempenho dos Algoritmos	244
Figura B.274	Execução 23 - Comparação das Melhores Soluções por Algoritmo	244
Figura B.275	Execução 23 - Convergência dos Algoritmos ao Longo do Tempo	245
Figura B.276	Execução 23 - Convergência dos Algoritmos por Número de Avaliações	245
Figura B.277	Execução 23 - Relação entre Tempo de Execução e Qualidade da Solução	246
Figura B.278	Execução 24 - Comparação de Desempenho dos Algoritmos	247
Figura B.279	Execução 24 - Comparação das Melhores Soluções por Algoritmo	247
Figura B.280	Execução 24 - Comparação das 4 Melhores Soluções Distintas (DE)	248
Figura B.281	Execução 24 - Comparação das 4 Melhores Soluções Distintas (GA)	248
Figura B.282	Execução 24 - Divisão Ótima do Poço (DE - Differential Evolution)	249
Figura B.283	Execução 24 - Divisão Ótima do Poço (GA - Algoritmo Genético)	249
Figura B.284	Execução 24 - Convergência dos Algoritmos ao Longo do Tempo	250
Figura B.285	Execução 24 - Convergência dos Algoritmos por Número de Avaliações	250
Figura B.286	Execução 24 - Convergência do Algoritmo DE – Soluções Viáveis	251

Figura B.287	Execução 24 - Convergência do Algoritmo GA – Soluções Viáveis	251
Figura B.288	Execução 24 - Relação entre Tempo de Execução e Qualidade da Solução	252
Figura B.289	Execução 25 - Comparação de Desempenho dos Algoritmos	253
Figura B.290	Execução 25 - Comparação das Melhores Soluções por Algoritmo	253
Figura B.291	Execução 25 - Comparação das 4 Melhores Soluções Distintas (DE)	254
Figura B.292	Execução 25 - Comparação das 4 Melhores Soluções Distintas (GA)	254
Figura B.293	Execução 25 - Divisão Ótima do Poço (DE - Differential Evolution)	255
Figura B.294	Execução 25 - Divisão Ótima do Poço (GA - Algoritmo Genético)	255
Figura B.295	Execução 25 - Convergência dos Algoritmos ao Longo do Tempo	256
Figura B.296	Execução 25 - Convergência dos Algoritmos por Número de Avaliações	256
Figura B.297	Execução 25 - Convergência do Algoritmo DE – Soluções Viáveis	257
Figura B.298	Execução 25 - Convergência do Algoritmo GA – Soluções Viáveis	257
Figura B.299	Execução 25 - Relação entre Tempo de Execução e Qualidade da Solução	258
Figura B.300	Execução 26 - Comparação de Desempenho dos Algoritmos	259
Figura B.301	Execução 26 - Comparação das Melhores Soluções por Algoritmo	259
Figura B.302	Execução 26 - Comparação das 4 Melhores Soluções Distintas (DE)	260
Figura B.303	Execução 26 - Divisão Ótima do Poço (DE - Differential Evolution)	260
Figura B.304	Execução 26 - Convergência dos Algoritmos ao Longo do Tempo	261
Figura B.305	Execução 26 - Convergência dos Algoritmos por Número de Avaliações	261
Figura B.306	Execução 26 - Convergência do Algoritmo DE – Soluções Viáveis	262
Figura B.307	Execução 26 - Relação entre Tempo de Execução e Qualidade da Solução	262
Figura B.308	Execução 27 - Comparação de Desempenho dos Algoritmos	263
Figura B.309	Execução 27 - Comparação das Melhores Soluções por Algoritmo	263
Figura B.310	Execução 27 - Comparação das 4 Melhores Soluções Distintas (DE)	264
Figura B.311	Execução 27 - Comparação das 4 Melhores Soluções Distintas (GA)	264

Figura B.31	Execução 27 - Comparação das 4 Melhores Soluções Distintas (PSO)	265
Figura B.31	Execução 27 - Divisão Ótima do Poço (DE - Differential Evolution)	265
Figura B.31	Execução 27 - Divisão Ótima do Poço (GA - Algoritmo Genético)	266
Figura B.31	Execução 27 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	266
Figura B.31	Execução 27 - Convergência dos Algoritmos ao Longo do Tempo	267
Figura B.31	Execução 27 - Convergência dos Algoritmos por Número de Avaliações	267
Figura B.31	Execução 27 - Convergência do Algoritmo DE – Soluções Viáveis	268
Figura B.31	Execução 27 - Convergência do Algoritmo GA – Soluções Viáveis	268
Figura B.32	Execução 27 - Convergência do Algoritmo PSO – Soluções Viáveis	269
Figura B.32	Execução 27 - Análise da Distribuição de Soluções Viáveis	270
Figura B.32	Execução 27 - Relação entre Tempo de Execução e Qualidade da Solução	271
Figura B.32	Execução 28 - Comparação de Desempenho dos Algoritmos	272
Figura B.32	Execução 28 - Comparação das Melhores Soluções por Algoritmo	272
Figura B.32	Execução 28 - Comparação das 4 Melhores Soluções Distintas (DE)	273
Figura B.32	Execução 28 - Comparação das 4 Melhores Soluções Distintas (GA)	273
Figura B.32	Execução 28 - Comparação das 4 Melhores Soluções Distintas (PSO)	274
Figura B.32	Execução 28 - Divisão Ótima do Poço (DE - Differential Evolution)	274
Figura B.32	Execução 28 - Divisão Ótima do Poço (GA - Algoritmo Genético)	275
Figura B.32	Execução 28 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	275
Figura B.33	Execução 28 - Convergência dos Algoritmos ao Longo do Tempo	276
Figura B.33	Execução 28 - Convergência dos Algoritmos por Número de Avaliações	276
Figura B.33	Execução 28 - Convergência do Algoritmo DE – Soluções Viáveis	277
Figura B.33	Execução 28 - Convergência do Algoritmo GA – Soluções Viáveis	277
Figura B.33	Execução 28 - Convergência do Algoritmo PSO – Soluções Viáveis	278
Figura B.33	Execução 28 - Análise da Distribuição de Soluções Viáveis	279

Figura B.337	Execução 28 - Relação entre Tempo de Execução e Qualidade da Solução	280
Figura B.338	Execução 29 - Comparação de Desempenho dos Algoritmos	281
Figura B.339	Execução 29 - Comparação das Melhores Soluções por Algoritmo	281
Figura B.340	Execução 29 - Comparação das 4 Melhores Soluções Distintas (DE)	282
Figura B.341	Execução 29 - Comparação das 4 Melhores Soluções Distintas (GA)	282
Figura B.342	Execução 29 - Comparação das 4 Melhores Soluções Distintas (PSO)	283
Figura B.343	Execução 29 - Divisão Ótima do Poço (DE - Differential Evolution)	283
Figura B.344	Execução 29 - Divisão Ótima do Poço (GA - Algoritmo Genético)	284
Figura B.345	Execução 29 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	284
Figura B.346	Execução 29 - Convergência dos Algoritmos ao Longo do Tempo	285
Figura B.347	Execução 29 - Convergência dos Algoritmos por Número de Avaliações	285
Figura B.348	Execução 29 - Convergência do Algoritmo DE – Soluções Viáveis	286
Figura B.349	Execução 29 - Convergência do Algoritmo GA – Soluções Viáveis	286
Figura B.350	Execução 29 - Convergência do Algoritmo PSO – Soluções Viáveis	287
Figura B.351	Execução 29 - Análise da Distribuição de Soluções Viáveis	288
Figura B.352	Execução 29 - Relação entre Tempo de Execução e Qualidade da Solução	289
Figura B.353	Execução 30 - Comparação de Desempenho dos Algoritmos	290
Figura B.354	Execução 30 - Comparação das Melhores Soluções por Algoritmo	290
Figura B.355	Execução 30 - Comparação das 4 Melhores Soluções Distintas (DE)	291
Figura B.356	Execução 30 - Comparação das 4 Melhores Soluções Distintas (GA)	291
Figura B.357	Execução 30 - Comparação das 4 Melhores Soluções Distintas (PSO)	292
Figura B.358	Execução 30 - Divisão Ótima do Poço (DE - Differential Evolution)	292
Figura B.359	Execução 30 - Divisão Ótima do Poço (GA - Algoritmo Genético)	293
Figura B.360	Execução 30 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)	293
Figura B.361	Execução 30 - Convergência dos Algoritmos ao Longo do Tempo	294

Figura B.362	Execução 30 - Convergência dos Algoritmos por Número de Avaliações	294
Figura B.363	Execução 30 - Convergência do Algoritmo DE – Soluções Viáveis	295
Figura B.364	Execução 30 - Convergência do Algoritmo GA – Soluções Viáveis	295
Figura B.365	Execução 30 - Convergência do Algoritmo PSO – Soluções Viáveis	296
Figura B.366	Execução 30 - Análise da Distribuição de Soluções Viáveis	297
Figura B.367	Execução 30 - Relação entre Tempo de Execução e Qualidade da Solução	298

Lista de Tabelas

Tabela 3.1	Comparativo Geral das Funções de Score Avaliadas	23
Tabela 4.1	Extrato das diretrizes impeditivas	42
Tabela 4.2	Extrato das diretrizes otimizadoras	43
Tabela 4.3	Ranqueamento das diretrizes otimizadoras	44
Tabela 4.4	Matriz Par a Par do Especialista 1 (ranking 1;3;4;7;6;5;2)	45
Tabela 4.5	Matriz Par a Par do Especialista 2 (ranking 1;2;3;4;6;5;7)	45
Tabela 4.6	Matriz Par a Par do Especialista 3 (ranking 1;4;2;3;7;5;6)	46
Tabela 4.7	Matriz Par a Par do Especialista 4 (ranking 1;2;4;5;6;3;7)	46
Tabela 4.8	Matriz Par a Par do Especialista 5 (ranking 3;2;4;6;7;5;1)	46
Tabela 4.9	Matriz Par a Par do Especialista 6 (ranking 1;3;2;4;6;5;7)	46
Tabela 4.10	Matriz de Comparação Agregada	47
Tabela 4.11	Matriz de Comparação Agregada normalizada por coluna	47
Tabela 4.12	Matriz de pesos relativos entre as diretrizes otimizadoras	48
Tabela 4.13	Correspondência entre índice, diretriz, peso relativo e função de score	53
Tabela 4.14	Consolidação das Métricas Principais entre Algoritmos de Otimização	73
Tabela 4.15	Resumo das Frequências de Superação e Viabilidade dos Algoritmos	73
Tabela D.1	Tabela de Correlação de Parâmetros de Perfis	303

1

Introdução

Este capítulo estabelece o fio condutor da dissertação: parte do papel da perfilagem de poços na caracterização petrofísica, avança para a necessidade de segmentação do poço em zonas e a importância dos Intervalos de Isolamento Crítico (IICs) e do controle por ICVs no desempenho produtivo, e então enuncia o problema, a justificativa, os objetivos e a organização do trabalho. A intenção é conectar a prática operacional às formulações computacionais desenvolvidas nos capítulos seguintes, preparando o leitor para o mergulho conceitual que se inicia a seguir.

1.1

Contextualização

O petróleo é um líquido natural inflamável composto principalmente por uma complexa mistura de hidrocarbonetos. Após a extração, o petróleo bruto é refinado em diversas frações para produzir combustíveis como gasolina, diesel e querosene, além de matérias-primas para produtos petroquímicos, incluindo plásticos, fertilizantes, solventes e muitos outros. Devido à sua alta densidade energética e versatilidade, o petróleo é considerado uma das principais fontes de energia da sociedade moderna (Tissot e Welte, 1984). Assim, é uma fonte de energia fundamental para a economia global, alimentando indústrias, transportes e aquecimento, entre outras aplicações.

A cada ano, aproximadamente 70.000 poços de petróleo são perfurados globalmente (Rystad Energy, 2024), refletindo a demanda contínua por novas fontes de hidrocarbonetos e a necessidade de manutenção e expansão dos campos existentes. Esse número inclui poços de exploração, que buscam descobrir novas reservas, e poços de desenvolvimento, destinados a otimizar a extração de campos já conhecidos. A perfuração de poços é um indicador importante da atividade na indústria do petróleo, representando investimentos significativos em tecnologia e infraestrutura.

Para maximizar a eficiência de produção de um poço de petróleo, informações detalhadas são obtidas por meio da perfilagem de poço, também conhecida como *well logging*. Esses perfis oferecem um panorama detalhado das propriedades geológicas e petrofísicas da formação subterrânea, registrando

variáveis como porosidade, permeabilidade e saturação de fluidos ao longo da profundidade do poço. Um exemplo de conjunto de perfis geológicos de um poço de petróleo pode ser encontrado na Figura 1.1.




Figura 1.1: Conjunto de perfis geológicos de poço de petróleo

Esses dados permitem um mapeamento preciso do reservatório, identificando as zonas de maior potencial produtivo, caso seja um poço produtor, e aquelas mais adequadas para injeção de fluidos, caso seja injetor.

A partir desse mapeamento, torna-se possível dividir o poço em zonas de produção ou injeção. Os locais ao longo do poço onde ocorre a divisão efetiva entre as zonas são denominados intervalos de isolamento críticos (IICs).

A definição dos IICs é um elemento crucial na completação de poços de petróleo, influenciando diretamente a eficiência da produção e o controle de fluxo dos reservatórios. Em reservatórios heterogêneos, onde as camadas podem apresentar grandes variações nas propriedades, essa segmentação permite um controle seletivo do fluxo em cada zona, direcionando os esforços de produção para as camadas mais ricas em hidrocarbonetos e otimizando a injeção para sustentar a pressão do reservatório e deslocar o óleo na direção dos poços produtores.

Para gerenciar essas zonas de forma dinâmica, são utilizadas as *Interval Control Valves* (ICVs), que permitem o ajuste do fluxo de fluidos em cada zona, podendo ser operadas remotamente. Instaladas ao longo da coluna de produção, as ICVs possibilitam que cada zona seja aberta, fechada ou ajustada conforme necessário, evitando a produção de fluidos indesejados, como água ou gás, e garantindo que o potencial de cada zona seja aproveitado ao máximo.

Um esboço de completção de poço de petróleo de 3 zonas de produção/injeção pode ser encontrado na Figura 1.2.




Figura 1.2: Esquema de completção de poço produtor de petróleo dividido em 3 zonas

Assim, o correto posicionamento dos IICs, orientado pelos dados de perfilagem, e o gerenciamento dinâmico do fluxo que as ICVs proporcionam são fundamentais para um controle eficaz do reservatório e a maximização da recuperação de hidrocarbonetos ao longo da vida útil do poço e do campo.

1.2

Problema de Pesquisa

Apesar dos avanços tecnológicos na instrumentação e modelagem de reservatórios, a definição dos Intervalos de Isolamento Críticos ainda é frequentemente baseada em julgamentos subjetivos e abordagens pouco padronizadas, o que pode comprometer o desempenho do poço. Dada a complexidade e a heterogeneidade dos reservatórios, há uma necessidade crescente de métodos sistemáticos e inteligentes para orientar a seleção dos IICs com base em critérios técnicos bem definidos.

Esta dissertação propõe uma abordagem integrada que combina diretrizes técnicas, chamadas de “Regras de Ouro”, com análise assistida de perfis de poço para padronizar e otimizar a seleção dos IICs, visando maximizar a recuperação de hidrocarbonetos. A pesquisa investiga o uso de algoritmos de otimização capazes de interpretar e aplicar essas diretrizes em conjunto com

dados de perfilagem, promovendo uma tomada de decisão mais precisa e eficiente.

1.3

Justificativa

A escolha criteriosa dos IICs é essencial para o sucesso da produção em reservatórios complexos, sendo um elo crítico entre o conhecimento geológico e as operações de engenharia. No entanto, a ausência de diretrizes robustas e padronizadas para essa definição representa uma lacuna significativa na prática atual da indústria. Embora existam ferramentas avançadas de simulação e modelagem, elas ainda dependem fortemente de decisões humanas que podem variar entre os especialistas.

Neste contexto, a presente pesquisa justifica-se por propor uma metodologia pioneira que utiliza algoritmos de otimização e diretrizes técnicas derivadas de conhecimento especializado para apoiar a tomada de decisão. Além disso, o desenvolvimento de um software dedicado à aplicação dessa metodologia representa um avanço prático e replicável, com potencial de aplicação em diversos contextos operacionais. Do ponto de vista científico, a proposta contribui com a literatura ao explorar sinergias entre otimização e engenharia de reservatórios — áreas ainda pouco integradas quando se trata da definição de IICs.

1.4

Objetivo

Para orientar a investigação de forma objetiva, os propósitos desta pesquisa são apresentados em dois níveis complementares. Primeiro, define-se um objetivo geral que sintetiza a contribuição pretendida; em seguida, desdobram-se objetivos específicos que operacionalizam essa proposta.

1.4.1

Objetivo Geral

Desenvolver e avaliar uma metodologia baseada em algoritmos de otimização e diretrizes técnicas estruturadas para apoiar a definição assistida de Intervalos de Isolamento Críticos (IICs) em poços de petróleo com base na análise de perfis de poço.

1.4.2

Objetivos Específicos

- Coletar e sintetizar conhecimento especializado por meio de entrevistas com profissionais da indústria;
- Formular diretrizes técnicas (Regras de Ouro) para a seleção de IICs;
- Implementar e comparar diferentes algoritmos de otimização aplicados ao problema;
- Validar os resultados obtidos com especialistas por meio de estudos de caso em dados reais ou sintéticos;
- Desenvolver um software *open source* para visualização de perfis de poços de petróleo.

1.5

Estrutura da Dissertação

A dissertação está organizada da seguinte forma:

- **Capítulo 2 – Trabalhos Relacionados:** apresenta os fundamentos técnicos e científicos relacionados a metodologias de coleta de dados qualitativos e quantitativos, técnicas e algoritmos de otimização com foco em metaheurísticas, perfilagem de poços e definição de IICs.
- **Capítulo 3 – Metodologia:** detalha o processo de construção das diretrizes, a modelagem do problema, os algoritmos utilizados e os critérios de avaliação.
- **Capítulo 4 – Resultados:** apresenta os resultados obtidos com a aplicação da metodologia e a implantação dos algoritmos metaheurísticos, analisando seu desempenho, confrontando com os objetivos estabelecidos e sua validação com especialistas.
- **Capítulo 5 – Considerações Finais:** sintetiza as principais conclusões da pesquisa, discute suas limitações e apresenta sugestões para trabalhos futuros.

2

Trabalhos Relacionados

A literatura aponta avanços relevantes no uso de inteligência artificial (IA) e algoritmos de otimização aplicados à engenharia de reservatórios. No entanto, ainda são escassos os estudos que tratam diretamente da definição dos Intervalos de Isolamento Crítico (IICs) em poços a partir de melhores práticas operacionais. Embora pesquisas envolvendo válvulas de controle de intervalo (ICVs) e estratégias de otimização em poços inteligentes evidenciem benefícios na automação, observa-se a carência de abordagens que utilizem perfilagem de forma assistida para a seleção dos IICs. De modo geral, os trabalhos publicados abordam separadamente os principais eixos de investigação deste estudo: metodologias de coleta e análise de dados, técnicas de perfilagem de poços e otimização de ICV, bem como os algoritmos metaheurísticos.

No que diz respeito às metodologias de coleta de dados qualitativos e quantitativos semiestruturados, diversos autores discutem a importância de entrevistas semiestruturadas para capturar percepções, experiências e métricas de especialistas, com flexibilidade e profundidade (Jansen, 2010). Métodos como o *Analytic Hierarchy Process* (AHP) vêm sendo utilizados para transformar dados subjetivos em parâmetros quantitativos, conferindo rigor metodológico ao processo decisório (Leal, 2020) (Vaidya e Kumar, 2006) (Saaty, 2008). Leal (2020), por exemplo, propõe uma versão simplificada do AHP, denominada *AHP-express*, que reduz o número de comparações necessárias sem prejuízo da precisão, o que se mostra vantajoso em cenários práticos com múltiplos critérios. Já Maretto et al. (2022) sugerem a integração do AHP com lógica *fuzzy* para tratar incertezas e priorizar alternativas, ampliando a robustez dos modelos de decisão multicritério. Esses avanços metodológicos reforçam a aplicabilidade do AHP e de técnicas correlatas na organização e hierarquização de diretrizes operacionais para definição dos IICs.

Em relação à perfilagem de poços e otimização de ICV, a evolução das técnicas de aquisição e análise de dados tem impulsionado o uso de algoritmos de aprendizado de máquina, controle automatizado de válvulas de fluxo e processos de otimização em tempo real, especialmente em reservatórios complexos (Xie et al., 2023). Schaefer e Sampaio (2020) apresentam um fluxo de trabalho inovador para identificar camadas candidatas à aplicação de ICVs,

baseando-se em parâmetros de produção em tempo real e mapas de qualidade, com o objetivo de maximizar o valor presente líquido (NPV). Diretrizes para o posicionamento ideal de ICVs também são discutidas por Ebadi e Davies (2006), que destacam a influência do número e localização das válvulas sobre o controle de fluxo e produtividade dos poços inteligentes. Em reservatórios carbonáticos com alto teor de gás, Botechia et al. (2021) propõem a gestão de ICVs utilizando o *Gas-Oil Ratio* (GOR) como variável de controle, demonstrando ganhos econômicos e operacionais a partir da aplicação de algoritmos de otimização como o *Iterative Discrete Latin Hypercube* (IDLHC). Além disso, abordagens baseadas em redes neurais recorrentes com mecanismos de atenção e teoria Bayesiana vêm sendo aplicadas à previsão e análise de incertezas em dados de perfilagem, aprimorando a caracterização de reservatórios (Zeng et al., 2022).

No tocante às técnicas e algoritmos de otimização, destaca-se o papel das metaheurísticas na resolução de problemas complexos e de alta dimensionalidade, como o posicionamento de IICs em reservatórios heterogêneos. Os algoritmos evolutivos, como o Algoritmo Genético (GA), têm se mostrado eficazes ao explorar soluções inspiradas na seleção natural (Sharma e Kumar, 2022). Métodos como *Simulated Annealing* (SA), que simula o resfriamento de metais para evitar mínimos locais, e *Particle Swarm Optimization* (PSO), inspirado no comportamento coletivo de enxames, também figuram entre as técnicas amplamente adotadas (Verma et al., 2021) (Guilmeau et al., 2021). Liang et al. (2023) analisam a aplicação de algoritmos evolutivos em problemas de otimização multiobjetivo com restrições, ressaltando os desafios em equilibrar objetivos conflitantes. Estudos recentes têm demonstrado a integração dessas técnicas com inteligência artificial, permitindo automação e análise de grandes volumes de dados em sistemas de produção e gerenciamento de poços inteligentes (Elaziz et al., 2021) (Chou e Thejda, 2016). Ademais, estratégias para seleção de variáveis em problemas de classificação multiclasse e avaliações comparativas de desempenho de algoritmos metaheurísticos são discutidas por Akinola et al. (2022) e Halim et al. (2020), respectivamente, evidenciando o potencial dessas abordagens para simplificar dados e otimizar processos em engenharia de reservatórios.

Dessa forma, observa-se que, embora haja uma base sólida de métodos e ferramentas para coleta, análise e otimização em engenharia de poços, permanece uma lacuna significativa quanto ao desenvolvimento de técnicas integradas que, com base em boas práticas e dados de perfilagem, orientem de forma assistida a definição dos IICs em poços de petróleo. O presente trabalho propõe-se a avançar nesse sentido, promovendo decisões mais fundamentadas

e consistentes no contexto de poços inteligentes.

3 Metodologia

A presente pesquisa propõe uma abordagem metodológica estruturada para a definição assistida dos Intervalos de Isolamento Crítico (IICs) em poços de petróleo, a partir da integração de conhecimento especializado, técnicas multicritério e algoritmos de otimização. A metodologia foi organizada em duas grandes etapas complementares, conforme descrito a seguir e visualizado na Figura 3.1:



Figura 3.1: Metodologia

Etapa 1 – Criação das Melhores Práticas para o Posicionamento dos IICs

Esta etapa teve como objetivo levantar e sistematizar o conhecimento tácito de especialistas da indústria sobre os critérios mais relevantes para a definição dos intervalos de isolamento. Foram conduzidas entrevistas semi-estruturadas com profissionais experientes nas áreas de petrofísica, geologia, perfuração e completação de poços e engenharia de reservatórios.

A partir dos extratos das entrevistas, foi construído um conjunto de diretrizes técnicas — chamadas de “Regras de Ouro” — que refletem as melhores práticas para o posicionamento dos IICs em campos de petróleo, considerando aspectos como espessura mínima, porosidade, saturação, capacidade de fluxo, heterogeneidade, entre outros. Cada diretriz foi então formalizada em uma

função de score contínua, com valores entre 0 e 1, indicando o grau de conformidade de cada trecho do poço ao critério correspondente.

Etapla 2 – Avaliação de Algoritmos de Otimização para a Definição Assistida dos IICs

Esta é a etapa central da pesquisa, responsável por testar e validar o uso de algoritmos de otimização aplicados ao problema de definição dos IICs com base nos critérios estabelecidos. Primeiramente, foi conduzido um ranqueamento das diretrizes com uso do método *Analytic Hierarchy Process* (AHP). Os ranqueamentos por nível de importância feitos pelos especialistas permitiram atribuir pesos relativos a cada diretriz, formando uma estrutura multicritério quantitativa que foi integrada à função-objetivo da otimização.

Com os pesos definidos e as funções de score implementadas, foram aplicados três algoritmos metaheurísticos: *Genetic Algorithm* (GA), *Particle Swarm Optimization* (PSO) e *Differential Evolution* (DE). Esses algoritmos foram testados em dados reais e sintéticos de perfilagem de poços, com o objetivo de identificar configurações ótimas de zonas produtivas separadas por IICs.

O desempenho das abordagens foi avaliado com base na robustez das soluções, aderência às diretrizes técnicas e capacidade de generalização do modelo para diferentes cenários.

Bônus – Visualização e Análise dos Perfis de Poços

Por fim, foi desenvolvido um software *open source* de visualização interativa dos dados de perfilagem, denominado *WellLog Viewer and Analyzer*.

O software desenvolvido é uma ferramenta projetada para a visualização e análise detalhada de dados de perfis de poços, especialmente aqueles armazenados no formato padrão LAS. Este formato é amplamente utilizado na indústria de exploração de petróleo e gás, sendo fundamental para registrar informações cruciais sobre formações geológicas, propriedades dos fluidos e características do poço.

3.1

Criação das Melhores Práticas para o Posicionamento dos IICs

Nesta seção, o conhecimento tácito dos especialistas é traduzido em artefatos quantitativos utilizáveis pelos algoritmos de otimização. A partir de

entrevistas semiestruturadas, são extraídas e sistematizadas diretrizes técnicas para o posicionamento dos IICs.

3.1.1

Roteiro das Entrevistas

O roteiro utilizado nas entrevistas foi cuidadosamente elaborado para explorar de forma abrangente os fatores que influenciam a definição dos Intervalos de Isolamento Crítico (IICs). As perguntas foram organizadas em blocos temáticos, permitindo compreender tanto os aspectos subjetivos quanto os técnicos envolvidos na tomada de decisão. O roteiro completo encontra-se descrito no Apêndice A. A seguir, apresenta-se um resumo estruturado do instrumento de pesquisa.

3.1.1.1

Definição da Pesquisa

O objetivo principal do levantamento qualitativo/quantitativo foi entender as motivações para a divisão de um poço de petróleo em diferentes zonas de produção ou injeção, com foco na criação de diretrizes técnicas que orientem a seleção dos IICs.

A pergunta central da pesquisa foi: *Quais fatores guiam a decisão da divisão de poços de petróleo em zonas de produção e como são selecionados os IICs?*

Essa pergunta foi desdobrada nas seguintes subquestões:

- Quais são os principais critérios que influenciam a decisão de divisão de poços?
- Qual o papel da perfilagem no processo de seleção dos IICs?
- Quais perfis são mais importantes para a tomada de decisão?
- Quais fatores quantitativos derivados da perfilagem impactam diretamente essa escolha?

3.1.1.2

Seleção dos Participantes

Os participantes foram selecionados com base em critérios de expertise e experiência prática. Foram considerados elegíveis profissionais com atuação nas áreas de engenharia de reservatórios, geofísica e geologia, perfuração e completação de poços, e com envolvimento direto na tomada de decisão sobre zonas de produção.

- **Crítérios de seleção:** conhecimento técnico e vivência prática com a definição de zonas em poços multizonais.
- **Tamanho da amostra:** de 5 a 10 especialistas, com saturação teórica como critério de encerramento.
- **Estratégia de amostragem:** amostragem proposital, focada em indivíduos-chave do processo de decisão.

Coleta de Dados

As entrevistas foram realizadas de forma remota, por videoconferência, em formato semiestruturado. Essa abordagem permitiu flexibilidade para aprofundar pontos específicos a partir da experiência dos entrevistados.

3.1.1.3

Blocos de Perguntas

O roteiro de perguntas foi organizado em quatro blocos temáticos:

- **Bloco 1 – Perfil do Respondente:** Explora formação acadêmica, tempo de experiência e relação com a análise de perfis e divisão de zonas.
- **Bloco 2 – Fatores de Decisão para a Divisão em Zonas:** Investiga critérios técnicos e operacionais utilizados na prática, padrões recorrentes e experiências desafiadoras.
- **Bloco 3 – Perfilagem e Fatores Quantitativos:** Analisa a relevância dos diferentes tipos de perfilagem (porosidade, resistividade, densidade etc.) e busca dados quantitativos no processo de decisão dos IICs para posterior uso nas metaheurísticas.
- **Bloco 4 – Tecnologia e Inovação:** Questiona a existência de ferramentas automatizadas em uso e a receptividade a soluções computacionais de apoio à decisão.

3.1.2

Definição das Diretrizes

A definição efetiva das diretrizes técnicas se deu, principalmente, nos Blocos de Perguntas 2 e 3 da pesquisa. No Bloco 2, os entrevistados foram estimulados a discorrer sobre os principais fatores técnicos e operacionais que influenciam a divisão de um poço em zonas produtivas ou de injeção. As perguntas buscaram compreender o processo decisório que leva à escolha do número e da posição das zonas, além de identificar quais características do poço e do reservatório são priorizadas durante essa segmentação.

Já no Bloco 3, o foco recaiu sobre os perfis de poço mais utilizados nas decisões. Foram abordadas questões como: quais perfis os especialistas consideram mais relevantes, quais parâmetros extraídos desses perfis influenciam diretamente na escolha dos intervalos de isolamento e quais valores típicos ou faixas numéricas são utilizadas como referência prática para determinar se/onde uma zona deve ser isolada. A expectativa era que os especialistas mencionassem, de forma espontânea ou orientada, faixas específicas de porosidade, saturação, permeabilidade, espessura, entre outras variáveis técnicas.

Assim, a metodologia adotada para a construção das diretrizes consistiu na extração das recorrências técnicas e operacionais identificadas nas respostas a esses dois blocos. A análise foi conduzida com base em triangulação qualitativa, buscando convergência entre os diferentes relatos, bem como identificação de critérios mencionados com maior frequência, ênfase ou detalhamento pelos especialistas.

A partir dessa sistematização, foram elaboradas duas categorias principais de diretrizes:

- **Diretrizes Otimizadoras:** são aquelas que orientam o algoritmo de otimização para regiões de maior interesse técnico, ou seja, regiões do poço cujas características favorecem uma produção ou injeção eficiente. Quanto mais próxima a solução estiver do valor ideal dessas diretrizes, maior será seu score, refletindo seu maior potencial.
- **Diretrizes Impeditivas:** representam restrições técnicas que, se violadas, comprometem a viabilidade do isolamento no poço. A presença de características que contrariam essas diretrizes invalida completamente a seleção do intervalo de isolamento, sendo necessário excluir tais soluções do conjunto final.

Importante destacar que esta definição não é apenas um exercício teórico: ela visa alimentar diretamente a construção de uma função-objetivo formal, cuja estrutura numérica será posteriormente utilizada em algoritmos de otimização para apoiar decisões automatizadas no posicionamento dos IICs. Os resultados dessa sistematização, incluindo a lista final de diretrizes e sua aplicação prática, serão apresentados no capítulo 4 desta dissertação.

3.1.3

Ranqueamento das Diretrizes Otimizadoras

Após a definição das diretrizes otimizadoras com base nas entrevistas qualitativas (Seção 3.1.2), foi necessário estabelecer o peso relativo de cada diretriz para compor a função-objetivo dos algoritmos de otimização. Para

isso, utilizou-se o método *Analytic Hierarchy Process* (AHP) em sua versão adaptada para dados de ranking.

A atribuição de pesos foi feita a partir do julgamento dos próprios especialistas entrevistados, que receberam a lista de diretrizes e foram solicitados a classificá-las por ordem de importância, do critério mais relevante ao menos relevante no contexto do posicionamento ideal dos IICs. Essa abordagem visa capturar a percepção técnica dos especialistas quanto ao impacto relativo de cada variável no sucesso da operação.

AHP baseado em ranking

O método AHP tradicional, proposto por Saaty (1980), fundamenta-se na comparação par a par entre critérios, construindo uma matriz quadrada de juízos de preferência relativos (comparação par a par). A versão adaptada utilizada neste trabalho, no entanto, parte de um ranking ordinal fornecido diretamente pelos especialistas, sem a necessidade de preenchimento de todas as comparações possíveis. Isso reduz o esforço cognitivo e facilita a coleta em contextos práticos, especialmente quando há múltiplos critérios e um número elevado de participantes.

O funcionamento do AHP baseado em ranking se dá em quatro etapas principais, conforme a Figura 3.2.



Figura 3.2: Metodologia do AHP baseado em ranking

1. **Ranqueamento pelos Entrevistados:** Cada especialista ficou responsável por ordenar as diretrizes otimizadoras em caráter de importância. A numeração utilizada variou de 1 a N, sendo N o número de diretrizes otimizadoras. Quanto menor o número, maior a relevância atribuída à diretriz. Essa abordagem está alinhada com métodos de obtenção de pesos a partir de rankings ordinais, cuja simplicidade reduz o esforço cognitivo dos especialistas e é reconhecida na literatura de apoio à decisão multicritério (Ahn e Park, 2008).
2. **Criação da Matriz de Comparação Par a Par:** A partir da ordem fornecida por cada especialista, é construída automaticamente uma matriz quadrada de preferências relativas entre os critérios. Se um critério

C_i foi ranqueado acima de C_j , então assume-se que $C_i \succ C_j$, atribuindo-se uma razão entre os pesos baseada na distância relativa no ranking. Uma das formas mais empregadas para esse cálculo é a razão entre os rankings (Vaidya e Kumar, 2006). Sendo M_{ij} o valor na linha i e coluna j da matriz de comparação par a par, tem-se, portanto, o seguinte cálculo:

$$M_{ij} = \frac{\text{ranking}(j)}{\text{ranking}(i)}$$

3. **Agregação Matricial:** Para obter uma visão consolidada do grupo, essas matrizes são agregadas por meio da média geométrica dos valores correspondentes, abordagem reconhecida em estudos de consenso multi-critério (Saaty, 2008; Vaidya e Kumar, 2006). O resultado é uma matriz consensual que representa a opinião coletiva dos especialistas. Sendo M_{ij}^{agregado} o valor na linha i e coluna j da matriz agregada, tem-se, portanto, o seguinte cálculo:

$$M_{ij}^{\text{agregado}} = \left(\prod_{p=1}^k M_{ij}^{(p)} \right)^{1/k}$$

4. **Cálculo Final dos Pesos:** Após a obtenção da matriz agregada, calcula-se o vetor de pesos normalizados por meio do autovetor principal da matriz. Esse vetor representa a importância relativa de cada diretriz otimizadora, procedimento amplamente aceito no contexto do AHP (Saaty, 2008; Vaidya e Kumar, 2006), sendo posteriormente utilizado como fator de ponderação nos algoritmos de otimização. O passo a passo abaixo exemplifica o método de cálculo:

- (a) *Escrever o sistema:*

$$M^{\text{agregada}} \mathbf{w} = \lambda_{\max} \mathbf{w},$$

onde $\lambda_{\max}$ é o maior autovalor da matriz positiva M^{agregada} .

- (b) *Extrair o autovetor $\mathbf{w}' = (w'_1, \dots, w'_n)^\top$ associado a $\lambda_{\max}$.*

- (c) *Normalizar para somar 1:*

$$w_i = \frac{w'_i}{\sum_{j=1}^n w'_j} \quad (i = 1, \dots, n)$$

O vetor $\mathbf{w}$ obtido representa a importância relativa de cada critério e coincide, no AHP, com a única solução positiva (teorema de

Perron–Frobenius).

Como alternativa mais simples ao cálculo do autovetor principal — especialmente válida quando se deseja uma solução computacionalmente mais leve —, adotou-se a estratégia da média das linhas da matriz normalizada, proporcionando resultados próximos aos do autovetor principal (Vaidya e Kumar, 2006). Nesse procedimento, cada valor da matriz é dividido pela soma da respectiva coluna, e, em seguida, calcula-se a média dos valores de cada linha. O vetor resultante aproxima bem os pesos derivados pelo autovetor e é amplamente aceito como substituto prático, com margem de erro pequena na maioria dos contextos decisórios. O passo a passo abaixo exemplifica o método de cálculo:

(a) *Normalização por coluna. Para cada coluna j :*

$$c_j = \sum_{i=1}^n M_{ij}^{\text{agregada}}, \quad N_{ij} = \frac{M_{ij}^{\text{agregada}}}{c_j}.$$

(b) *Média de cada linha:*

$$r_i = \frac{1}{n} \sum_{j=1}^n N_{ij} \quad (i = 1, \dots, n)$$

(c) *Normalização final:*

$$\boxed{w_i = \frac{r_i}{\sum_{j=1}^n r_j} \quad (i = 1, \dots, n)}$$

O vetor resultante $\mathbf{w}$ aproxima muito bem o autovetor principal, mas requer apenas divisões e médias, sendo indicado quando se busca simplicidade computacional.

3.2

Avaliação de Algoritmos de Otimização para a Definição Assistida dos IICs

A segunda etapa da metodologia, e também a mais relevante deste trabalho, consistiu na avaliação computacional de diferentes algoritmos de otimização aplicados à definição assistida dos Intervalos de Isolamento Crítico (IICs) em poços de petróleo. Esta etapa representa o núcleo central da proposta metodológica, pois traduz as diretrizes técnicas estabelecidas com base na expertise dos especialistas em uma estrutura formal de tomada de decisão,

capaz de ser processada computacionalmente por algoritmos avançados de busca.

A abordagem proposta fundamenta-se na construção de funções objetivo parametrizadas por critérios técnicos (Seção 3.1) e na utilização de algoritmos capazes de explorar, de forma eficiente, o espaço de soluções possíveis. O objetivo é identificar os posicionamentos de IICs que maximizem o potencial produtivo e a eficiência do poço, respeitando simultaneamente as restrições operacionais impostas pelas diretrizes impeditivas.

Por meio dessa estrutura, a pesquisa pretende fornecer uma metodologia robusta, reproduzível e escalável para suportar decisões críticas no planejamento de completação de poços heterogêneos. A seguir são descritos os componentes centrais da formulação do problema de otimização.

3.2.1

Criação da Base de Dados de Perfis Geológicos

A obtenção de dados públicos de perfis de poços é um desafio significativo para pesquisadores, engenheiros e profissionais da indústria de petróleo e gás. Existem várias razões para essa dificuldade:

- **Privacidade e Confidencialidade:** Muitos dados de perfis de poços são considerados proprietários e confidenciais pelas empresas que realizam a exploração e produção. Como resultado, esses dados não são compartilhados publicamente para proteger interesses comerciais e estratégicos.
- **Regulamentações e Políticas:** As regulamentações governamentais e políticas de muitas regiões podem restringir a divulgação de dados geológicos e geofísicos. Isso pode incluir restrições de segurança nacional ou políticas de propriedade de recursos naturais.
- **Custos Associados:** A coleta e processamento de dados de perfis de poços são atividades caras. Frequentemente, as empresas investem significativamente em tecnologia e mão de obra para adquirir esses dados, e podem não ter incentivo para compartilhar essas informações gratuitamente.

O site da Kansas Geological Survey (KGS)¹ disponibiliza uma base de dados pública onde os usuários podem encontrar uma variedade de informações geológicas e geofísicas, incluindo dados de perfis de poços em arquivos LAS, os quais foram utilizados como inputs das metaheurísticas implementadas.

Foram selecionados conjuntos de perfis de 13 poços reais que continham todas as informações necessárias para a aplicação completa das diretrizes téc-

¹<https://www.kgs.ku.edu/Magellan/Logs/index.html>

nicas estabelecidas. Para garantir a consistência dos critérios, foram realizadas adequações nos perfis originais, de modo que seus valores se alinhassem às faixas esperadas pelas diretrizes. Essas adequações foram necessárias porque os especialistas participantes da pesquisa se basearam em um campo de petróleo específico, cujas características podem variar significativamente de outros campos. Ressalta-se que o algoritmo desenvolvido possui flexibilidade para adaptação a diferentes contextos, permitindo a reconfiguração rápida dos limites utilizados caso se deseje aplicar a metodologia a outras áreas ou formações geológicas.

Com o objetivo de ampliar o espaço amostral e permitir uma análise mais robusta da performance dos algoritmos de otimização, foram geradas 17 variações sintéticas dos 13 conjuntos de perfis originais, resultando em um total de 30 conjuntos de dados na base utilizada para os testes computacionais.

3.2.2

Funções de Score Individuais

A construção da função-objetivo dos algoritmos de otimização exige que cada diretriz otimizadora seja formalmente traduzida em uma função matemática de avaliação — denominada aqui função de score individual. Tal procedimento é fundamental em métodos multicritério e de otimização, garantindo a tradução dos requisitos operacionais em métricas numéricas padronizadas para comparação e agregação (Marler e Arora, 2010; Brans et al., 1986). Essa função é responsável por atribuir, a cada zona avaliada do poço, uma pontuação padronizada entre 0 e 1, representando o grau de aderência daquela zona à diretriz desejada.

Assim, cada diretriz otimizadora definida na etapa anterior é associada a uma função de score individual específica, elaborada de forma a refletir o comportamento ideal para a variável em questão. Por exemplo, uma diretriz baseada em porosidade mínima desejável pode adotar uma função sigmoide crescente, na qual zonas com baixa porosidade recebem pontuação próxima de zero e zonas com porosidade superior ao limiar ideal se aproximam de um score igual a 1. A literatura recomenda a escolha de funções de score que melhor reflitam o efeito esperado do critério avaliado, podendo adotar diferentes formas matemáticas de acordo com a natureza da variável (Brans et al., 1986; Marler e Arora, 2010).

Diversos tipos de funções foram testados para representar esses comportamentos, incluindo funções exponenciais, lineares e quadráticas. A escolha da função mais adequada depende da sensibilidade desejada para o critério, do tipo de penalização ou incentivo e do contexto de aplicação (Marler e Arora,

2010).

O detalhamento matemático de cada função de score individual testada será apresentado nas seções a seguir, junto de seus respectivos comentários sobre vantagens, limitações e adequação a diferentes contextos operacionais.

3.2.2.1

Função Sigmoide

A função sigmoide é usada quando se deseja representar, de forma contínua, uma transição suave entre valores rejeitados e aceitos. Sua aplicabilidade é reconhecida na modelagem de preferências progressivas, em que a pontuação aumenta gradativamente conforme a variável se aproxima do ideal (Brans et al., 1986).

$$f(x) = \frac{1}{1 + e^{-k(x-x_0)}}$$

Onde:

- x : valor da variável de interesse;
- x_0 : ponto de inflexão (onde $f(x) = 0,5$);
- k : coeficiente que define a inclinação da curva.

Vantagens:

- Função contínua e diferenciável (ótima para algoritmos de otimização);
- Alta interpretabilidade por especialistas;
- Flexibilidade para simular diferentes limiares e faixas de transição;
- Estabilidade computacional mesmo em ambientes com múltiplas variáveis.

3.2.2.2

Função Linear por Partes

A função linear por partes é usada quando se deseja uma penalização abrupta ao cruzar um limite mínimo ou máximo. Este tipo de função é indicado quando a aceitabilidade do critério muda drasticamente em torno de um valor-limite (Brans et al., 1986).

$$f(x) = \begin{cases} 0, & x \leq x_{\text{mín}}, \\ \frac{x - x_{\text{mín}}}{x_{\text{ideal}} - x_{\text{mín}}}, & x_{\text{mín}} < x < x_{\text{ideal}}, \\ 1, & x \geq x_{\text{ideal}}. \end{cases}$$

Onde:

- $x_{\min}$: valor a partir do qual o score começa a crescer;
- x_{ideal} : valor no qual o score atinge 1.

Vantagens:

- Simples e intuitiva;
- Fácil de configurar e compreender;
- Adequada para limiares com aceitação binária.

Desvantagens:

- Gera descontinuidades (não suave);
- Menor estabilidade para métodos baseados em gradiente.

3.2.2.3**Função Parabólica (Quadrática)**

Indicada quando se deseja uma penalização simétrica ao redor de um valor ideal, a função parabólica é apropriada para variáveis que devem estar próximas de um ponto ótimo, penalizando desvios para mais ou para menos. A suavidade desse tipo de função pode ser vantajosa para critérios com tolerância central (Marler e Arora, 2010).

$$f(x) = 1 - \left(\frac{x - x_0}{r} \right)^2$$

Onde:

- x_0 : valor ideal;
- r : raio de tolerância.

Vantagens:

- Penalização suave e contínua;
- Ideal para representar variáveis que devem estar próximas de um valor central.

Desvantagens:

- Penalização rápida em valores distantes do ótimo;
- Pode gerar score negativo se mal calibrada (necessita limitação entre 0 e 1).

3.2.2.4

Função Tangente Hiperbólica

A função tangente hiperbólica oferece uma transição suave, semelhante à sigmoide, mas simétrica em torno do ponto de inflexão. Esta função, por suas características de suavidade e simetria, é especialmente útil em situações em que é necessário modelar critérios com resposta simétrica e contínua (Brans et al., 1986).

$$f(x) = \frac{\tanh(k(x - x_0)) + 1}{2}$$

Onde:

- k : fator de inclinação;
- x_0 : ponto de transição.

Vantagens:

- Alternativa suave e simétrica;
- Mais controlável em curvas amplas.

Desvantagens:

- Interpretação menos intuitiva;
- Pouco adotada na literatura em engenharia de reservatórios.

3.2.2.5

Função Gaussiana

Usada para premiar valores que estejam muito próximos de um alvo ótimo, a função gaussiana penaliza desvios em ambas as direções a partir do centro. A literatura recomenda seu uso para variáveis cujo valor ideal é bem definido e desvios devem ser penalizados igualmente (Brans et al., 1986).

$$f(x) = \exp\left(-\frac{(x - x_0)^2}{2\sigma^2}\right)$$

Onde:

- x_0 : valor ideal;
- σ : desvio padrão que define a “largura” da aceitação.

Vantagens:

- Suavidade absoluta;
- Penaliza igualmente para mais ou para menos.

Desvantagens:

- Não funciona bem com limites assimétricos (apenas mínimo ou máximo);
- Exige cuidado para evitar scores residuais irrelevantes.

3.2.2.6**Função Hiperbólica Inversa**

Indica rejeição de valores altos com penalização agressiva, sendo útil para critérios em que valores elevados representam maior penalidade ou risco. Este tipo de função pode ser aplicado para limitar rapidamente o score em situações críticas (Brans et al., 1986).

$$f(x) = \frac{1}{1 + kx}$$

Onde:

- k : fator de penalização (ajustável conforme sensibilidade).

Vantagens:

- Rejeita rapidamente valores ruins;
- Ideal para variáveis como calíper ou razão gás-óleo.

Desvantagens:

- Curva muito inclinada;
- Requer normalização cuidadosa.

3.2.2.7**Comparativo Geral das Funções de Score Avaliadas**

A Tabela 3.1 resume as principais funções de score avaliadas nesta pesquisa, destacando suas aplicações típicas, vantagens e desvantagens. Tal abordagem de comparação entre funções de score encontra amplo respaldo na literatura de decisão multicritério e otimização (Marler e Arora, 2010; Brans et al., 1986).

Função	Aplicação típica	Vantagens principais	Desvantagens principais
Sigmoide	Crítérios progressivos com zona de transição	Suavidade, controle de inclinação, fácil parametrização	Pode ser pouco intuitiva em faixas muito estreitas
Linear por partes	Limiar absoluto com salto direto de score	Simples de implementar e interpretar	Descontinuidade brusca no ponto de corte
Parabólica (quadrática)	Penalização simétrica em torno de um valor ótimo	Penalização suave, função contínua	Penaliza fortemente valores extremos
Tangente hiperbólica	Alternativa suave à sigmoide	Transição simétrica, suavidade	Mais difícil de calibrar
Gaussiana	Recompensa máxima em torno de um valor central	Suavidade e penalização simétrica	Inadequada quando há apenas limiares inferiores
Hiperbólica inversa	Rejeição rápida para valores fora do ideal	Forte penalização de valores ruins	Pode gerar instabilidade numérica

Tabela 3.1: Comparativo Geral das Funções de Score Avaliadas

3.2.2.8

Função de Equilíbrio via Desvio Relativo

Em muitos problemas de decisão multicritério, especialmente aqueles aplicados à engenharia de reservatórios, não basta que determinadas variáveis atinjam valores absolutos elevados — é igualmente desejável que esses valores estejam distribuídos de forma equilibrada entre diferentes zonas. Por exemplo, ao considerar a capacidade de fluxo ou a espessura de zonas produtivas, é frequente que se busque um desempenho uniforme entre os segmentos, evitando concentrações excessivas que possam comprometer a eficiência operacional futura. Esse tipo de requisito é bem discutido na literatura de otimização multicritério, onde métricas de dispersão e homogeneidade são usadas como funções objetivo auxiliares, sobretudo quando se deseja robustez e equilíbrio no resultado (Marler e Arora, 2010).

Para capturar esse comportamento desejável, introduz-se nesta seção o conceito de funções de equilíbrio, baseadas no desvio relativo entre zonas. Tais funções avaliam o grau de homogeneidade entre os valores observados, penalizando discrepâncias significativas mesmo quando os valores médios são elevados. A utilização do desvio padrão relativo à média como função-objetivo auxiliar está alinhada às recomendações de Marler e Arora (2010), que enfatizam a importância da normalização e da equivalência adimensional na comparação de múltiplos critérios, principalmente quando há interesse em uniformidade ou

robustez dos resultados.

$$\text{Score}_{\text{equilíbrio}} = 1 - \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}}{\bar{x} + \epsilon}$$

Onde:

- $\bar{x}$: média das variáveis entre zonas;
- ϵ : pequeno valor para evitar divisão por zero.

Vantagens:

- Penaliza dispersões;
- Incentiva uniformidade entre zonas produtivas ou injetoras.

A formulação resultante produz scores contínuos entre 0 e 1, nos quais valores mais próximos de 1 indicam maior equilíbrio entre as zonas. Além de apresentar excelente interpretabilidade, esse tipo de função se mostra computacionalmente simples e compatível com técnicas modernas de otimização (Marler e Arora, 2010).

3.2.2.9

Combinação de Funções de Score

Ao se trabalhar com múltiplas variáveis que representam a mesma característica desejável (otimizar o posicionamento dos IICs em um poço de petróleo), torna-se necessário combinar suas respectivas funções de score em uma métrica única que represente o desempenho global daquele critério. Essa etapa é crucial para a agregação coerente dos indicadores parciais, garantindo que o modelo de avaliação reflita adequadamente o comportamento do sistema como um todo.

Marler e Arora (2010) apresentam e discutem em profundidade as principais formas de agregação de funções de score no contexto de otimização multicritério, como o produto, o mínimo e a média ponderada, abordando as vantagens e limitações de cada abordagem. Brans et al. (1986), ao tratar do método PROMETHEE, apresentam uma ampla variedade de funções de agregação (incluindo produto, mínimo, média ponderada e funções generalizadas como gaussiana, linear e por partes) para compor preferências globais, destacando o rigor lógico, a suavidade e o efeito de penalização/compensação de cada método.

Nesta seção, são exploradas diferentes estratégias matemáticas para combinar funções de score associadas a variáveis similares em diferentes zonas. As

abordagens analisadas incluem: o produto das funções, que representa um modelo multiplicativo com forte penalização em casos de baixo desempenho individual; o uso do mínimo entre os scores, que assume uma postura conservadora ao considerar apenas a pior zona; e a média ponderada, que permite balancear o impacto relativo de cada zona com base em pesos previamente definidos.

A escolha entre essas formas de combinação considera tanto o comportamento desejado do modelo quanto os objetivos específicos da análise, equilibrando rigor, interpretabilidade e compatibilidade com técnicas de otimização.

Produto

$$f = f(x_1) \cdot f(x_2)$$

O produto das funções de score representa um modelo multiplicativo com forte penalização em casos de baixo desempenho individual. Marler e Arora (2010) enfatizam que o produto é consistente com o princípio de que todos os critérios devem ser atendidos simultaneamente, sendo amplamente usado em situações em que a falha em um único critério compromete o resultado global.

Vantagens:

- **Rigor lógico:** penaliza fortemente quando qualquer uma das zonas está ruim. A saída só será alta se ambos os valores forem altos.
- **Multiplicativamente consistente:** representa bem o conceito de “todos os critérios precisam ser atendidos”.
- **Suavidade e diferenciabilidade:** ótimo para métodos de otimização contínua (ex.: algoritmos baseados em gradiente).

Desvantagens:

- **Pode ser excessivamente punitivo,** ou seja, se uma das funções tiver score baixo (mesmo que a outra esteja boa), o resultado será baixo.
- **A interpretação do valor resultante é menos direta** que em uma média.

Mínimo

$$f = \min \left(f(x_1), f(x_2) \right)$$

O uso do mínimo entre os scores assume uma postura conservadora ao considerar apenas a pior zona, sendo adequado para análises de “pior caso” ou situações críticas. Brans et al. (1986) explicam que essa abordagem é útil quando o desempenho global depende do “elo mais fraco”.

Vantagens:

- **Clareza semântica:** o score final reflete o pior caso — o que faz sentido se uma zona crítica pode comprometer toda a operação.
- **Robusto para análise conservadora:** útil quando se quer garantir que todas as zonas estejam em conformidade.

Desvantagens:

- **Não suave:** a função mínima não é diferenciável em todos os pontos, o que dificulta o uso em otimizações contínuas.
- **Pode ser pessimista demais,** desconsiderando o bom desempenho das outras zonas.

Média Ponderada

$$f = w_1 \cdot f(x_1) + w_2 \cdot f(x_2), \quad \text{com } w_1 + w_2 = 1$$

A média ponderada permite balancear o impacto relativo de cada zona com base em pesos definidos, facilitando a interpretação e a flexibilidade do modelo. Marler e Arora (2010) e Brans et al. (1986) discutem como a atribuição de pesos influencia a agregação e os cuidados na escolha para garantir coerência na análise multicritério.

Vantagens:

- **Flexível:** permite atribuir diferentes importâncias para cada zona.
- **Interpretação intuitiva:** reflete o desempenho médio ponderado das zonas.

- **Suave e contínua:** ideal para modelos baseados em otimização.

Desvantagens:

- **Pode diluir penalizações importantes** — ex.: uma zona muito ruim pode ser compensada por outra muito boa.
- **Requer justificativa para os pesos:** a escolha de w_1 e w_2 pode ser subjetiva ou arbitrária.

3.2.3

Função-Objetivo

Com a definição das funções de score individuais associadas a cada diretriz otimizadora, é possível construir a função-objetivo composta que será utilizada pelos algoritmos de otimização para avaliar e comparar diferentes soluções — ou seja, diferentes combinações possíveis de posicionamento dos Intervalos de Isolamento Crítico (IICs) ao longo do poço. Esse tipo de abordagem é amplamente adotado em problemas de otimização multicritério, sendo conhecida como método da soma ponderada (Marler e Arora, 2010; Brans et al., 1986). A função-objetivo é estruturada como um somatório ponderado:

$$F(x) = \sum_{i=1}^n w_i \cdot S_i(x)$$

Onde:

- $F(x)$ é a função-objetivo total associada a uma dada solução x ;
- n é o número total de diretrizes otimizadoras;
- w_i é o peso da diretriz i , associado à importância relativa de cada critério, frequentemente obtido por métodos como AHP ou técnicas de comparação pareada (Marler e Arora, 2010);
- $S_i(x)$ é o score atribuído pela função de score individual da diretriz i à zona avaliada x .

Esta estrutura, de composição linear ponderada, garante que diretrizes mais importantes (com pesos maiores) tenham maior influência no valor final da função-objetivo (Marler e Arora, 2010; Brans et al., 1986). Além disso, a padronização das funções de score individuais em uma escala comum de 0 a 1 é fundamental para assegurar uma comparação justa entre critérios de natureza diferente, evitando distorções por diferentes magnitudes ou unidades (Marler e Arora, 2010).

O objetivo dos algoritmos de otimização será maximizar o valor de $F(x)$, identificando a configuração de IICs que apresenta a melhor aderência às diretrizes otimizadoras, dentro dos limites impostos pelas diretrizes impeditivas.

Nos testes realizados, essa função foi aplicada de forma integrada aos algoritmos *Genetic Algorithm* (GA), *Particle Swarm Optimization* (PSO) e *Differential Evolution* (DE), conforme será detalhado nas próximas seções.

3.2.4

Algoritmos de Otimização

A definição assistida dos Intervalos de Isolamento Crítico (IICs) neste trabalho foi formulada como um problema de otimização mono-objetivo, no qual se busca maximizar uma única função-objetivo composta a partir de diretrizes técnicas.

Problemas dessa natureza envolvem desafios como alto número de variáveis envolvidas (propriedades dos perfis ao longo de trechos do poço), múltiplas restrições não lineares (condições impeditivas), espaço de busca com diversas soluções viáveis e soluções ótimas não triviais e altamente dependentes do contexto do reservatório, exigindo métodos robustos para obtenção de soluções próximas do ótimo global (de Carvalho et al., 2020; Halim et al., 2020; Elaziz et al., 2021).

Diante desse cenário, metaheurísticas baseadas em populações, como *Genetic Algorithm* (GA), *Particle Swarm Optimization* (PSO) e *Differential Evolution* (DE), têm se mostrado especialmente eficazes por sua capacidade de explorar amplamente o espaço de busca e lidar com descontinuidades e múltiplos ótimos locais (Elaziz et al., 2021; Halim et al., 2020; Akinola et al., 2022; de Carvalho et al., 2020).

Os algoritmos selecionados para este estudo, portanto, foram:

- ***Genetic Algorithm* (GA)**
- ***Particle Swarm Optimization* (PSO)**
- ***Differential Evolution* (DE)**

A escolha desses três algoritmos se justifica por sua comprovada robustez e ampla aceitação na literatura para problemas de otimização contínua e combinatória, especialmente quando se busca flexibilidade, robustez à inicialização aleatória e boa performance mesmo em funções não deriváveis (Elaziz et al., 2021; Akinola et al., 2022; Halim et al., 2020).

Breve descrição dos algoritmos escolhidos

- ***Genetic Algorithm (GA)*** Inspirado na seleção natural, utiliza operadores como seleção, cruzamento e mutação. Destaca-se por sua capacidade de escapar de ótimos locais e desempenho satisfatório em problemas de alta dimensionalidade (de Carvalho et al., 2020; Akinola et al., 2022).
- ***Particle Swarm Optimization (PSO)*** Baseado no comportamento de enxames, cada partícula ajusta sua posição conforme o melhor desempenho individual e coletivo, sendo eficiente para problemas contínuos e com rápida convergência (Elaziz et al., 2021; Chou e Thejda, 2016).
- ***Differential Evolution (DE)*** Atua pela combinação e diferença de vetores de solução, apresentando simplicidade de implementação e boa performance em funções não lineares e contínuas (Akinola et al., 2022; Halim et al., 2020).

Adequação ao problema mono-objetivo

Como o objetivo da pesquisa é maximizar uma única função, não há necessidade de empregar algoritmos multiobjetivo (como NSGA-II, NSGA-III, SPEA2 ou MOEA/D), os quais são recomendados para situações com objetivos conflitantes (Sharma e Kumar, 2023; Verma et al., 2021; Halim et al., 2020). O uso de algoritmos mono-objetivo, como GA, PSO e DE, é amplamente reconhecido na literatura como eficaz para problemas de alta dimensionalidade e com múltiplas restrições (Halim et al., 2020; de Carvalho et al., 2020).

Robustez e facilidade de parametrização

Os três algoritmos escolhidos:

- Possuem implementações consolidadas em bibliotecas como PyMoo, SciPy, DEAP, facilitando a aplicação prática (Elaziz et al., 2021).
- São robustos à inicialização aleatória e não exigem aproximação inicial sofisticada (de Carvalho et al., 2020; Halim et al., 2020).
- São flexíveis quanto ao tipo de função a ser otimizada, permitindo facilmente o uso de funções não deriváveis, descontinuidades e penalizações (como as que ocorrem nas diretrizes impeditivas).

Comparação com outros algoritmos não selecionados

Outros algoritmos foram considerados, mas não adotados neste estudo por razões técnicas e práticas:

- Algoritmos de busca local (como Hill Climbing, Simulated Annealing): Apesar de úteis para encontrar ótimos locais rapidamente, tendem a apresentar limitação em problemas com muitos mínimos locais, sendo menos adequados para problemas altamente não lineares e multidimensionais (de Carvalho et al., 2020; Guilmeau et al., 2021).
- Algoritmos multiobjetivo (NSGA-II, NSGA-III): Recomendados quando há múltiplos objetivos conflitantes (Sharma e Kumar, 2023; Verma et al., 2021; Halim et al., 2020), não se aplicam ao contexto deste estudo.
- Algoritmos baseados em gradiente (Gradiente Descendente, BFGS, L-BFGS): Requerem funções suaves e deriváveis, o que não é garantido no presente problema, além de serem menos robustos para funções com penalizações abruptas (Elaziz et al., 2021).

Justificativa final

Dada a natureza mono-objetivo, não linear, multidimensional e restrita do problema proposto, GA, PSO e DE representam o melhor compromisso entre eficácia, facilidade de implementação e robustez, estando entre as metaheurísticas mais consolidadas e estudadas para problemas similares na literatura internacional (Elaziz et al., 2021; Halim et al., 2020; Akinola et al., 2022; de Carvalho et al., 2020).

Essa seleção permitirá uma análise comparativa entre três das metaheurísticas mais consolidadas da literatura, resultando em uma avaliação robusta de suas capacidades na definição otimizada dos IICs.

3.2.4.1

Genetic Algorithm (GA)

O *Genetic Algorithm* (GA), ou Algoritmo Genético, simula um processo evolutivo artificial em que cada indivíduo da população representa uma solução candidata, codificada como um vetor de profundidades que define os inícios e termos dos Intervalos de Isolamento Crítico (IICs). O algoritmo utiliza os seguintes operadores:

- **Seleção:** Os indivíduos com melhor desempenho na função-objetivo são escolhidos com maior probabilidade para reproduzir.

- **Crossover (cruzamento):** Dois indivíduos selecionados são combinados para gerar novos indivíduos, herdando características de ambos.
- **Mutação:** Pequenas alterações aleatórias são aplicadas nos descendentes para manter a diversidade da população.
- **Substituição:** Os melhores indivíduos são mantidos ou substituem os menos aptos em cada geração.

Esse ciclo de evolução ocorre ao longo de várias gerações, refinando continuamente as soluções. O GA é especialmente útil para problemas com múltiplas variáveis e critérios, apresentando flexibilidade, boa capacidade de exploração global e é amplamente recomendado na literatura para problemas de otimização em engenharia, tanto de natureza contínua quanto combinatória (de Carvalho et al., 2020; Halim et al., 2020; Akinola et al., 2022).

Formalismo Matemático

Seleção (torneio):

$$\text{pai} = \arg \max_{i \in T} f(X_i)$$

Onde:

- T representa um subconjunto aleatório da população (o "torneio"), onde são escolhidos k indivíduos para competir.
- $f(X_i)$ indica o valor da função-objetivo para o indivíduo X_i .

A expressão seleciona o indivíduo com o maior valor de f , ou seja, aquele com melhor desempenho dentro do torneio, que será utilizado como pai para reprodução.

Crossover (aritmético):

$$X' = \alpha \cdot X_a + (1 - \alpha) \cdot X_b, \quad \alpha \in [0, 1]$$

Onde:

- X_a e X_b são os vetores dos pais selecionados, representando propostas de posicionamento dos IICs. A variável α é um número aleatório entre 0 e 1, usado para ponderar a contribuição de cada pai na formação do novo indivíduo X' . Esse novo vetor herda características de ambos os pais, permitindo a combinação de boas soluções.

Mutação:

$$x'_i = x_i + \delta$$

Onde:

- x_i representa um componente (ou gene) do vetor de profundidades de um indivíduo. A mutação consiste em adicionar uma pequena perturbação aleatória δ , geralmente proveniente de uma distribuição uniforme ou normal. Isso introduz diversidade genética na população, evitando que o algoritmo fique preso em soluções locais.

3.2.4.2

Differential Evolution (DE)

O *Differential Evolution* (DE) é um algoritmo populacional que cria novas soluções com base na diferença entre outras soluções da população. Cada solução é representada como um vetor contínuo com os valores de profundidade do início e término de cada IIC. O algoritmo funciona por meio de três passos principais:

- **Mutação diferencial:** Novas soluções são geradas combinando três vetores aleatórios da população.
- **Crossover:** O vetor mutante é cruzado com a solução original para gerar uma proposta final.
- **Seleção:** A melhor solução entre a proposta e a original é mantida.

O DE se destaca por sua simplicidade, boa convergência e baixa necessidade de ajuste de parâmetros, sendo frequentemente citado como uma das metaheurísticas mais eficazes para problemas contínuos, especialmente com funções objetivo não lineares e multidimensionais (de Carvalho et al., 2020; Halim et al., 2020; Akinola et al., 2022; Elaziz et al., 2021).

Formalismo Matemático

Mutação diferencial:

$$V_i = X_{r1} + F \cdot (X_{r2} - X_{r3})$$

Onde:

- vetor mutante V_i é gerado a partir de três indivíduos distintos X_{r1} , X_{r2} e X_{r3} , todos escolhidos aleatoriamente da população atual. O termo $(X_{r2} -$

X_{r3}) representa uma diferença vetorial, que define uma direção no espaço de busca. O fator de escala F controla a intensidade da perturbação aplicada à base X_{r1} . O resultado é um novo vetor potencialmente promissor, usado como ponto de partida para o próximo operador.

Crossover (binomial):

$$u_{ij} = \begin{cases} v_{ij}, & \text{se } \text{rand}_j \leq \text{CR} \text{ ou } j = j_{\text{rand}}, \\ x_{ij}, & \text{caso contrário.} \end{cases}$$

Onde:

- o vetor de teste $\mathbf{U}_i$ é gerado a partir da combinação do vetor mutante $\mathbf{V}_i$ com o vetor original $\mathbf{X}_i$. A variável u_{ij} representa o valor da j -ésima posição do vetor de teste. A condição $\text{rand}_j \leq \text{CR}$ (onde rand_j é um número aleatório entre 0 e 1) define se o gene virá do vetor mutante ou do vetor original. O parâmetro $\text{CR} \in [0, 1]$ é a taxa de recombinação, que controla a frequência de troca de genes. A condição $j = j_{\text{rand}}$ garante que pelo menos uma posição seja herdada do mutante.

Seleção:

$$X_i^{(t+1)} = \begin{cases} U_i, & \text{se } f(U_i) > f(X_i), \\ X_i, & \text{caso contrário.} \end{cases}$$

- A seleção é feita com base na avaliação da função-objetivo f . Se a solução de teste U_i apresentar melhor desempenho que a original X_i , ela é incorporada à próxima geração. Caso contrário, X_i é mantida. Isso garante que a população evolua somente com melhorias (ou, no mínimo, mantenha a qualidade anterior).

3.2.4.3

Particle Swarm Optimization (PSO)

O *Particle Swarm Optimization* (PSO) é inspirado em comportamentos coletivos da natureza, como o movimento coordenado de bandos de pássaros ou cardumes. No PSO, cada partícula representa uma solução candidata expressa por um vetor com os valores de profundidade dos inícios e términos dos IICs.

O algoritmo PSO é amplamente citado pela sua eficiência em problemas contínuos, simplicidade de parametrização e rápida convergência, sendo

especialmente recomendado para otimizações de alta dimensão (de Carvalho et al., 2020; Halim et al., 2020; Akinola et al., 2022; Elaziz et al., 2021; Chou e Thejda, 2016).

O algoritmo funciona com base em dois tipos de memória:

- A memória individual (melhor posição encontrada pela partícula);
- A memória coletiva (melhor posição global da população).

As partículas ajustam suas velocidades e posições com base nessas memórias, buscando melhores regiões no espaço de soluções.

Formalismo Matemático

Atualização da velocidade:

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_i - x_i(t)) + c_2 \cdot r_2 \cdot (g - x_i(t))$$

Onde:

- $v_i(t)$ é a velocidade atual da partícula i no instante t ;
- $v_i(t+1)$ será sua nova velocidade;
- $x_i(t)$ é a posição atual da partícula i , ou seja, o vetor com os valores de profundidade dos inícios e términos dos IICs;
- p_i é a melhor posição individual que a partícula i já encontrou;
- g é a melhor posição global entre todas as partículas da população;
- w é o fator de inércia, que controla o quanto da velocidade anterior será mantido;
- c_1 e c_2 são coeficientes de aceleração, que controlam a influência das memórias individual e coletiva, respectivamente;
- r_1 e r_2 são números aleatórios uniformemente distribuídos entre 0 e 1, introduzindo variabilidade estocástica.

Essa equação representa o equilíbrio entre exploração (busca de novas regiões) e exploração local (refinamento de boas soluções), pois combina a tendência da partícula de manter sua direção anterior com a atração pelas melhores posições conhecidas.

Atualização da posição:

$$x_i(t+1) = x_i(t) + v_i(t+1)$$

A posição da partícula é atualizada com base em sua nova velocidade. Essa nova posição corresponde a uma nova solução candidata (um novo conjunto de profundidades para os IICs), que será avaliada pela função-objetivo na próxima iteração.

3.2.5

Implementação dos Algoritmos de Otimização

Para possibilitar a aplicação prática dos algoritmos de otimização estudados — *Genetic Algorithm* (GA), *Differential Evolution* (DE) e *Particle Swarm Optimization* (PSO) —, foi necessário implementar computacionalmente toda a lógica de avaliação e busca de soluções. As implementações foram realizadas em linguagem Python, utilizando a biblioteca *pymoo*, que oferece uma infraestrutura robusta e flexível para problemas de otimização evolutiva.

A escolha do ambiente Python se justifica por sua ampla adoção científica, facilidade de integração com bibliotecas de análise numérica e visualização, além do suporte ativo da comunidade. A biblioteca *pymoo*, em especial, foi selecionada por fornecer implementações padronizadas e customizáveis de diversos algoritmos evolutivos, permitindo o controle detalhado da avaliação de soluções e da aplicação de restrições.

Cada solução candidata foi modelada como um vetor real contendo os valores de profundidade dos inícios e términos dos Intervalos de Isolamento Crítico (IICs). A função-objetivo utilizada pelos algoritmos foi baseada na soma ponderada das funções de score individuais, associadas a cada diretriz otimizadora, conforme descrito na Seção 3.2.2.

As restrições impostas pelas diretrizes impeditivas foram incorporadas à modelagem do problema por meio do sistema de penalizações da *pymoo*. Soluções que violam essas condições são tratadas como inviáveis, sendo automaticamente descartadas durante o processo de busca.

O código completo da implementação foi desenvolvido para tratar casos complexos de poços com três zonas de produção/injeção, configurando um desafio realista e exigente do ponto de vista computacional. O código-fonte que implementa os experimentos desta dissertação encontra-se disponível publicamente no GitHub, em commit fixo para reprodutibilidade (*CIIIs-Optimizer* (Henriques Neto, 2025)).

3.2.6

Comparação dos Algoritmos de Otimização

A avaliação da performance dos algoritmos de otimização empregados — *Genetic Algorithm* (GA), *Differential Evolution* (DE) e *Particle Swarm*

Optimization (PSO) — exige a definição de métricas objetivas que permitam comparar sua eficácia na resolução do problema de definição assistida dos Intervalos de Isolamento Crítico (IICs). O objetivo desta etapa é identificar qual algoritmo apresenta melhor desempenho diante dos desafios impostos por perfis reais de poços de petróleo.

A comparação será realizada com base nos seguintes indicadores individuais, calculados ao fim da execução de cada algoritmo sobre um mesmo caso de teste:

- **Score da melhor solução encontrada:** valor da função-objetivo máxima obtida, representando a qualidade da solução ótima identificada.
- **Tempo de simulação:** tempo total de execução do algoritmo, mensurado em segundos, refletindo a eficiência computacional.
- **Número de soluções viáveis encontradas:** quantidade de soluções que atenderam às restrições impostas pelas diretrizes impeditivas, refletindo a robustez do algoritmo.

Essas métricas fornecem uma visão detalhada do desempenho do algoritmo em um único cenário. No entanto, para permitir uma análise mais abrangente e generalizável, será realizada também uma comparação global entre os algoritmos, considerando múltiplos cenários de teste.

A comparação global consistirá na execução dos algoritmos sobre diferentes perfis de poços, representando uma gama variada de condições geológicas. Com isso, serão calculadas métricas agregadas, como:

- **Média dos scores obtidos nos casos testados.**
- **Eficiência computacional média (tempo médio por simulação).**
- **Taxa de viabilidade (média de soluções viáveis encontradas por execução).**
- **Frequência de superação (quantas vezes cada algoritmo obteve o melhor score).**
- **Frequência de viabilidade (quantas vezes cada algoritmo apresentou pelo menos uma solução viável).**

Essas métricas permitirão a construção de tabelas comparativas, destacando os pontos fortes e fracos de cada algoritmo.

Esse processo comparativo é essencial para subsidiar decisões fundamentadas sobre a escolha do algoritmo mais adequado em contextos futuros, especialmente em ambientes operacionais com restrições de tempo ou recursos computacionais limitados.

3.2.7

Validação das Soluções

Para a etapa de validação das soluções provenientes dos algoritmos de otimização, foram selecionados 5 conjuntos de perfis a partir da base de dados composta por 30 poços. Esses 5 casos foram utilizados para confrontar as soluções geradas pelos algoritmos com as decisões tomadas por especialistas humanos, buscando aferir a aderência prática e operacional das recomendações computacionais.

O processo de validação seguiu um protocolo estruturado em três etapas:

- **Aplicação do julgamento técnico pelos especialistas:** os 5 conjuntos de perfis foram apresentados a especialistas da área, que, sem conhecimento prévio das soluções geradas pelos algoritmos, realizaram a definição dos Intervalos de Isolamento Crítico (IICs) com base nos mesmos critérios aplicados em reuniões operacionais reais.
- **Comparação com as soluções otimizadas:** em seguida, foram apresentadas aos especialistas as soluções com maior score obtidas pelos algoritmos para cada conjunto de perfis. Avaliou-se a distância entre as soluções humanas e computacionais, tanto em termos de posicionamento dos IICs quanto em critérios qualitativos.
- **Feedback e refinamento:** em casos em que os especialistas apontem divergências relevantes ou insatisfação com a solução sugerida pelo algoritmo, serão conduzidos ajustes e refinamentos na implementação, visando melhorar a coerência das respostas com as práticas reconhecidas no ambiente técnico.

Esse processo de validação contribuirá não apenas para verificar a eficácia dos algoritmos, mas também para ajustar parâmetros, funções e restrições, consolidando a robustez da abordagem proposta.

4

Resultados

Este capítulo apresenta, de forma prática e detalhada, os resultados obtidos a partir da aplicação da metodologia descrita no Capítulo 3. A estrutura segue a mesma lógica metodológica adotada anteriormente, permitindo uma leitura sequencial e coerente com as etapas do trabalho.

Inicialmente, são apresentados os resultados referentes à criação das melhores práticas para o posicionamento dos Intervalos de Isolamento Crítico (IICs), a partir da análise das entrevistas com especialistas da área. Em seguida, são demonstrados os experimentos realizados com os algoritmos de otimização, destacando o desempenho de cada técnica na definição assistida dos IICs. Por fim, é apresentada a versão funcional do software WellLog Viewer and Analyzer, desenvolvido para integrar os componentes da metodologia e apoiar a tomada de decisão técnica com base nos dados de perfilagem e nas diretrizes consolidadas.

4.1

Criação das Melhores Práticas para o Posicionamento dos IICs

Conforme descrito no Capítulo 3, o processo de definição das diretrizes técnicas para o posicionamento dos Intervalos de Isolamento Crítico (IICs) teve como ponto de partida a realização de uma entrevista qualitativa semiestruturada com especialistas da área. O objetivo dessa etapa foi identificar, a partir da experiência prática dos profissionais, os principais fatores que influenciam a decisão sobre onde posicionar os IICs ao longo do poço.

A entrevista buscou extrair percepções técnicas e operacionais aplicadas no contexto real de análise de perfis. Os resultados obtidos nesse processo foram analisados, consolidados e organizados em diretrizes estruturadas que serviram de base para os algoritmos de otimização.

Nas subseções a seguir, são apresentados e discutidos os principais achados dessa etapa, incluindo o roteiro da entrevista, os extratos qualitativos das respostas, a sistematização das diretrizes otimizadoras e impeditivas, bem como o ranqueamento das diretrizes com base na avaliação dos especialistas.

4.1.1

Extrato das Entrevistas

A pesquisa qualitativa semiestruturada foi conduzida com o objetivo de compreender os critérios técnicos utilizados na prática para a definição dos Intervalos de Isolamento Crítico (IICs) em poços de petróleo. Abaixo, apresenta-se uma síntese dos principais resultados obtidos nas entrevistas com os especialistas.

4.1.1.1

Características Gerais da Pesquisa

- Foram realizadas 7 entrevistas via Microsoft Teams, com transcrição integral.
- Os participantes foram selecionados por amostragem proposital, considerando sua atuação direta com definição de zonas de produção ou injeção.
- A duração média das entrevistas foi de 45 minutos.
- O número médio de páginas transcritas por entrevista foi de 30 páginas.
- O roteiro foi dividido em quatro blocos temáticos:
 1. Perfil do Respondente
 2. Fatores de Decisão para a Divisão em Zonas de Produção
 3. Perfilagem de Poços e Fatores Quantitativos
 4. Tecnologia e Inovação

4.1.1.2

Perfil dos Entrevistados

- A amostra incluiu 5 engenheiros e 2 geólogos:
 - 2 engenheiros especializados em avaliação de reservatórios;
 - 2 engenheiros especializados em simulação de reservatórios;
 - 1 engenheiro especializado em completação de poços;
 - 2 geólogos especializados em petrofísica.
- Todos os participantes possuem mais de 10 anos de experiência na área:
 - 5 possuem mais de 15 anos de experiência;
 - 2 possuem mais de 20 anos de experiência.

4.1.1.3

Fatores de Decisão para a Divisão em Zonas

- Os principais fatores considerados na decisão de segmentação do poço foram:
 - Perfilagem – como base para caracterização petrofísica.
 - Tipo de poço – distinção entre poços produtores e injetores.
 - Modelo de fluxo – comportamento estimado do reservatório.
- Em relação ao número de zonas de produção:
 - Poços produtores geralmente são divididos em 3 zonas.
 - Poços injetores normalmente são segmentados em 2 zonas.
 - A quantidade de zonas costuma vir definida no projeto, com pouca margem para alteração durante a operação.

4.1.1.4

Perfilagem e Fatores Quantitativos

- Perfis mais importantes citados:
 - Resistividade – identificação do tipo de fluido.
 - Ressonância magnética – para análise de saturação, porosidade, permeabilidade e capacidade de fluxo.
 - Imagem acústica – identificação de fraturas e carstes.
 - Cáliper – identificação de arrombamentos.
- Perfis considerados menos relevantes:
 - Nenhum perfil foi classificado como irrelevante, porém perfis que apresentam informações redundantes, como porosidade de nêutrons, sônico, densidade e litológicos, foram considerados menos úteis para decisões críticas.

4.1.1.5

Tecnologia e Inovação

- Todos os entrevistados afirmaram, de forma unânime, que não conhecem nem utilizam ferramentas automatizadas ou algoritmos que auxiliem na definição dos IICs.
- Os participantes demonstraram grande receptividade à ideia de um código que automatize parte do processo, destacando benefícios como:
 - Redução no tempo de tomada de decisão;
 - Aumento da precisão na escolha dos intervalos, especialmente em casos mais desafiadores, com alta heterogeneidade ou baixo contraste petrofísico.

4.1.2

Definição das Diretrizes

A entrevista com os especialistas resultou na identificação de um conjunto claro e estruturado de diretrizes técnicas quantitativas que orientam o posicionamento dos Intervalos de Isolamento Crítico (IICs). Ao todo, foram definidas 14 diretrizes, sendo 7 diretrizes impeditivas — que representam condições obrigatórias e não podem ser violadas — e 7 diretrizes otimizadoras, utilizadas no cálculo do score das soluções geradas pelos algoritmos.

Cada diretriz foi formalmente associada a um conjunto de atributos fundamentais, que permitem sua interpretação e aplicação de forma automatizada. Esses atributos incluem:

- A qual parte do poço a diretriz se aplica (IIC ou zona produtora/injetora);
- O perfil de poço correspondente (ex: porosidade, saturação, resistividade etc.);
- O valor de referência técnico-operacional utilizado como limiar;
- A classe da diretriz (impeditiva ou otimizadora);
- Uma observação descritiva, que justifica ou contextualiza a importância da diretriz com base no julgamento dos especialistas.

A Tabela 4.1 e a Tabela 4.2 apresentam, respectivamente, extratos das diretrizes impeditivas e das diretrizes otimizadoras.

Intervalo do Poço	Perfil	Valor	Observação	Classe da Restrição
Isolamento (IIC)	Cáliper	> 9.5"	Impróprio ao assentamento de elementos vedantes	Impeditiva
Isolamento (IIC)	Porosidade	> 15%	Impróprio ao assentamento de elementos vedantes	Impeditiva
Isolamento (IIC)	Profundidade (Espessura)	< 25m > 30m	Espessuras mínima/máxima para cada IIC para instalação dos elementos vedantes	Impeditiva
Zona Produtora/Injetora	Porosidade	< 6%	Considerar não reservatório (descarte)	Impeditiva
Zona Produtora/Injetora	Permeabilidade	< 0,02 mD	Considerar não reservatório (descarte)	Impeditiva
Zona Produtora/Injetora	Profundidade/Resistividade	50m acima do COA	Última zona do poço produtor. Determina pelo perfil de Resistividade o COA.	Impeditiva
Zona Produtora/Injetora	Profundidade (Espessura)	< 50m	Instalação de acessórios (PDG, MIQ etc.)	Impeditiva

Tabela 4.1: Extrato das diretrizes impeditivas

Índice	Intervalo do Poço	Perfil	Valor	Observação	Classe da Restrição
A	Isolamento (IIC)	Cáliper	< 9"	Desejado para evitar problemas de isolamento	Otimizadora
B	Zona Produtora/ Injetora	Capacidade de Fluxo (kh)	> 10000 mD.m	Capacidade de fluxo muito baixa	Otimizadora
C	Zona Produtora/ Injetora	Capacidade de Fluxo (kh)	Equilíbrio entre zonas	Em caso de não equilíbrio, priorizar maior kh na zona intermediária (3 zonas)	Otimizadora
D	Zona Produtora/ Injetora	Profundidade (Espessura)	Equilíbrio entre zonas	Espessuras equilibradas facilitam o gerenciamento do poço	Otimizadora
E	Zona Produtora/ Injetora	Profundidade (Espessura)	< 110m	Espessura muito grande prejudica o gerenciamento do poço	Otimizadora
F	Zona Produtora/ Injetora	Profundidade (Espessura)	> 60m	Espessura muito pequena prejudica o gerenciamento do poço	Otimizadora
G	Zona Produtora/ Injetora	Capacidade de Fluxo (kh)	> 100000 mD.m	Capacidade de fluxo para uma zona ser considerada de alta capacidade	Otimizadora

Tabela 4.2: Extrato das diretrizes otimizadoras

4.1.3

Ranqueamento das Diretrizes Otimizadoras

Após a consolidação das diretrizes técnicas a partir da análise das entrevistas, foi realizada uma nova rodada de interação com os especialistas, com o objetivo de ranquear as diretrizes otimizadoras de acordo com sua importância relativa no processo de definição dos Intervalos de Isolamento Crítico (IICs).

Esse ranqueamento constitui uma etapa essencial da aplicação do método *Analytic Hierarchy Process* (AHP), conforme descrito na metodologia. No AHP baseado em ranking, as posições atribuídas pelos especialistas são transformadas em pesos relativos, que serão utilizados como coeficientes de ponderação na função-objetivo aplicada pelos algoritmos de otimização.

A posição 1 no ranking corresponde à diretriz considerada prioritária, enquanto a posição 7 indica a de menor relevância relativa.

A Tabela 4.3 apresenta o resultado do ranqueamento das diretrizes otimizadoras, consolidado a partir das contribuições dos especialistas. Esses valores servirão como input direto para os cálculos descritos na Seção 4.1.4, onde será realizada a transformação das ordens de importância em uma matriz de comparação par a par e, posteriormente, em um vetor de pesos.

Intervalo do Poço	Perfil	Valor	E1	E2	E3	E4	E5	E6
Isolamento (IIC)	Cáliper	< 9"	1	1	1	1	3	1
Zona Produtora/Injetora	Capacidade de Fluxo	> 10000 mD.m	3	2	4	2	2	3
Zona Produtora/Injetora	Capacidade de Fluxo	Equilíbrio entre zonas	4	3	2	4	4	2
Zona Produtora/Injetora	Profundidade	Equilíbrio entre zonas	7	4	3	5	6	4
Zona Produtora/Injetora	Profundidade	< 110m	6	6	7	6	7	6
Zona Produtora/Injetora	Profundidade	> 60m	5	5	5	3	5	5
Zona Produtora/Injetora	Capacidade de Fluxo	> 100000 mD.m	2	7	6	7	1	7

Tabela 4.3: Ranqueamento das diretrizes otimizadoras

4.1.4

Definição dos Pesos

Com base na matriz de ranqueamento das diretrizes otimizadoras, elaborada a partir das avaliações fornecidas pelos especialistas (conforme apresentado na seção anterior), procede-se agora à aplicação do método *Analytic Hierarchy Process* (AHP) para o cálculo dos pesos relativos atribuídos a cada diretriz.

O processo segue uma sequência estruturada de etapas, envolvendo a normalização da matriz de comparação e o cálculo do vetor de prioridades, garantindo que a soma final dos pesos seja igual a 1, conforme os princípios do método.

A Figura 3.2 ilustra a estrutura completa e ordenada do procedimento adotado, desde o ranqueamento inicial até a obtenção dos pesos finais a serem utilizados na função-objetivo dos algoritmos de otimização.

Etapa 1: Criação das Matrizes Par a Par Individuais

$$M_{ij} = \frac{\text{ranking}(j)}{\text{ranking}(i)}$$

	A	B	C	D	E	F	G
A	1.000	3.000	4.000	7.000	6.000	5.000	2.000
B	0.333	1.000	1.333	2.333	2.000	1.667	0.667
C	0.250	0.750	1.000	1.750	1.500	1.250	0.500
D	0.143	0.429	0.571	1.000	0.857	0.714	0.286
E	0.167	0.500	0.667	1.167	1.000	0.833	0.333
F	0.200	0.600	0.800	1.400	1.200	1.000	0.400
G	0.500	1.500	2.000	3.500	3.000	2.500	1.000

Tabela 4.4: Matriz Par a Par do Especialista 1 (ranking 1;3;4;7;6;5;2)

	A	B	C	D	E	F	G
A	1.000	2.000	3.000	4.000	6.000	5.000	7.000
B	0.500	1.000	1.500	2.000	3.000	2.500	3.500
C	0.333	0.667	1.000	1.333	2.000	1.667	2.333
D	0.250	0.500	0.750	1.000	1.500	1.250	1.750
E	0.167	0.333	0.500	0.667	1.000	0.833	1.167
F	0.200	0.400	0.600	0.800	1.200	1.000	1.400
G	0.143	0.286	0.429	0.571	0.857	0.714	1.000

Tabela 4.5: Matriz Par a Par do Especialista 2 (ranking 1;2;3;4;6;5;7)

	A	B	C	D	E	F	G
A	1.000	4.000	2.000	3.000	7.000	5.000	6.000
B	0.250	1.000	0.500	0.750	1.750	1.250	1.500
C	0.500	2.000	1.000	1.500	3.500	2.500	3.000
D	0.333	1.333	0.667	1.000	2.333	1.667	2.000
E	0.143	0.571	0.286	0.429	1.000	0.714	0.857
F	0.200	0.800	0.400	0.600	1.400	1.000	1.200
G	0.167	0.667	0.333	0.500	1.167	0.833	1.000

Tabela 4.6: Matriz Par a Par do Especialista 3 (ranking 1;4;2;3;7;5;6)

	A	B	C	D	E	F	G
A	1.000	2.000	4.000	5.000	6.000	3.000	7.000
B	0.500	1.000	2.000	2.500	3.000	1.500	3.500
C	0.250	0.500	1.000	1.250	1.500	0.750	1.750
D	0.200	0.400	0.800	1.000	1.200	0.600	1.400
E	0.167	0.333	0.667	0.833	1.000	0.500	1.167
F	0.333	0.667	1.333	1.667	2.000	1.000	2.333
G	0.143	0.286	0.571	0.714	0.857	0.429	1.000

Tabela 4.7: Matriz Par a Par do Especialista 4 (ranking 1;2;4;5;6;3;7)

	A	B	C	D	E	F	G
A	1.000	0.667	1.333	2.000	2.333	1.667	0.333
B	1.500	1.000	2.000	3.000	3.500	2.500	0.500
C	0.750	0.500	1.000	1.500	1.750	1.250	0.250
D	0.500	0.333	0.667	1.000	1.167	0.833	0.167
E	0.429	0.286	0.571	0.857	1.000	0.714	0.143
F	0.600	0.400	0.800	1.200	1.400	1.000	0.200
G	3.000	2.000	4.000	6.000	7.000	5.000	1.000

Tabela 4.8: Matriz Par a Par do Especialista 5 (ranking 3;2;4;6;7;5;1)

	A	B	C	D	E	F	G
A	1.000	3.000	2.000	4.000	6.000	5.000	7.000
B	0.333	1.000	0.667	1.333	2.000	1.667	2.333
C	0.500	1.500	1.000	2.000	3.000	2.500	3.500
D	0.250	0.750	0.500	1.000	1.500	1.250	1.750
E	0.167	0.500	0.333	0.667	1.000	0.833	1.167
F	0.200	0.600	0.400	0.800	1.200	1.000	1.400
G	0.143	0.429	0.286	0.571	0.857	0.714	1.000

Tabela 4.9: Matriz Par a Par do Especialista 6 (ranking 1;3;2;4;6;5;7)

Etapa 2: Criação da Matriz de Comparação Agregada

$$M_{ij}^{\text{agregado}} = \left(\prod_{p=1}^k M_{ij}^{(p)} \right)^{1/k}$$

	A	B	C	D	E	F	G
A	1.000	2.061	2.381	3.470	5.254	4.242	3.113
B	0.485	1.000	1.306	1.958	3.050	2.357	1.464
C	0.420	0.766	1.000	1.552	2.425	1.933	1.200
D	0.288	0.511	0.644	1.000	1.549	1.244	0.797
E	0.190	0.328	0.412	0.646	1.000	0.788	0.524
F	0.236	0.424	0.517	0.804	1.269	1.000	0.675
G	0.321	0.683	0.833	1.254	1.908	1.482	1.000

Tabela 4.10: Matriz de Comparação Agregada

Etapa 3: Normalização por Coluna

Para cada coluna, cada elemento é dividido pelo somatório da própria coluna, resultando na Tabela 4.11.

	A	B	C	D	E	F	G
A	0.340	0.357	0.336	0.325	0.319	0.325	0.355
B	0.165	0.173	0.184	0.183	0.185	0.181	0.167
C	0.143	0.133	0.141	0.145	0.147	0.148	0.137
D	0.098	0.089	0.091	0.094	0.094	0.095	0.091
E	0.065	0.057	0.058	0.060	0.061	0.060	0.060
F	0.080	0.073	0.073	0.075	0.077	0.077	0.077
G	0.109	0.118	0.117	0.117	0.116	0.114	0.114

Tabela 4.11: Matriz de Comparação Agregada normalizada por coluna

Etapa 4: Média das Linhas (Pesos Relativos)

A partir da matriz de comparação agregada normalizada, a média calculada de cada linha (isto é, média dos valores normalizados de cada critério em relação aos demais) é o peso aproximado de cada critério, os quais podem ser vistos na Tabela 4.12.

Com os pesos relativos das diretrizes otimizadoras devidamente determinados, torna-se possível a formulação final da função-objetivo utilizada pelas metaheurísticas implementadas neste trabalho.

Critério	Peso aproximado
A: Cáliper $< 9''$	0.3367
B: $kh > 10.000 \text{ mD.m}$	0.1769
C: Igualdade kh	0.1420
G: $kh > 100.000 \text{ mD.m}$	0.1151
D: Igualdade espessura	0.0930
F: Espessura $\geq 60 \text{ m}$	0.0761
E: Espessura $\leq 110 \text{ m}$	0.0601

Tabela 4.12: Matriz de pesos relativos entre as diretrizes otimizadoras

4.2

Avaliação de Algoritmos de Otimização para a Definição Assistida dos IICs

Concluídas as etapas de definição das diretrizes impeditivas e otimizadoras, ranqueamento das diretrizes otimizadoras e determinação dos pesos relativos a serem aplicados na função-objetivo, dá-se início à fase de avaliação dos algoritmos de otimização selecionados para este estudo.

Esta Seção apresenta, de forma estruturada, todos os componentes envolvidos nesse processo. Inicialmente, são descritas as funções de score individuais, seguidas pela formulação da função-objetivo baseada na ponderação das diretrizes. Em seguida, são detalhadas a implementação computacional dos algoritmos, os resultados das soluções encontradas, o comparativo de desempenho entre os métodos utilizados e, por fim, o processo de validação das soluções junto aos especialistas, assegurando a consistência prática dos resultados obtidos.

4.2.1

Funções de Score Individuais

As diretrizes otimizadoras utilizadas neste trabalho podem ser agrupadas em dois tipos principais:

- **Tipo 1 – Diretrizes com valor-alvo absoluto:** requerem que cada zona de produção/injeção atenda a um critério quantitativo mínimo ou máximo bem definido. Por exemplo: a zona produtora deverá possuir capacidade de fluxo superior a 10.000 mD.m .
- **Tipo 2 – Diretrizes de equilíbrio entre zonas:** não impõem um valor absoluto, mas sim buscam uniformidade entre as zonas para um determinado parâmetro. Por exemplo: a capacidade de fluxo deverá estar balanceada entre as três zonas.

Funções para Diretrizes Tipo 1 – A, B, E, F, G

Para as diretrizes do Tipo 1, foram analisadas diversas funções de score para converter o valor observado em cada zona em um score contínuo entre 0 e 1. Após a comparação técnica entre as alternativas, optou-se pela função sigmoide com validação dos especialistas, com base nas seguintes justificativas:

- **Suavidade e continuidade:** a sigmoide fornece uma transição suave entre valores baixos e altos, evitando descontinuidades bruscas que dificultariam a convergência dos algoritmos.
- **Facilidade de ajuste:** seus parâmetros permitem controle direto sobre o ponto de inflexão (limiar técnico) e sobre a inclinação da curva, o que facilita a calibragem conforme o perfil do campo analisado.
- **Adaptabilidade a múltiplos contextos:** diferentemente de funções como a parabólica (que penaliza extremos) ou a hiperbólica inversa (que pode gerar instabilidade), a sigmoide se comporta bem mesmo quando os limiares técnicos variam entre campos ou aplicações.

As demais alternativas analisadas apresentaram limitações importantes:

- A linear por partes introduz descontinuidades e não permite transições graduais;
- A gaussiana e a parabólica penalizam tanto valores abaixo quanto acima do ótimo, o que não é adequado em diretrizes com limiar mínimo;
- A tangente hiperbólica possui parametrização mais complexa e sensível;
- A hiperbólica inversa tem penalização abrupta, podendo afetar negativamente a estabilidade do algoritmo.

Portanto, a função sigmoide foi escolhida como função de score padrão para todas as diretrizes otimizadoras do Tipo 1, sendo aplicada individualmente a cada zona (três por poço).

Determinação dos Parâmetros da Função Sigmoide

Cada diretriz otimizadora do Tipo 1 apresenta, em seu contexto técnico, uma necessidade específica de transição entre a zona considerada não ótima e a zona ótima. Essa transição é modelada por meio da função sigmoide, cuja forma depende diretamente de dois parâmetros principais: o ponto de inflexão e a taxa de crescimento.

Para este trabalho, os valores-alvo técnicos definidos nas diretrizes foram utilizados como pontos de inflexão da curva sigmoide, representando o limiar em que o score começa a aumentar de forma significativa. Já a taxa de crescimento da função (k), responsável por controlar a inclinação da curva e, portanto, a suavidade da transição entre a zona de baixo desempenho e a zona ótima, foi definida por meio de consulta e validação junto aos especialistas da área.

Os valores adotados para o parâmetro k em cada diretriz otimizadora estão apresentados a seguir:

- A: Cáliper $< 9''$, $k = -3$
- B: Capacidade de Fluxo > 10000 mD.m, $k = 0,001$
- E: Espessura < 110 m, $k = -0,3$
- F: Espessura > 60 m, $k = 0,3$
- G: Capacidade de Fluxo > 100000 mD.m, $k = 0,0001$

Vale destacar que valores absolutos menores de k resultam em uma transição mais suave entre os extremos da curva (zonas não ótima e ótima), enquanto valores maiores tornam a transição mais abrupta. A escolha cuidadosa desses parâmetros permite que cada diretriz reflita adequadamente sua importância operacional e sensibilidade técnica.

Na Figura 4.1, são apresentados os gráficos das funções sigmóides correspondentes às diretrizes otimizadoras do Tipo 1, permitindo a visualização das curvas de transição utilizadas no cálculo do score.




Figura 4.1: Gráficos das funções sigmoides das diretrizes otimizadoras

Combinação das Funções: Operador Produto

Uma vez que cada diretriz é avaliada separadamente para cada uma das três zonas, torna-se necessário agregar os resultados parciais em um único score representativo. Foram avaliadas três estratégias de combinação:

- **Média ponderada:** favorece soluções que tenham boa performance em uma ou duas zonas, mesmo que a terceira seja deficiente.
- **Mínimo:** adota a performance da pior zona como score final, o que penaliza fortemente desequilíbrios.
- **Produto:** amplifica as penalizações de zonas com baixo desempenho, mas ainda permite compensações parciais quando o conjunto das zonas está bem equilibrado.

Dentre essas opções, o produto das funções sigmoides foi o método escolhido, por apresentar um equilíbrio ideal entre seletividade e suavidade. Ele permite que soluções com desempenho consistente em todas as zonas obtenham pontuações elevadas, enquanto penaliza aquelas que apresentam desempenho insatisfatório em uma ou mais zonas — sem anular completamente a solução, como faria o uso do mínimo.

Funções para Diretrizes Tipo 2 – C, D

Já para as diretrizes do Tipo 2, que exigem equilíbrio entre zonas, foi adotado o desvio relativo normalizado da média como métrica. Essa abordagem avalia o quão distante cada zona está do valor médio, transformando esse desvio

em um score padronizado entre 0 e 1. Quanto menor a dispersão, maior será o score, promovendo o balanceamento entre as zonas.

A Figura 4.2 representa o score da função para a diretriz C - Equilíbrio de Capacidade de Fluxo contemplando as 3 zonas de produção/injeção:




Figura 4.2: Função de score da diretriz otimizadora C (Equilíbrio de Capacidade de Fluxo)

4.2.2 Função-Objetivo

A função-objetivo, conforme apresentada em 3.2.3, é definida como um somatório ponderado das funções de score individuais associadas a cada diretriz otimizadora. Essa estrutura permite que diferentes critérios técnicos contribuam proporcionalmente para a avaliação de cada solução candidata, de acordo com sua importância relativa:

$$F(x) = \sum_{i=1}^n w_i \cdot S_i(x)$$

O vetor de pesos w_i , utilizado na ponderação, foi obtido a partir do ranqueamento das diretrizes otimizadoras pelos especialistas e do posterior cálculo dos pesos relativos via método AHP, conforme detalhado na Seção 4.1.

Para facilitar a compreensão da composição da função-objetivo, a Tabela 4.13 apresenta o mapeamento entre o índice i , as respectivas diretrizes otimizadoras, seus pesos relativos, a função de score utilizada por zona e a função agregada resultante $S_i(x)$, que será aplicada a cada solução candidata durante o processo de otimização.

Índice	Diretriz	Peso Relativo (w_i)	Função de Score Por Zona	Função de Score Resultante ($S_i(x)$)
1	Cáliper < 9"	0.3367	$\frac{1}{1 + e^{3(x-9)}}$	$f(IIC_1) \cdot f(IIC_2)$
2	Capacidade de Fluxo > 10000 mD.m	0.1769	$\frac{1}{1 + e^{-0.001(x-10000)}}$	$f(ZP_1) \cdot f(ZP_2) \cdot f(ZP_3)$
3	Igualdade de Capacidade de Fluxo (kh)	0.1420	N/A	$1 - \frac{\sqrt{\frac{1}{3} \sum_{i=1}^3 (kh_i - \bar{kh})^2}}{\bar{kh} + \varepsilon}$
4	Igualdade de Espessura (esp)	0.0930	N/A	$1 - \frac{\sqrt{\frac{1}{3} \sum_{i=1}^3 (esp_i - \bar{esp})^2}}{\bar{esp} + \varepsilon}$
5	Espessura < 110 m	0.0601	$\frac{1}{1 + e^{0.3(x-110)}}$	$f(ZP_1) \cdot f(ZP_2) \cdot f(ZP_3)$
6	Espessura > 60 m	0.0761	$\frac{1}{1 + e^{-0.3(x-60)}}$	$f(ZP_1) \cdot f(ZP_2) \cdot f(ZP_3)$
7	Capacidade de Fluxo > 100000 mD.m	0.1151	$\frac{1}{1 + e^{-0.0001(x-100000)}}$	$f(ZP_1) \cdot f(ZP_2) \cdot f(ZP_3)$

Tabela 4.13: Correspondência entre índice, diretriz, peso relativo e função de score

4.2.3

Implementação dos Algoritmos de Otimização

A implementação computacional dos algoritmos de otimização foi realizada integralmente em linguagem Python, utilizando a biblioteca pymoo, especializada em métodos evolutivos e metaheurísticas. O objetivo foi aplicar os algoritmos GA, DE e PSO para resolver o problema de definição dos Intervalos de Isolamento Crítico (IICs) com base em perfis de poços e diretrizes técnicas previamente estabelecidas.

Leitura e preparação dos dados

Inicialmente, foi desenvolvido um módulo específico para leitura de arquivos .las, amplamente utilizados na indústria de petróleo para armazenar dados de perfilagem de poços. Esse módulo realiza a conversão automática para o formato .csv, identificando de forma robusta os nomes das curvas presentes na seção ~CURVE INFORMATION ou diretamente no cabeçalho de dados ~A. O resultado é um arquivo .csv estruturado, contendo colunas numéricas

interpretáveis pelo algoritmo.

A etapa seguinte consiste na leitura e limpeza inteligente dos dados contidos no arquivo .csv. O script identifica automaticamente as colunas, como profundidade, porosidade e cáliber, essenciais para os cálculos subsequentes. Em caso de ausência de alguma dessas colunas, o código aplica mecanismos de fallback, preservando a execução. As variáveis são normalizadas e transformadas de forma que os valores fiquem consistentes com a realidade dos poços do pré-sal brasileiro.

Modelagem do problema no Pymoo

Para a aplicação dos algoritmos evolutivos, foi definida uma classe customizada de problema, herdando de `ElementwiseProblem` da biblioteca pymoo. Essa classe define as variáveis de decisão como sendo os quatro pontos de divisão do poço: os limites superior e inferior de cada um dos dois IICs. Ou seja, a solução é representada por um vetor de quatro variáveis inteiras correspondentes às profundidades (em índice) que delimitam os cinco trechos do poço: zona 1, IIC 1, zona 2, IIC 2, zona 3.

A função-objetivo avalia quão boa é a divisão proposta, considerando o cumprimento das diretrizes impeditivas como restrições e o desempenho nas diretrizes otimizadoras como score. O valor da função é o somatório ponderado dos scores das diretrizes otimizadoras, conforme discutido em 3.2.3. As restrições são tratadas diretamente no modelo como desigualdades (restrições do tipo $G \leq 0$), penalizando soluções que violam requisitos como espessura mínima dos IICs, cáliber máximo e porosidade máxima permitida.

A função de avaliação do problema também armazena todas as soluções viáveis encontradas, possibilitando a geração de gráficos de convergência e comparação entre algoritmos.

Configuração dos algoritmos

Os três algoritmos foram configurados com população de 100 indivíduos e 100 gerações, sendo utilizadas amostragens por Latin Hypercube (LHS) e operadores evolutivos apropriados para cada caso:

- **GA (*Genetic Algorithm*)**: utiliza crossover do tipo SBX e mutação polinomial (PM). A seleção é baseada em torneio e as duplicatas são eliminadas a cada geração.
- **DE (*Differential Evolution*)**: implementado com a variante DE/rand/1/bin, com taxa de crossover de 0.85 e fator de mutação de 0.5.

- **PSO (*Particle Swarm Optimization*)**: utiliza pesos de inércia, coeficientes cognitivo e social e adaptação automática dos parâmetros ao longo das gerações.

Todos os algoritmos foram executados com semente fixa (`seed = 42`) para garantir reprodutibilidade e permitir comparações justas entre os métodos.

Visualização e análise

Durante a execução, os algoritmos geram relatórios detalhados contendo:

- Soluções viáveis encontradas, incluindo os valores dos parâmetros de corte (i, j, k, l), espessura dos trechos e capacidade de fluxo;
- Validação das diretrizes impeditivas para cada solução;
- Score da melhor solução;
- Gráficos comparativos entre os algoritmos, incluindo tempo de execução, número de avaliações, score máximo e número de soluções viáveis.

A melhor solução de cada algoritmo é visualmente destacada, com sombreamento das zonas e gráficos das curvas de porosidade, cáliber e permeabilidade ao longo do poço. Também são gerados gráficos de convergência por tempo e por número de avaliações, permitindo análise clara da eficiência de cada abordagem.

Código completo e reprodutibilidade

O código-fonte que implementa os experimentos desta dissertação encontra-se disponível publicamente no GitHub, em commit fixo para reprodutibilidade (*CIIs-Optimizer* (Henriques Neto, 2025)). Nele estão incluídas as funções de pré-processamento dos dados, definição do problema de otimização, execução dos algoritmos, análise dos resultados e geração das visualizações. Esse material permite a reexecução e adaptação dos experimentos para novos conjuntos de dados com mínima intervenção.

4.2.4

Soluções Encontradas da Definição Assistida dos IICs

Nesta seção, apresenta-se um conjunto demonstrativo de soluções obtidas a partir do código implementado, utilizando um conjunto de perfis selecionado como exemplo. Soluções correspondentes a outros conjuntos de perfis podem ser consultadas no Apêndice B.

Conforme descrito anteriormente, a implementação desenvolvida permite a geração automática de uma ampla variedade de gráficos e relatórios detalhados, que traduzem visualmente os resultados das otimizações e facilitam a análise técnica das soluções encontradas. O objetivo, aqui, é proporcionar ao leitor uma compreensão aprofundada e didática do significado de cada gráfico ou tabela produzido, facilitando a replicação do raciocínio analítico para outros casos disponibilizados no Apêndice B.

No total, são gerados 15 gráficos e tabelas, abrangendo diferentes aspectos do desempenho dos algoritmos e da qualidade das soluções propostas. Cada um desses materiais será apresentado a seguir, sempre dividido em duas partes: uma explicação sobre o que a imagem representa e uma análise dos resultados exibidos (“Análise do gráfico”). Esse formato busca garantir que o leitor compreenda plenamente a utilidade e o significado de cada resultado apresentado, servindo de guia para análises futuras.

1. Comparação de Desempenho dos Algoritmos




Figura 4.3: Comparação de Desempenho dos Algoritmos

A Figura 4.3 mostra quatro gráficos de barras agrupados para comparar os algoritmos nos principais critérios de desempenho:

- Tempo de Execução (segundos)
- Número Total de Avaliações da Função-Objetivo
- Número de Soluções Viáveis Encontradas
- Melhor Score Encontrado

As variáveis analisadas são fundamentais para avaliar não apenas a eficácia dos algoritmos, mas também sua robustez operacional e sua aderência às restrições do problema.

Análise do gráfico:

- Tempo de execução: O DE foi o mais rápido (3,26s), seguido de perto pelo PSO (3,42s), enquanto o GA foi o mais lento (4,76s), sendo quase 50% mais demorado que os demais.
- Número de avaliações: Todos realizaram 10.000 avaliações, garantindo que a comparação entre algoritmos seja justa e não enviesada pelo esforço computacional.
- Número de soluções viáveis: O DE encontrou a maior quantidade de soluções viáveis (3.791), superando o GA (3.203) e principalmente o PSO (1.004). Isso indica que o DE foi mais eficiente em navegar pelo espaço de busca, localizando mais alternativas válidas, o que pode ser vantajoso para análises de sensibilidade ou robustez.
- Melhor score: Todos os métodos atingiram exatamente o mesmo valor máximo de score (0,8448), confirmando que, ao menos para este caso, não houve superioridade de qualidade entre eles, e sim diferença na eficiência de busca e diversidade de soluções.

Do ponto de vista prático, DE e PSO se destacam pela eficiência, mas o DE ainda oferece uma maior quantidade de alternativas de qualidade para análises pós-otimização.

2. Comparação das Melhores Soluções por Algoritmo




Figura 4.4: Comparação das Melhores Soluções por Algoritmo

A Figura 4.4 sobrepõe as melhores soluções de cada algoritmo ao longo do perfil do poço analisado. As linhas verticais coloridas representam os posicionamentos dos intervalos de isolamento crítico (IICs) propostos por cada algoritmo. As variáveis mostradas incluem calíper, permeabilidade (dividida por 1000) e porosidade (multiplicada por 10), permitindo ao leitor visualizar como os algoritmos alocam os IICs em relação às regiões de interesse dos perfis do poço.

Análise do gráfico:

- Os três algoritmos propuseram exatamente as mesmas posições de divisão, indicando que a melhor solução encontrada é robusta para esse conjunto de dados.
- As zonas de produção/injeção coincidem com trechos de maior permeabilidade e porosidade, características desejáveis para intervalos produtores/injetores, o que mostra coerência entre o critério de score e os dados reais do perfil do poço.
- A sobreposição das zonas ótimas com regiões de calíper mais estável indica que as restrições de integridade do poço também foram respeitadas.

Esse resultado reforça a robustez do critério utilizado: independentemente do algoritmo, as soluções convergem para a mesma configuração, sugerindo que eventuais variações entre algoritmos podem ser mais relevantes

em casos em que a paisagem do espaço de busca é mais complexa ou multimodal.

3. Comparação das 4 Melhores Soluções Distintas (DE)




Figura 4.5: Comparação das 4 Melhores Soluções Distintas (DE)

A Figura 4.5 apresenta, simultaneamente, as quatro melhores soluções encontradas pelo DE. Cada conjunto de linhas verticais coloridas indica o início e término dos intervalos IIC para cada solução distinta. A base do gráfico inclui calíper, permeabilidade e porosidade, com área sombreada destacando as zonas produtivas.

Análise do gráfico:

- As quatro melhores soluções do DE apresentaram scores idênticos (0,84) e divisões quase coincidentes (diferença de poucos metros de profundidade entre as soluções).
- Essa proximidade sugere que o ótimo global é cercado de várias soluções equivalentes, reforçando a estabilidade do resultado e fornecendo alternativas operacionais quase tão boas quanto o ótimo.
- Isso também evidencia que pequenas variações nos limites das zonas não impactam significativamente o score, o que pode ser importante para a flexibilidade no planejamento operacional.

- A proximidade das divisões ótimas entre si e com os perfis de maior permeabilidade/porosidade mostra que as soluções são tecnicamente consistentes.

4. Comparação das 4 Melhores Soluções Distintas (GA)




Figura 4.6: Comparação das 4 Melhores Soluções Distintas (GA)

Equivalente à anterior, a Figura 4.6 mostra as quatro melhores soluções encontradas pelo GA. As variáveis de base (cáliper, permeabilidade, porosidade) permitem análise integrada das decisões de posicionamento dos IICs.

Análise do gráfico:

- O padrão observado é semelhante ao do DE: as quatro melhores soluções apresentam scores iguais (0,84) e divisões praticamente idênticas, com diferenças pequenas nas profundidades.
- Isso demonstra que o GA também explora bem o espaço de busca, não ficando restrito a apenas uma configuração ótima.
- Essas soluções alternativas servem de referência para mostrar que, do ponto de vista prático, pode-se escolher qualquer uma delas, pois o impacto no resultado será mínimo.

- A convergência do GA para as mesmas regiões ótimas dos demais algoritmos reforça que, neste problema, a superfície de busca é pouco propensa a ótimos locais relevantes.

5. Comparação das 4 Melhores Soluções Distintas (PSO)




Figura 4.7: Comparação das 4 Melhores Soluções Distintas (PSO)

Na Figura 4.7, tem-se as quatro melhores soluções encontradas pelo PSO. As áreas de interesse dos perfis são mantidas para avaliação qualitativa da qualidade das soluções.

Análise do gráfico:

- O PSO também encontrou múltiplas soluções com score ótimo (0,84) e divisões praticamente idênticas às encontradas pelos outros algoritmos, indicando que não houve aprisionamento em ótimos locais e que o método é eficaz para esse tipo de problema.
- As divisões ótimas coincidem com regiões de interesse do perfil (alta permeabilidade e porosidade, cáliber estável), indicando alinhamento com as premissas de seleção das zonas de produção/injeção.
- Esse resultado sugere que o PSO é tão confiável quanto os demais métodos para encontrar soluções ótimas.

6. Divisão Ótima do Poço (DE - Differential Evolution)




Figura 4.8: Divisão Ótima do Poço (DE - Differential Evolution)

A Figura 4.8 mostra a divisão ótima do poço identificada pelo algoritmo DE. O eixo X corresponde à profundidade e o eixo Y mostra as escalas dos perfis logados (permeabilidade, calíper, porosidade). As áreas coloridas representam os trechos delimitados pelos IICs, com os respectivos comprimentos e capacidade de fluxo (mD.m) indicados na legenda. Sobrepostos, vemos as curvas dos principais perfis, sendo a linha azul pontilhada o calíper, a preta a permeabilidade (dividida por 1000), e a vermelha a porosidade multiplicada por 10.

Análise do gráfico:

- As zonas de produção/injeção coincidem com zonas de maior permeabilidade e porosidade, indicando que o algoritmo buscou maximizar a capacidade produtiva.
- As zonas de isolamento (IICs) ocorrem em regiões de menor qualidade e não compreendem áreas com spikes no calíper, regiões de arrombamento local (diretriz impeditiva).
- As fronteiras das zonas geralmente alinham-se a transições abruptas nos perfis, evidenciando sensibilidade do algoritmo a mudanças geológicas importantes.

- O equilíbrio entre extensão dos trechos e capacidade produtiva mostra o sucesso do algoritmo em otimizar múltiplos critérios simultaneamente (diretrizes otimizadoras).

7. Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura 4.9: Divisão Ótima do Poço (GA - Algoritmo Genético)

A Figura 4.9, análoga à anterior, mas utilizando o Algoritmo Genético (GA) para propor a divisão ótima do poço. As mesmas variáveis são apresentadas: profundidade (X), logs dos perfis, divisão do poço em trechos coloridos e respectivos indicadores de comprimento e capacidade de fluxo.

Análise do gráfico:

- As divisões propostas pelo GA são idênticas ao DE, indicando convergência entre métodos para as melhores regiões do perfil.
- Caso houvesse pequenas diferenças no posicionamento das divisões, poderiam estar associadas à variabilidade natural dos algoritmos estocásticos.
- O alinhamento das divisões com transições de propriedades (porosidade, permeabilidade e caliper) mostra que o GA capturou bem as zonas críticas do poço.
- O resultado reforça a robustez do GA para encontrar soluções com alta qualidade, mesmo em espaços de busca complexos, apresentando sucesso no problema de definição assistida de IICs.

8. Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura 4.10: Divisão Ótima do Poço (PSO - Particle Swarm Optimization)

A Figura 4.10 apresenta o resultado do PSO para o mesmo desafio. Mantém a estrutura dos anteriores, permitindo comparação direta entre as soluções dos algoritmos para o mesmo conjunto de perfis.

Análise do gráfico:

- O PSO identificou divisões idênticas aos outros algoritmos em sua melhor solução.
- O alinhamento das divisões com as transições dos perfis permanece evidente, validando a aderência do método aos objetivos do problema.

9. Convergência dos Algoritmos ao Longo do Tempo




Figura 4.11: Convergência dos Algoritmos ao Longo do Tempo

A Figura 4.11 exibe a evolução do melhor score encontrado por cada algoritmo (GA - Algoritmo Genético, DE - Differential Evolution, PSO - Particle Swarm Optimization) em função do tempo de execução, medido em segundos. O eixo X apresenta o tempo acumulado de processamento, enquanto o eixo Y indica o valor do melhor score obtido (quanto maior, melhor). Cada linha representa a trajetória de um algoritmo diferente. Essa visualização é fundamental para comparar a eficiência de convergência de cada método, permitindo ao leitor avaliar não só a qualidade das soluções, mas também o custo computacional de cada abordagem, que é crítico em ambientes de aplicação real.

Análise do gráfico: Observa-se que os três algoritmos chegam ao mesmo valor de score ótimo (0,8448), demonstrando que todos são capazes de encontrar soluções de alta qualidade para esse conjunto de dados. No entanto, o comportamento durante a busca é marcadamente diferente:

- DE e PSO apresentam uma rápida ascensão do score e convergem ao valor ótimo em menos de 2 segundos, estabilizando precocemente.
- GA apresenta uma trajetória mais instável, com flutuações negativas que sugerem a exploração de regiões menos promissoras, antes de finalmente estabilizar no ótimo após cerca de 4,5 segundos.

Em termos práticos, embora todos entreguem o mesmo resultado, DE e PSO mostraram vantagem significativa na velocidade para alcançar a melhor solução.

10. Convergência dos Algoritmos por Número de Avaliações




Figura 4.12: Convergência dos Algoritmos por Número de Avaliações

A Figura 4.12 avalia a evolução do melhor score de cada algoritmo em função do número de avaliações da função-objetivo, permitindo comparar a eficiência de exploração do espaço de busca independente do tempo computacional.

Análise do gráfico:

- O DE e o PSO atingem o score ótimo (0,8448) em cerca de 5.000 avaliações, enquanto o GA precisa de aproximadamente 9.000 avaliações para convergir ao mesmo valor.
- Após atingir o ótimo, não se observa melhoria adicional relevante em nenhum dos algoritmos, indicando que todos são eficientes em estabilizar e evitar oscilações desnecessárias.

11. Convergência do Algoritmo DE – Soluções Viáveis




Figura 4.13: Convergência do Algoritmo DE – Soluções Viáveis

A Figura 4.13 mostra a evolução dos scores das soluções viáveis encontradas pelo DE ao longo das iterações, destacando a dispersão e tendência das soluções durante o processo.

Análise do gráfico:

- Observa-se grande dispersão dos scores nas primeiras iterações, refletindo uma ampla exploração do espaço de busca pelo DE.
- Já por volta da iteração 1500, a maioria dos scores se concentra acima de 0,8, com poucas soluções de score baixo, mostrando rápida convergência para regiões promissoras.
- Nas iterações finais, as soluções estão praticamente todas muito próximas ao score ótimo, confirmando a eficiência do DE em refinar soluções de alta qualidade rapidamente, sem perder diversidade no início da busca.

12. Convergência do Algoritmo GA – Soluções Viáveis




Figura 4.14: Convergência do Algoritmo GA – Soluções Viáveis

A Figura 4.14 mostra a evolução dos scores das soluções viáveis encontradas pelo GA ao longo das iterações, destacando a dispersão e tendência das soluções durante o processo.

Análise do gráfico:

- O GA inicia com uma variação significativa nos scores, incluindo valores relativamente baixos (abaixo de 0,6), sugerindo uma fase inicial de exploração intensa.
- A elevação gradativa dos scores, com redução progressiva das soluções de score baixo, mostra a transição para uma exploração mais refinada.
- A estabilização dos scores ocorre de forma mais lenta quando comparada ao DE (apenas após ~3.000 iterações), indicando um processo evolutivo conservador, que pode ser útil em problemas mais difíceis ou de paisagem multimodal.

13. Convergência do Algoritmo PSO – Soluções Viáveis




Figura 4.15: Convergência do Algoritmo PSO – Soluções Viáveis

A Figura 4.15 mostra a evolução dos scores das soluções viáveis encontradas pelo PSO ao longo das iterações, destacando a dispersão e tendência das soluções durante o processo.

Análise do gráfico:

- O PSO rapidamente elimina soluções de score baixo nas primeiras 200 iterações, demonstrando uma rápida exploração e direcionamento das partículas para regiões mais promissoras do espaço de busca.
- Após 400 iterações, quase todas as soluções viáveis estão próximas ao score ótimo, mostrando que o algoritmo consegue, além de convergir rápido, manter certa diversidade de soluções próximas ao ótimo.
- Esse comportamento torna o PSO especialmente interessante para aplicações onde tanto a velocidade quanto a diversidade de alternativas próximas ao ótimo são desejáveis.

14. Análise da Distribuição de Soluções Viáveis




Figura 4.16: Análise da Distribuição de Soluções Viáveis

A Figura 4.16 reúne quatro subgráficos que analisam a dispersão das soluções viáveis encontradas pelos algoritmos de otimização quanto aos posicionamentos dos intervalos de isolamento crítico (IICs). Nos três primeiros subgráficos, temos diagramas de dispersão comparando as profundidades das divisões consecutivas do poço: (prof_i vs prof_j), (prof_j vs prof_k) e (prof_k vs prof_l), sendo cada ponto uma solução viável e sua cor associada ao score alcançado. O quarto gráfico traz histogramas das profundidades em cada divisão, facilitando a visualização da concentração ou dispersão das soluções para cada intervalo.

Análise do gráfico:

- Observa-se forte correlação linear entre as divisões consecutivas (prof_i vs prof_j e prof_k vs prof_l), sugerindo que as restrições de espaçamento dos IICs foram respeitadas.
- Scores mais altos concentram-se em determinadas regiões dos diagramas, indicando que as melhores soluções tendem a ocupar faixas específicas de profundidade.
- O histograma mostra picos de frequência em certas profundidades para cada divisão, sugerindo preferência dos algoritmos por certos intervalos, muitas vezes alinhados a propriedades petrofísicas favoráveis.
- A visualização conjunta reforça que, apesar de diferentes algoritmos, há consenso sobre as zonas mais atrativas para dividir o poço.


15. Relação entre Tempo de Execução e Qualidade da Solução

Figura 4.17: Relação entre Tempo de Execução e Qualidade da Solução

A Figura 4.17 apresenta um gráfico de dispersão (bubble chart), que mostra a relação entre o tempo de execução (eixo X) e a qualidade da melhor solução encontrada (score, eixo Y) para cada algoritmo (GA, DE, PSO). O tamanho das bolhas está associado ao número de soluções viáveis encontradas por cada método, e as cores identificam os algoritmos.

Análise do gráfico:

- DE e PSO tiveram os menores tempos de execução, enquanto o GA foi um pouco mais demorado.
- Todos os algoritmos alcançaram scores finais semelhantes, indicando equivalência quanto à qualidade das melhores soluções.
- O tamanho das bolhas revela que o DE encontrou mais soluções viáveis, sugerindo melhor exploração do espaço de busca; já o PSO obteve menos soluções viáveis, indicando menor diversidade.
- A visualização evidencia que a escolha do algoritmo pode ser guiada por critérios como tempo de processamento e quantidade de alternativas geradas, além do score máximo obtido.
- O resultado reforça a adequação de diferentes metaheurísticas para o problema, cabendo ao decisor ponderar os trade-offs entre robustez, eficiência e diversidade de soluções. Uma visão comparativa maior entre os algoritmos de otimização utilizados poderá ser vista na próxima seção.

4.2.5**Comparação dos Algoritmos de Otimização**

Neste estudo, foi realizada uma comparação aprofundada entre três algoritmos evolutivos - *Genetic Algorithm* (GA), *Differential Evolution* (DE) e *Particle Swarm Optimization* (PSO) - para otimização de um problema típico de engenharia, considerando múltiplas rodadas experimentais e um conjunto de métricas de desempenho relevantes: tempo de execução, número de soluções viáveis, melhor score encontrado e robustez dos algoritmos frente a diferentes execuções.

Execuções independentes em diferentes cenários e restrições permitiram uma análise robusta da performance dos métodos. As informações completas dos resultados dos algoritmos podem ser encontradas na Tabela 4.14 e na Tabela 4.15.

Rodada	Tempo GA (s)	Tempo DE (s)	Tempo PSO (s)	Nº Solu- ções GA	Nº Solu- ções DE	Nº Solu- ções PSO	Máx. Score GA	Máx. Score DE	Máx. Score PSO
1	3.40	4.93	3.43	2824	2415	2686	0.7065	0.8468	0.8475
2	3.52	3.37	4.92	3407	3522	2774	0.8033	0.8037	0.8037
3	4.76	3.39	4.45	3598	3477	1445	0.6985	0.6431	0.6431
4	3.56	4.44	3.35	1528	702	125	0.6799	0.8537	0.6440
5	4.09	3.16	3.31	2148	1755	0	0.8321	0.8331	0.0000
6	4.07	3.70	3.32	2677	2096	1234	0.8124	0.8107	0.8127
7	3.47	3.12	4.66	2402	0	0	0.4765	0.0000	0.0000
8	4.68	3.23	3.34	2099	978	0	0.8385	0.8414	0.0000
9	5.00	3.33	3.53	512	212	0	0.7578	0.7536	0.0000
10	4.44	3.29	3.40	2923	3177	150	0.7700	0.7649	0.7184
11	3.44	3.30	4.73	1154	1698	668	0.7135	0.8220	0.6418
12	4.03	4.26	3.46	0	563	25	0.0000	0.7437	0.5991
13	3.89	4.87	3.50	3152	1231	1418	0.5666	0.5639	0.5605
14	3.35	3.23	4.46	2545	825	0	0.5306	0.8050	0.0000
15	3.40	3.17	4.82	0	1178	0	0.0000	0.7526	0.0000
16	4.46	3.41	3.33	2716	1019	1206	0.8257	0.8273	0.8272
17	4.42	3.73	3.61	2838	0	3175	0.5757	0.0000	0.5757
18	3.49	4.69	3.57	2015	1010	1066	0.8074	0.8060	0.5667
19	3.45	3.41	5.19	3121	1711	0	0.5901	0.5965	0.3869
20	4.90	3.47	3.39	2977	850	0	0.5692	0.5690	0.0000
21	4.02	4.11	3.52	2485	1028	0	0.6923	0.8162	0.0000
22	3.50	4.59	3.93	0	0	0	0.0000	0.0000	0.0000
23	5.04	3.58	3.78	0	0	0	0.0000	0.0000	0.0000
24	3.58	3.47	5.18	1692	129	0	0.7962	0.7944	0.0000
25	3.71	5.21	3.60	2813	1503	0	0.6821	0.8663	0.0000
26	4.59	3.49	3.36	0	1533	0	0.0000	0.7658	0.0000
27	4.24	3.29	3.44	3314	3208	1281	0.8647	0.8649	0.8649
28	4.76	3.26	3.42	3203	3791	1004	0.8448	0.8448	0.8448
29	3.52	5.12	3.52	2372	896	408	0.7983	0.8008	0.6780
30	6.97	3.29	3.47	3024	1672	430	0.8882	0.8876	0.6205
Média	4.12	3.76	3.83	2117	1405	636	0.6040	0.6759	0.3878

Tabela 4.14: Consolidação das Métricas Principais entre Algoritmos de Otimização

	GA	DE	PSO
Frequência de Superação	20/30	27/30	10/30
Frequência de Viabilidade	25/30	26/30	16/30

Tabela 4.15: Resumo das Frequências de Superação e Viabilidade dos Algoritmos

Tempo de Execução

- Os 3 algoritmos, para o problema analisado, apresentam tempos semelhantes de execução.
- DE tende a ser mais rápido na maioria dos cenários, enquanto GA e PSO frequentemente apresentam tempos pouco maiores.
- Em tempo: foram realizadas rodadas do algoritmo de Força Bruta (teste exaustivo) na tentativa de solucionar o problema sem recorrer a um algoritmo de otimização. Todas as rodadas foram encerradas após mais de uma dezena de horas de simulação sem apresentar soluções para o problema.

Número de Soluções Viáveis Encontradas

- GA e DE são superiores em número de soluções viáveis na maioria das execuções, especialmente em cenários com restrições intermediárias.
- PSO frequentemente não retorna soluções viáveis em cenários mais restritivos, o que indica sensibilidade a restrições (robustez limitada).
- DE apresenta performance robusta, com grandes variações, mas mantendo-se competitivo com GA.

Melhor Score Encontrado

- Em cenários menos restritivos, GA, DE e PSO atingem scores máximos próximos, com vantagem visível para os algoritmos GA e DE.
- Em cenários de alta restrição, DE é o algoritmo que mais frequentemente atinge o melhor score, seguido por GA.
- PSO apresenta desempenho ruim ou nulo em cenários muito restritos, com scores muito inferiores ou inexistentes.

Robustez

- DE é o algoritmo mais estável, apresentando bons resultados tanto em score quanto em soluções viáveis na maioria dos cenários.
- GA é mais robusto que o PSO, principalmente quanto ao número de soluções viáveis.
- PSO é o mais sensível a restrições, com grandes oscilações e tendência a não encontrar soluções em problemas altamente restritivos.

Vantagens de Cada Algoritmo

– *Genetic Algorithm (GA)*:

- Maior robustez na geração de soluções viáveis, mesmo em cenários restritivos.
- Score competitivo, especialmente em cenários de dificuldade intermediária.
- Execução rápida e estável, com poucas instâncias de falha total.

– *Differential Evolution (DE)*:

- Melhor desempenho geral no trade-off score vs. número de soluções viáveis.
- Algoritmo mais robusto e estável, adaptando-se bem a diferentes níveis de restrição.
- Tempo de execução consistentemente baixo, tornando-o vantajoso para aplicações onde eficiência computacional é relevante.

– *Particle Swarm Optimization (PSO)*:

- Quando encontra soluções viáveis, frequentemente apresenta scores próximos aos demais em cenários sem grandes restrições.
- Sensibilidade a restrições pode ser um problema, mas em problemas “mais fáceis” pode ser competitivo.

Limitações Identificadas

- PSO demonstra baixa robustez em cenários altamente restritivos, apresentando várias execuções sem encontrar sequer uma solução viável.
- GA e DE apresentam maior estabilidade, mas DE se destaca em eficiência e score em cenários restritivos.

Recomendações para Uso Prático

- Para cenários restritivos (muitos requisitos, alta penalização, ou busca por soluções factíveis): DE é a melhor escolha.
- Para problemas intermediários (nível de dificuldade moderado, interesse em diversidade de soluções): DE e GA apresentam robustez e bons scores.
- Para cenários pouco restritivos, DE, GA e PSO são competitivos e apresentam resultados semelhantes.

A análise experimental comparativa evidencia que o *Differential Evolution* (DE) apresenta o melhor desempenho global frente aos critérios estabelecidos, especialmente na presença de restrições rigorosas e quando se busca o equilíbrio entre número de soluções viáveis e qualidade do score encontrado. O *Genetic Algorithm* (GA) se mostra robusto e confiável, sendo uma boa alternativa para cenários intermediários ou quando a diversidade de soluções é relevante. Já o *Particle Swarm Optimization* (PSO) apresenta comportamento inconsistente e limitada robustez em cenários de alta restrição, sendo recomendado apenas para casos em que restrições não sejam predominantes.

Recomendação Final

Para aplicações práticas e acadêmicas similares ao contexto estudado, recomenda-se o uso do DE como método principal, com o GA como alternativa robusta. O PSO deve ser utilizado apenas em situações em que a viabilidade das soluções não seja fortemente comprometida por restrições.

4.2.6

Validação das Soluções

Para atestar a eficácia das soluções computacionais propostas, foi conduzido um processo de validação estruturado conforme descrito na metodologia. Cinco conjuntos de perfis foram selecionados aleatoriamente a partir da base de dados, abrangendo diferentes cenários e desafios operacionais representativos do contexto do estudo.

A validação ocorreu em três etapas: inicialmente, os especialistas definiram os Intervalos de Isolamento Crítico (IICs) de modo independente, seguindo a prática tradicional das reuniões operacionais. Em seguida, as soluções de maior score geradas pelos algoritmos de otimização foram apresentadas para análise comparativa. Por fim, os especialistas foram convidados a oferecer feedback sobre a adequação das soluções e possíveis necessidades de ajuste.

Os resultados dessa etapa foram altamente positivos. Em todos os casos analisados, observou-se elevada aderência entre as recomendações dos algoritmos e as decisões humanas. As soluções computacionais coincidiram, de forma geral, com as definições de posicionamento dos IICs indicadas pelos especialistas. Além disso, a avaliação qualitativa apontou que as soluções sugeridas pelos algoritmos respeitaram as diretrizes técnicas estabelecidas.

Importante destacar que, em nenhum dos casos avaliados, os especialistas indicaram necessidade de refinamento ou ajuste dos algoritmos. Os participantes expressaram confiança na robustez do processo de otimização e reconheceram o potencial da abordagem para apoiar decisões em ambientes reais, destacando o alinhamento entre teoria e prática promovido pelo framework desenvolvido.

Em síntese, a etapa de validação comprovou que as soluções otimizadas apresentadas pelos algoritmos não apenas são compatíveis com o julgamento humano especializado, como também se mostram aptas a serem incorporadas ao processo decisório das operações de definição de IICs, fortalecendo o valor prático da metodologia proposta.

4.3

Desenvolvimento da Ferramenta *Welllog Viewer and Analyzer*

Com base nas demandas práticas identificadas, esta seção apresenta o *Welllog Viewer and Analyzer*, concebido para operacionalizar a metodologia proposta: leitura de arquivos LAS, cálculo e organização de métricas, visualização de curvas relevantes e recursos de inspeção que apoiam a seleção de IICs.

O código-fonte que implementa a ferramenta encontra-se disponível publicamente no GitHub para reprodutibilidade (*WellLog Viewer and Analyzer* (Henriques Neto, 2024)).

As seções a seguir descrevem a finalidade, a arquitetura e as funcionalidades do software.

4.3.1

Descrição do Software

O software desenvolvido é uma ferramenta projetada para a visualização e análise detalhada de dados de perfis de poços, especialmente aqueles armazenados no formato padrão LAS. Este formato é amplamente utilizado na indústria de exploração de petróleo e gás, sendo fundamental para registrar informações cruciais sobre formações geológicas, propriedades dos fluidos e características do poço.

4.3.1.1

Finalidade

O principal propósito deste software é capacitar os profissionais e especialistas envolvidos na análise de dados geofísicos e geológicos a explorar de maneira eficaz e detalhada as informações contidas nos arquivos LAS. Ao integrar funcionalidades de conversão de dados, visualização gráfica e cálculo de métricas matemáticas dos parâmetros dos perfis, o software facilita a interpretação precisa e a tomada de decisões fundamentadas em exploração e produção de recursos naturais.

4.3.1.2

Requisitos Funcionais e Não Funcionais

Requisitos Funcionais

- **Carregar Arquivos LAS:** O sistema deve permitir ao usuário selecionar e carregar arquivos no formato LAS.
- **Converter LAS para CSV:** O sistema deve converter arquivos LAS para CSV com formatação apropriada.
- **Gerar Métricas Matemáticas:** O sistema deve calcular e exibir métricas matemáticas (média, desvio padrão, etc.) dos dados dos perfis.
- **Visualizar Perfis:** O sistema deve permitir a visualização gráfica dos perfis carregados a partir do arquivo LAS.
- **Operações de Zoom:** O sistema deve permitir zoom in e zoom out nas visualizações dos perfis para uma análise detalhada.

Requisitos Não Funcionais

- **Eficiência:** O sistema deve processar e visualizar os dados de maneira eficiente, minimizando o tempo de espera do usuário.
- **Robustez:** O sistema deve tratar entradas inválidas de maneira graciosa, exibindo mensagens de erro apropriadas.
- **Usabilidade:** A interface deve ser intuitiva e fácil de usar, permitindo que os usuários naveguem e utilizem as funcionalidades sem dificuldades.
- **Compatibilidade:** O sistema deve ser compatível com as versões mais recentes do Python (≥ 3.7).

4.3.2

Conformidade do Arquivo LAS para Uso no Software

De forma geral, os arquivos LAS de dados de perfis de poços, independentemente de sua origem, possuem a mesma formatação para que possam ser utilizados diretamente nos softwares dedicados sem uma necessidade de correção. O Apêndice C serve como guia para verificação de corretude de formatação para uso no software.

4.3.3

Exemplos da Interface do Sistema

A Figura 4.18 e a Figura 4.19 indicam as duas primeiras telas do software que levam à seleção do arquivo .LAS para análise.




Figura 4.18: Tela Inicial




Figura 4.19: Caixa de seleção do arquivo .las

A Figura 4.20 apresenta métricas de distribuição importantes para a análise efetiva do conjunto de perfis carregado, como média e percentis das curvas dos perfis.

index	count	mean	std	min	25%	50%	75%	max
DEPT [F]	950.0	287.8	137.2	50.5	169.1	287.8	406.4	525.0
CALI [IN]	950.0	5.9	1.2	3.9	5.2	5.5	6.0	11.6
SGR [GAPI]	950.0	90.5	33.4	26.3	68.3	91.0	108.3	230.1
CGR [GAPI]	950.0	57.2	21.3	3.8	41.6	60.0	73.2	109.8
THOR [PPM]	950.0	7.9	3.6	-1.4	5.5	8.2	10.6	18.5
URAN [PPM]	950.0	3.8	3.1	0.0	2.3	3.1	4.1	19.1
POTA [PERC]	950.0	1.2	0.6	-0.3	0.7	1.0	1.4	3.1
ILD [OHMM]	840.0	24.8	16.0	2.9	14.8	19.5	30.7	79.2
ILM [OHMM]	950.0	24.6	16.6	2.9	15.3	19.4	29.3	85.4
SFLU [OHMM]	950.0	94.7	320.6	2.9	16.0	24.5	51.5	2000.0

Figura 4.20: Tabela de métricas dos dados de perfil

A tabela de correlação das siglas apresentadas na interface com o nome completo do perfil e com sua descrição pode ser encontrada no Apêndice D.

A Figura 4.21 apresenta, de forma gráfica e de fácil entendimento, as curvas dos perfis carregados. Através da imagem, consegue-se identificar zonas produtivas e caracterizar formações.




Figura 4.21: Visualizador e Analisador de Perfil de Poços

5

Considerações Finais

Este capítulo apresenta uma reflexão final sobre os principais resultados alcançados, as limitações encontradas durante a realização do estudo e as perspectivas para trabalhos futuros.

5.1

Conclusões da Pesquisa

A presente dissertação estabeleceu e validou uma abordagem inovadora e estruturada para a definição assistida dos Intervalos de Isolamento Crítico (IICs) em poços de petróleo, tema de alta relevância para a engenharia de reservatórios e a eficiência operacional da indústria do petróleo. Ao integrar conhecimento tácito de especialistas, diretrizes técnicas e métodos quantitativos robustos, este trabalho contribui para a consolidação de um novo paradigma de tomada de decisão fundamentada em dados e metaheurística aplicada.

Dentre as principais realizações, destaca-se a construção colaborativa de diretrizes técnicas a partir de entrevistas com especialistas experientes, aliando experiência prática à sistematização de melhores práticas para o posicionamento dos IICs. A hierarquização dessas diretrizes por meio do método *Analytic Hierarchy Process* (AHP) garantiu objetividade, transparência e consenso, resultando em critérios otimizadores claros e replicáveis para diferentes contextos operacionais.

No campo da otimização, a aplicação dos algoritmos metaheurísticos *Genetic Algorithm* (GA), *Differential Evolution* (DE) e *Particle Swarm Optimization* (PSO) demonstrou, de forma comparativa e rigorosa, que tais ferramentas são aptas para resolver problemas complexos, com múltiplas restrições e elevado grau de incerteza.

Como resultado prático da pesquisa, recomenda-se, para aplicações práticas e acadêmicas similares ao contexto estudado, o uso do DE como método principal, com o GA como alternativa robusta. O PSO deve ser utilizado apenas em situações em que a viabilidade das soluções não seja fortemente comprometida por restrições.

Sob a perspectiva científica, este estudo amplia os horizontes da literatura ao propor um *framework* replicável, transparente e adaptável, que pode ser

expandido para diferentes campos, cenários geológicos e exigências técnicas. As bases metodológicas e os resultados alcançados pavimentam o caminho para novas investigações e aplicações de algoritmos de otimização nos diversos setores da indústria.

Em síntese, a dissertação não apenas alcançou seus objetivos iniciais, como demonstrou o potencial transformador de metodologias baseadas em otimização assistida e integração de *expertises*, consolidando uma referência metodológica e operacional para futuras iniciativas no âmbito da engenharia de reservatórios e da automação da decisão no setor de petróleo.

5.2

Limitações

Apesar dos avanços apresentados, algumas limitações foram identificadas neste estudo:

- **Dependência da qualidade dos dados:** O desempenho da metodologia está diretamente relacionado à qualidade e consistência dos dados de perfilagem, exigindo calibração constante das diretrizes ao se aplicar em diferentes campos.
- **Amostragem restrita:** Os testes e validações foram realizados em um conjunto limitado de cenários reais e sintéticos, o que pode restringir a generalização dos resultados.
- **Simplificações do modelo:** A abordagem adotada considerou um único objetivo de otimização e critérios técnicos estabelecidos para um campo específico, o que pode não contemplar a complexidade de todos os ambientes.

5.3

Sugestões para Trabalhos Futuros

A partir das limitações identificadas e do potencial de expansão da abordagem, sugerem-se as seguintes linhas para trabalhos futuros:

- **Ampliação dos testes:** Aplicar e validar a metodologia em diferentes campos petrolíferos, considerando uma variedade maior de perfis geológicos e operacionais.
- **Consideração de múltiplos objetivos:** Evoluir o modelo para abranger critérios múltiplos, como custos operacionais, risco, segurança e impacto ambiental.

- **Integração com aprendizado de máquina:** Explorar o uso de modelos de *machine learning* para aprimorar a predição das zonas ideais e calibrar automaticamente as diretrizes a partir de bases de dados expandidas.
- **Avaliação de novas funções de *score* e operadores de otimização:** Investigar alternativas de funções objetivo e testar algoritmos híbridos ou outros métodos de otimização para problemas ainda mais complexos.
- **Implementação e validação operacional em campo:** Desenvolver estudos de caso que envolvam a aplicação prática das soluções otimizadas no ambiente de produção, avaliando impactos reais na eficiência e na tomada de decisão.

Referências Bibliográficas

- Ahn, B. S. e Park, K. S. (2008). Comparing methods for multiattribute decision making with ordinal weights. *Computers & Operations Research*, 35(5):1660–1670.
- Akinola, O. O., Ezugwu, A. E., Agushaka, J. O., et al. (2022). Multiclass feature selection with metaheuristic optimization algorithms: A review. *Neural Computing and Applications*, 35:4025–4046.
- Botechia, V. E., Lemos, R. A., João Carlos von Hohendorff Filho, e Schiozer, D. J. (2021). Well and icv management in a carbonate reservoir with high gas content. *Journal of Petroleum Science and Engineering*, 200:108345.
- Brans, J. P., Vincke, P., e Mareschal, B. (1986). How to select and how to rank projects: The promethee method. *European Journal of Operational Research*, 24(2):228–238.
- Chou, J. S. e Thejda, J. P. P. (2016). Metaheuristic optimization within machine learning based classification system for early warnings related to geotechnical problems. *Automation in Construction*, 68:65–80.
- de Carvalho, R. L., Almeida, T. S., e Rocha, M. L. (2020). *Introdução às Metaheurísticas*. EDUFT, Palmas, TO.
- Ebadi, F. e Davies, D. R. (2006). Techniques for optimum placement of interval control valve(s) in an intelligent well. In *SPE Europec/EAGE Annual Conference and Exhibition*.
- Elaziz, M. A., Dahou, A., Abualigah, L., et al. (2021). Advanced metaheuristic optimization techniques in applications of deep neural networks: A review. *Neural Computing and Applications*, 33:5731–5753.
- Guilmeau, T., Chouzenoux, E., e Elvira, V. (2021). Simulated annealing: A review and a new scheme. In *IEEE Statistical Signal Processing Workshop*.
- Halim, A. H., Ismail, I., e Das, S. (2020). Performance assessment of metaheuristic optimization algorithms: An exhaustive review. *Artificial Intelligence Review*, 53(1):435–470.

- Henriques Neto, L. A. (2024). Wellog viewer and analyzer. Repositório GitHub. Disponível em: <https://github.com/LuizdeAbreu/log-reader>. Acesso em: 20 ago. 2025.
- Henriques Neto, L. A. (2025). Ciiis-optimizer: Optimization of critical isolation intervals (cii) in oil wells. Repositório GitHub. Disponível em: <https://github.com/LuizdeAbreu/CIIIs-Optimizer>. Acesso em: 20 ago. 2025.
- Jansen, H. (2010). The logic of qualitative survey research and its position in the field of social research methods. *Forum: Qualitative Social Research*, 11(2):Art. 11.
- Leal, J. E. (2020). Ahp express: A simplified version of the analytical hierarchy process method. *MethodsX*, 7:100748.
- Liang, J., Ban, X., Yu, K., et al. (2023). A survey on evolutionary constrained multiobjective optimization. *IEEE Transactions on Evolutionary Computation*, 27(2):201–226.
- Maretto, L., Faccio, M., e Battini, D. (2022). A multi criteria decision making model based on fuzzy logic and ahp. *IFAC PapersOnLine*, 55(2):319–324.
- Marler, R. T. e Arora, J. S. (2010). The weighted sum method for multi objective optimization: New insights. *Structural and Multidisciplinary Optimization*, 41(6):853–862.
- Rystad Energy (2024). Wells in focus: Overview of global well activity.
- Saaty, T. L. (1980). *The Analytic Hierarchy Process: Planning, Priority Setting, Resource Allocation*. McGraw-Hill, New York.
- Saaty, T. L. (2008). Decision making with the analytic hierarchy process. *International Journal of Services Sciences*, 1(1):83–98.
- Schaefer, B. d. C. e Sampaio, M. A. (2020). Efficient workflow for optimizing intelligent well completion using production parameters in real time. *Oil & Gas Science and Technology – Rev. IFP Energies nouvelles*, 75:69.
- Sharma, S. e Kumar, V. (2022). A comprehensive review on multiobjective optimization techniques. *Archives of Computational Methods in Engineering*, 29(2):769–794.
- Sharma, S. e Kumar, V. (2023). A comprehensive review on multi objective optimization techniques: Past, present and future. *Archives of Computational Methods in Engineering*, 30:521–573.

- Tissot, B. P. e Welte, D. H. (1984). *Petroleum Formation and Occurrence*. Springer-Verlag, Berlin, 2 edition.
- Vaidya, O. S. e Kumar, S. (2006). Analytic hierarchy process: An overview of applications. *European Journal of Operational Research*, 169(1):1–29.
- Verma, S., Pant, M., e Snasel, V. (2021). A comprehensive review on nsga ii for multi objective combinatorial optimization problems. *IEEE Access*, 9:57757–57777.
- Xie, Y., Jin, L., Zhu, C., e Wu, S. (2023). A semi supervised coarse to fine approach with bayesian optimization for lithology identification. *Earth Science Informatics*, 16(6):2285–2305.
- Zeng, L., Ren, W., Shan, L., e Huo, F. (2022). Well logging prediction and uncertainty analysis based on recurrent neural network with attention mechanism and bayesian theory. *Journal of Petroleum Science and Engineering*, 208:109458.

A

Roteiro da Entrevista com Especialistas

Este apêndice apresenta o roteiro completo de perguntas utilizado nas entrevistas com os especialistas.

1. Definição da Pesquisa

- **Objetivo:** Entender as motivações para a divisão de um poço de petróleo em diferentes zonas de produção ou injeção e criar diretrizes para a seleção dos Intervalos de Isolamento Críticos (IICs) com base nas experiências e conhecimentos de especialistas da área de reservatórios, perfuração e completação.
- **Pergunta de Pesquisa Principal:** Quais fatores guiam a decisão da divisão de poços de petróleo em zonas de produção e como são selecionados os IICs?
- **Subperguntas:**
 - Quais são os principais critérios que influenciam a decisão de divisão de poços?
 - Qual o papel da perfilagem no processo da seleção dos IICs?
 - Quais perfis são mais importantes para a tomada de decisão?
 - Quais fatores quantitativos derivados da perfilagem que impactam diretamente essa escolha?

2. Seleção dos Participantes

- **Critérios de seleção:** Especialistas da área de reservatórios, perfuração e completação de poços com experiência prática na tomada de decisões relacionadas à divisão de poços em zonas de produção.
- **Tamanho da amostra:** De 5 a 15 especialistas, ou até a saturação dos dados, quando novas entrevistas não trazem mais informações relevantes.
- **Estratégia de amostragem:** Amostragem proposital, focando em indivíduos com conhecimento profundo do processo de completação e uso de perfilagem.

3. Coleta de Dados

- **Método principal:** Entrevistas semiestruturadas, permitindo que os especialistas compartilhem suas experiências e percepções com flexibilidade.
 - As entrevistas serão realizadas via videoconferência.
- **Complementação dos dados:** Coleta de documentos técnicos (como relatórios de poços) ou perfis de poços específicos, se disponíveis, para contextualizar melhor as respostas.

4. Elaboração das Perguntas de Entrevista

As perguntas serão divididas em três blocos principais:

- **Bloco 1: Perfil do Respondente**
 - **Formação:** “Qual a sua formação?”
 - **Experiência:** “Quantos anos de trabalho na área?”, “Em qual área da empresa você trabalha?”, “Como a análise de perfis e a divisão de poços em zonas de produção ou injeção se encaixam na sua atuação?”
- **Bloco 2: Fatores de Decisão para a Divisão em Zonas de Produção**
 - **Processo de decisão:** “Quais fatores você considera ao dividir um poço em zonas de produção?”
 - **Critérios de decisão:** “Que critérios você usa para definir o número de zonas de produção? Existe um padrão ou a decisão é flexível?”
- **Bloco 3: Perfilagem de Poços e Fatores Quantitativos**
 - **Perfilagem:** “Na sua experiência, qual perfil (porosidade, resistividade, densidade etc.) você considera mais importante na decisão de como dividir o poço em zonas de produção? Por quê?”
 - **Perfilagem:** “Quais perfis você considera que não são relevantes para a tarefa de divisão de poços em zonas de produção ou injeção?”
 - **Fatores quantitativos:** “Ao analisar a perfilagem de poços, quais fatores quantitativos (como saturação de fluido, porosidade ou permeabilidade) desempenham um papel decisivo na definição das zonas? Como esse fator influencia a sua decisão?”
 - **Desafios enfrentados:** “Pode descrever um caso em que a divisão do poço em zonas foi especialmente desafiadora? Como a decisão foi tomada e quais foram os resultados?”
- **Bloco 4: Tecnologia e Inovação**

- **Inovações tecnológicas:** “Existe alguma tecnologia, como uma automatização, que você utiliza para determinar a divisão em zonas? Como essa tecnologia impacta suas decisões? Em caso negativo, você considera que uma solução direcionada a essa questão ajudaria no processo?”

B

Soluções Encontradas da Definição Assistida dos IICs

Este apêndice apresenta o pacote de soluções obtidas a partir do código implementado para os 30 conjuntos de perfis analisados.

B.1

Execução 1

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 1.




Figura B.1: Execução 1 - Comparação de Desempenho dos Algoritmos




Figura B.2: Execução 1 - Comparação das Melhores Soluções por Algoritmo




Figura B.3: Execução 1 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.4: Execução 1 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.5: Execução 1 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.6: Execução 1 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.7: Execução 1 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.8: Execução 1 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.9: Execução 1 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.10: Execução 1 - Convergência dos Algoritmos por Número de Avaliações




Figura B.11: Execução 1 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.12: Execução 1 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.13: Execução 1 - Convergência do Algoritmo PSO – Soluções Viáveis




Figura B.14: Execução 1 - Análise da Distribuição de Soluções Viáveis




Figura B.15: Execução 1 - Relação entre Tempo de Execução e Qualidade da Solução

B.2

Execução 2

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 2.




Figura B.16: Execução 2 - Comparação de Desempenho dos Algoritmos




Figura B.17: Execução 2 - Comparação das Melhores Soluções por Algoritmo




Figura B.18: Execução 2 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.19: Execução 2 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.20: Execução 2 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.21: Execução 2 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.22: Execução 2 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.23: Execução 2 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.24: Execução 2 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.25: Execução 2 - Convergência dos Algoritmos por Número de Avaliações




Figura B.26: Execução 2 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.27: Execução 2 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.28: Execução 2 - Convergência do Algoritmo PSO – Soluções Viáveis

Análise da Distribuição de Soluções Viáveis




Figura B.29: Execução 2 - Análise da Distribuição de Soluções Viáveis




Figura B.30: Execução 2 - Relação entre Tempo de Execução e Qualidade da Solução

B.3

Execução 3

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 3.




Figura B.31: Execução 3 - Comparação de Desempenho dos Algoritmos




Figura B.32: Execução 3 - Comparação das Melhores Soluções por Algoritmo




Figura B.33: Execução 3 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.34: Execução 3 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.35: Execução 3 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.36: Execução 3 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.37: Execução 3 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.38: Execução 3 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.39: Execução 3 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.40: Execução 3 - Convergência dos Algoritmos por Número de Avaliações




Figura B.41: Execução 3 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.42: Execução 3 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.43: Execução 3 - Convergência do Algoritmo PSO – Soluções Viáveis

Análise da Distribuição de Soluções Viáveis




Figura B.44: Execução 3 - Análise da Distribuição de Soluções Viáveis




Figura B.45: Execução 3 - Relação entre Tempo de Execução e Qualidade da Solução

B.4

Execução 4

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 4.




Figura B.46: Execução 4 - Comparação de Desempenho dos Algoritmos




Figura B.47: Execução 4 - Comparação das Melhores Soluções por Algoritmo




Figura B.48: Execução 4 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.49: Execução 4 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.50: Execução 4 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.51: Execução 4 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.52: Execução 4 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.53: Execução 4 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.54: Execução 4 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.55: Execução 4 - Convergência dos Algoritmos por Número de Avaliações




Figura B.56: Execução 4 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.57: Execução 4 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.58: Execução 4 - Convergência do Algoritmo PSO – Soluções Viáveis

Análise da Distribuição de Soluções Viáveis




Figura B.59: Execução 4 - Análise da Distribuição de Soluções Viáveis




Figura B.60: Execução 4 - Relação entre Tempo de Execução e Qualidade da Solução

B.5

Execução 5

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 5.




Figura B.61: Execução 5 - Comparação de Desempenho dos Algoritmos




Figura B.62: Execução 5 - Comparação das Melhores Soluções por Algoritmo




Figura B.63: Execução 5 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.64: Execução 5 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.65: Execução 5 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.66: Execução 5 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.67: Execução 5 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.68: Execução 5 - Convergência dos Algoritmos por Número de Avaliações




Figura B.69: Execução 5 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.70: Execução 5 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.71: Execução 5 - Relação entre Tempo de Execução e Qualidade da Solução

B.6

Execução 6

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 6.




Figura B.72: Execução 6 - Comparação de Desempenho dos Algoritmos




Figura B.73: Execução 6 - Comparação das Melhores Soluções por Algoritmo




Figura B.74: Execução 6 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.75: Execução 6 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.76: Execução 6 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.77: Execução 6 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.78: Execução 6 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.79: Execução 6 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.80: Execução 6 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.81: Execução 6 - Convergência dos Algoritmos por Número de Avaliações




Figura B.82: Execução 6 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.83: Execução 6 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.84: Execução 6 - Convergência do Algoritmo PSO – Soluções Viáveis

Análise da Distribuição de Soluções Viáveis




Figura B.85: Execução 6 - Análise da Distribuição de Soluções Viáveis




Figura B.86: Execução 6 - Relação entre Tempo de Execução e Qualidade da Solução

B.7**Execução 7**

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 7.




Figura B.87: Execução 7 - Comparação de Desempenho dos Algoritmos




Figura B.88: Execução 7 - Comparação das Melhores Soluções por Algoritmo




Figura B.89: Execução 7 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.90: Execução 7 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.91: Execução 7 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.92: Execução 7 - Convergência dos Algoritmos por Número de Avaliações




Figura B.93: Execução 7 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.94: Execução 7 - Relação entre Tempo de Execução e Qualidade da Solução

B.8**Execução 8**

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 8.




Figura B.95: Execução 8 - Comparação de Desempenho dos Algoritmos




Figura B.96: Execução 8 - Comparação das Melhores Soluções por Algoritmo




Figura B.97: Execução 8 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.98: Execução 8 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.99: Execução 8 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.100: Execução 8 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.101: Execução 8 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.102: Execução 8 - Convergência dos Algoritmos por Número de Avaliações




Figura B.103: Execução 8 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.104: Execução 8 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.105: Execução 8 - Relação entre Tempo de Execução e Qualidade da Solução

B.9**Execução 9**

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 9.




Figura B.106: Execução 9 - Comparação de Desempenho dos Algoritmos




Figura B.107: Execução 9 - Comparação das Melhores Soluções por Algoritmo




Figura B.108: Execução 9 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.109: Execução 9 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.110: Execução 9 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.111: Execução 9 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.112: Execução 9 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.113: Execução 9 - Convergência dos Algoritmos por Número de Avaliações




Figura B.114: Execução 9 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.115: Execução 9 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.116: Execução 9 - Relação entre Tempo de Execução e Qualidade da Solução

B.10

Execução 10

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 10.




Figura B.117: Execução 10 - Comparação de Desempenho dos Algoritmos




Figura B.118: Execução 10 - Comparação das Melhores Soluções por Algoritmo




Figura B.119: Execução 10 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.120: Execução 10 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.121: Execução 10 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.122: Execução 10 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.123: Execução 10 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.124: Execução 10 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.125: Execução 10 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.126: Execução 10 - Convergência dos Algoritmos por Número de Avaliações




Figura B.127: Execução 10 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.128: Execução 10 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.129: Execução 10 - Convergência do Algoritmo PSO – Soluções Viáveis




Figura B.130: Execução 10 - Análise da Distribuição de Soluções Viáveis




Figura B.131: Execução 10 - Relação entre Tempo de Execução e Qualidade da Solução

B.11**Execução 11**

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 11.




Figura B.132: Execução 11 - Comparação de Desempenho dos Algoritmos




Figura B.133: Execução 11 - Comparação das Melhores Soluções por Algoritmo




Figura B.134: Execução 11 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.135: Execução 11 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.136: Execução 11 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.137: Execução 11 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.138: Execução 11 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.139: Execução 11 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.140: Execução 11 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.141: Execução 11 - Convergência dos Algoritmos por Número de Avaliações




Figura B.142: Execução 11 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.143: Execução 11 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.144: Execução 11 - Convergência do Algoritmo PSO – Soluções Viáveis




Figura B.145: Execução 11 - Análise da Distribuição de Soluções Viáveis




Figura B.146: Execução 11 - Relação entre Tempo de Execução e Qualidade da Solução

B.12

Execução 12

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 12.




Figura B.147: Execução 12 - Comparação de Desempenho dos Algoritmos




Figura B.148: Execução 12 - Comparação das Melhores Soluções por Algoritmo




Figura B.149: Execução 12 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.150: Execução 12 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.151: Execução 12 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.152: Execução 12 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.153: Execução 12 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.154: Execução 12 - Convergência dos Algoritmos por Número de Avaliações




Figura B.155: Execução 12 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.156: Execução 12 - Convergência do Algoritmo PSO – Soluções Viáveis




Figura B.157: Execução 12 - Análise da Distribuição de Soluções Viáveis




Figura B.158: Execução 12 - Relação entre Tempo de Execução e Qualidade da Solução

B.13

Execução 13

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 13.




Figura B.159: Execução 13 - Comparação de Desempenho dos Algoritmos




Figura B.160: Execução 13 - Comparação das Melhores Soluções por Algoritmo




Figura B.161: Execução 13 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.162: Execução 13 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.163: Execução 13 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.164: Execução 13 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.165: Execução 13 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.166: Execução 13 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.167: Execução 13 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.168: Execução 13 - Convergência dos Algoritmos por Número de Avaliações




Figura B.169: Execução 13 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.170: Execução 13 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.171: Execução 13 - Convergência do Algoritmo PSO – Soluções Viáveis




Figura B.172: Execução 13 - Análise da Distribuição de Soluções Viáveis




Figura B.173: Execução 13 - Relação entre Tempo de Execução e Qualidade da Solução

B.14

Execução 14

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 14.




Figura B.174: Execução 14 - Comparação de Desempenho dos Algoritmos




Figura B.175: Execução 14 - Comparação das Melhores Soluções por Algoritmo




Figura B.176: Execução 14 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.177: Execução 14 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.178: Execução 14 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.179: Execução 14 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.180: Execução 14 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.181: Execução 14 - Convergência dos Algoritmos por Número de Avaliações




Figura B.182: Execução 14 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.183: Execução 14 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.184: Execução 14 - Relação entre Tempo de Execução e Qualidade da Solução

B.15**Execução 15**

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 15.




Figura B.185: Execução 15 - Comparação de Desempenho dos Algoritmos




Figura B.186: Execução 15 - Comparação das Melhores Soluções por Algoritmo




Figura B.187: Execução 15 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.188: Execução 15 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.189: Execução 15 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.190: Execução 15 - Convergência dos Algoritmos por Número de Avaliações




Figura B.191: Execução 15 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.192: Execução 15 - Relação entre Tempo de Execução e Qualidade da Solução

B.16

Execução 16

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 16.




Figura B.193: Execução 16 - Comparação de Desempenho dos Algoritmos




Figura B.194: Execução 16 - Comparação das Melhores Soluções por Algoritmo




Figura B.195: Execução 16 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.196: Execução 16 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.197: Execução 16 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.198: Execução 16 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.199: Execução 16 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.200: Execução 16 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.201: Execução 16 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.202: Execução 16 - Convergência dos Algoritmos por Número de Avaliações




Figura B.203: Execução 16 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.204: Execução 16 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.205: Execução 16 - Convergência do Algoritmo PSO – Soluções Viáveis




Figura B.206: Execução 16 - Análise da Distribuição de Soluções Viáveis




Figura B.207: Execução 16 - Relação entre Tempo de Execução e Qualidade da Solução

B.17

Execução 17

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 17.




Figura B.208: Execução 17 - Comparação de Desempenho dos Algoritmos




Figura B.209: Execução 17 - Comparação das Melhores Soluções por Algoritmo




Figura B.210: Execução 17 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.211: Execução 17 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.212: Execução 17 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.213: Execução 17 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.214: Execução 17 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.215: Execução 17 - Convergência dos Algoritmos por Número de Avaliações




Figura B.216: Execução 17 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.217: Execução 17 - Convergência do Algoritmo PSO – Soluções Viáveis

Análise da Distribuição de Soluções Viáveis




Figura B.218: Execução 17 - Análise da Distribuição de Soluções Viáveis




Figura B.219: Execução 17 - Relação entre Tempo de Execução e Qualidade da Solução

B.18**Execução 18**

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 18.




Figura B.220: Execução 18 - Comparação de Desempenho dos Algoritmos




Figura B.221: Execução 18 - Comparação das Melhores Soluções por Algoritmo




Figura B.222: Execução 18 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.223: Execução 18 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.224: Execução 18 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.225: Execução 18 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.226: Execução 18 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.227: Execução 18 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.228: Execução 18 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.229: Execução 18 - Convergência dos Algoritmos por Número de Avaliações




Figura B.230: Execução 18 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.231: Execução 18 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.232: Execução 18 - Convergência do Algoritmo PSO – Soluções Viáveis




Figura B.233: Execução 18 - Análise da Distribuição de Soluções Viáveis




Figura B.234: Execução 18 - Relação entre Tempo de Execução e Qualidade da Solução

B.19**Execução 19**

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 19.




Figura B.235: Execução 19 - Comparação de Desempenho dos Algoritmos




Figura B.236: Execução 19 - Comparação das Melhores Soluções por Algoritmo




Figura B.237: Execução 19 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.238: Execução 19 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.239: Execução 19 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.240: Execução 19 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.241: Execução 19 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.242: Execução 19 - Convergência dos Algoritmos por Número de Avaliações




Figura B.243: Execução 19 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.244: Execução 19 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.245: Execução 19 - Relação entre Tempo de Execução e Qualidade da Solução

B.20**Execução 20**

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 20.




Figura B.246: Execução 20 - Comparação de Desempenho dos Algoritmos




Figura B.247: Execução 20 - Comparação das Melhores Soluções por Algoritmo




Figura B.248: Execução 20 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.249: Execução 20 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.250: Execução 20 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.251: Execução 20 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.252: Execução 20 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.253: Execução 20 - Convergência dos Algoritmos por Número de Avaliações




Figura B.254: Execução 20 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.255: Execução 20 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.256: Execução 20 - Relação entre Tempo de Execução e Qualidade da Solução

B.21
Execução 21

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 21.




Figura B.257: Execução 21 - Comparação de Desempenho dos Algoritmos




Figura B.258: Execução 21 - Comparação das Melhores Soluções por Algoritmo




Figura B.259: Execução 21 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.260: Execução 21 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.261: Execução 21 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.262: Execução 21 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.263: Execução 21 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.264: Execução 21 - Convergência dos Algoritmos por Número de Avaliações




Figura B.265: Execução 21 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.266: Execução 21 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.267: Execução 21 - Relação entre Tempo de Execução e Qualidade da Solução

B.22

Execução 22

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 22.




Figura B.268: Execução 22 - Comparação de Desempenho dos Algoritmos




Figura B.269: Execução 22 - Comparação das Melhores Soluções por Algoritmo




Figura B.270: Execução 22 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.271: Execução 22 - Convergência dos Algoritmos por Número de Avaliações




Figura B.272: Execução 22 - Relação entre Tempo de Execução e Qualidade da Solução

B.23

Execução 23

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 23.




Figura B.273: Execução 23 - Comparação de Desempenho dos Algoritmos




Figura B.274: Execução 23 - Comparação das Melhores Soluções por Algoritmo




Figura B.275: Execução 23 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.276: Execução 23 - Convergência dos Algoritmos por Número de Avaliações




Figura B.277: Execução 23 - Relação entre Tempo de Execução e Qualidade da Solução

B.24

Execução 24

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 24.




Figura B.278: Execução 24 - Comparação de Desempenho dos Algoritmos




Figura B.279: Execução 24 - Comparação das Melhores Soluções por Algoritmo




Figura B.280: Execução 24 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.281: Execução 24 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.282: Execução 24 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.283: Execução 24 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.284: Execução 24 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.285: Execução 24 - Convergência dos Algoritmos por Número de Avaliações




Figura B.286: Execução 24 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.287: Execução 24 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.288: Execução 24 - Relação entre Tempo de Execução e Qualidade da Solução

B.25**Execução 25**

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 25.




Figura B.289: Execução 25 - Comparação de Desempenho dos Algoritmos




Figura B.290: Execução 25 - Comparação das Melhores Soluções por Algoritmo




Figura B.291: Execução 25 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.292: Execução 25 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.293: Execução 25 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.294: Execução 25 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.295: Execução 25 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.296: Execução 25 - Convergência dos Algoritmos por Número de Avaliações




Figura B.297: Execução 25 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.298: Execução 25 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.299: Execução 25 - Relação entre Tempo de Execução e Qualidade da Solução

B.26**Execução 26**

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 26.




Figura B.300: Execução 26 - Comparação de Desempenho dos Algoritmos




Figura B.301: Execução 26 - Comparação das Melhores Soluções por Algoritmo




Figura B.302: Execução 26 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.303: Execução 26 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.304: Execução 26 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.305: Execução 26 - Convergência dos Algoritmos por Número de Avaliações




Figura B.306: Execução 26 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.307: Execução 26 - Relação entre Tempo de Execução e Qualidade da Solução

B.27

Execução 27

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 27.




Figura B.308: Execução 27 - Comparação de Desempenho dos Algoritmos




Figura B.309: Execução 27 - Comparação das Melhores Soluções por Algoritmo




Figura B.310: Execução 27 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.311: Execução 27 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.312: Execução 27 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.313: Execução 27 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.314: Execução 27 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.315: Execução 27 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.316: Execução 27 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.317: Execução 27 - Convergência dos Algoritmos por Número de Avaliações




Figura B.318: Execução 27 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.319: Execução 27 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.320: Execução 27 - Convergência do Algoritmo PSO – Soluções Viáveis




Figura B.321: Execução 27 - Análise da Distribuição de Soluções Viáveis




Figura B.322: Execução 27 - Relação entre Tempo de Execução e Qualidade da Solução

B.28

Execução 28

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 28.




Figura B.323: Execução 28 - Comparação de Desempenho dos Algoritmos




Figura B.324: Execução 28 - Comparação das Melhores Soluções por Algoritmo




Figura B.325: Execução 28 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.326: Execução 28 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.327: Execução 28 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.328: Execução 28 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.329: Execução 28 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.330: Execução 28 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.331: Execução 28 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.332: Execução 28 - Convergência dos Algoritmos por Número de Avaliações




Figura B.333: Execução 28 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.334: Execução 28 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.335: Execução 28 - Convergência do Algoritmo PSO – Soluções Viáveis




Figura B.336: Execução 28 - Análise da Distribuição de Soluções Viáveis




Figura B.337: Execução 28 - Relação entre Tempo de Execução e Qualidade da Solução

B.29

Execução 29

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 29.




Figura B.338: Execução 29 - Comparação de Desempenho dos Algoritmos




Figura B.339: Execução 29 - Comparação das Melhores Soluções por Algoritmo




Figura B.340: Execução 29 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.341: Execução 29 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.342: Execução 29 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.343: Execução 29 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.344: Execução 29 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.345: Execução 29 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.346: Execução 29 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.347: Execução 29 - Convergência dos Algoritmos por Número de Avaliações




Figura B.348: Execução 29 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.349: Execução 29 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.350: Execução 29 - Convergência do Algoritmo PSO – Soluções Viáveis




Figura B.351: Execução 29 - Análise da Distribuição de Soluções Viáveis




Figura B.352: Execução 29 - Relação entre Tempo de Execução e Qualidade da Solução

B.30**Execução 30**

As Figuras desta Seção reúnem comparações de soluções, métricas, curvas de convergência, distribuição de soluções viáveis e a relação tempo vs. qualidade para a Execução 30.




Figura B.353: Execução 30 - Comparação de Desempenho dos Algoritmos




Figura B.354: Execução 30 - Comparação das Melhores Soluções por Algoritmo




Figura B.355: Execução 30 - Comparação das 4 Melhores Soluções Distintas (DE)




Figura B.356: Execução 30 - Comparação das 4 Melhores Soluções Distintas (GA)




Figura B.357: Execução 30 - Comparação das 4 Melhores Soluções Distintas (PSO)




Figura B.358: Execução 30 - Divisão Ótima do Poço (DE - Differential Evolution)




Figura B.359: Execução 30 - Divisão Ótima do Poço (GA - Algoritmo Genético)




Figura B.360: Execução 30 - Divisão Ótima do Poço (PSO - Particle Swarm Optimization)




Figura B.361: Execução 30 - Convergência dos Algoritmos ao Longo do Tempo




Figura B.362: Execução 30 - Convergência dos Algoritmos por Número de Avaliações




Figura B.363: Execução 30 - Convergência do Algoritmo DE – Soluções Viáveis




Figura B.364: Execução 30 - Convergência do Algoritmo GA – Soluções Viáveis




Figura B.365: Execução 30 - Convergência do Algoritmo PSO – Soluções Viáveis




Figura B.366: Execução 30 - Análise da Distribuição de Soluções Viáveis




Figura B.367: Execução 30 - Relação entre Tempo de Execução e Qualidade da Solução

C

Exemplo de Arquivo LAS Corretamente Formatado

Este apêndice apresenta um arquivo LAS corretamente formatado.

```
1 # 10/30/2000 11:16:43 Updated by the Kansas Geological Survey
2 # #KGS#ID: 01S02E/1020069094
3 # #KGS#INPUT_FILE: /home/crude2_3/WellLogs/Doveton-Dakota_2000_10_30/
   gaydusek.las.las
4 ~VERSION INFORMATION
5 VERS . 2.0: CWLS log ASCII Standard -VERSION 2.0
6 WRAP . NO: One line per depth step
7 ~WELL INFORMATION
8 #MNEM.UNIT DATA DESCRIPTION OF MNEMONIC
9 #-----
10 STRT .F 50.5000: Start Depth
11 STOP .F 525.0000: Stop Depth
12 STEP .F 0.5000: Step Length
13 NULL . -999.0000: Null Value
14 COMP . KANSAS GEOLOGICAL SURVEY: Company
15 WELL . GAYDUSEK W II: Well
16 FLD . WILDCAT: Field
17 LOC . 10-1S-2E: Location
18 LOC1 . NW SW NW: Location Line 1
19 COUN . WASHINGTON: County
20 STAT . KANSAS: State
21 CTRY . USA: Country
22 SRVC . SCHLUMBERGER: Service Company
23 DATE . 29-NOVEMBER-1989: Log date
24 ~CURVE INFORMATION
25 #MNEM.UNIT CURVE DESCRIPTION
26 #-----
27 DEPT .F : Depth
28 CALI .IN : Caliper
29 SGR .GAPI : Total Gamma-Ray
30 CGR .GAPI : Computed Gamma Ray (Th plus K)
31 THOR .PPM : Thorium
32 URAN .PPM : Uranium
```

```

33 POTA .PERC : Potassium
34 ILD .OHMM : Deep Induction Resistivity
35 ILM .OHMM : Medium Induction Resistivity
36 SFLU .OHMM : Spherically-focussed Resistivity
37 PEF .B/E : Photo-Electric Factor
38 NPHI .PERC : Neutron Porosity (ls equiv.)
39 RHOB .GM/CC : Bulk Density
40 ~PARAMETER INFORMATION
41 #MNEM.UNIT VALUE DESCRIPTION
42 #-----
43 EGL .F 1599.0: Elevation Of Ground Level
44 LMF . GL: Log Measured From
45 TD .F 534.0: Total Depth
46 BHT .DEGF 60.0: Bottom Hole Temperature
47 BS .IN 6.25: Bit Size
48 MUD . FRESH: Mud Type
49 RM .OHMM 30.00: Mud Resistivity
50 EMT .DEGF 35.0: Mud meas. temperature
51 RMF .OHMM NM: Mud Filtrate Resistivity
52 MFT .DEGF NM: Mud Filtr. meas. temp.
53 # CURVE DATA. :
54 ~A DEPT CALI SGR CGR THOR URAN POTA ILD ILM SFLU PEF NPHI RHOB
55 50.500 5.902 145.146 24.131 2.477 13.727 .701 18.533 17.162
    2000.000 3.938 .098 2.120
56 51.000 5.895 150.785 28.006 2.884 13.927 .811 19.029 19.305
    1955.824 3.924 .049 2.100
57 51.500 5.895 155.732 31.508 3.259 14.091 .909 18.660 20.851
    1955.826 3.861 .049 2.084
58 52.000 5.895 154.033 30.359 3.149 14.028 .874 17.425 21.394
    1955.826 3.629 .244 2.074
59 52.500 5.895 169.844 40.371 4.755 14.686 1.022 16.477 20.181
    2000.001 3.658 3.467 2.064
60 53.000 5.895 169.541 40.079 4.702 14.685 1.019 15.248 17.972
    2000.000 3.770 19.336 2.072
61 53.500 5.898 169.768 40.038 4.666 14.715 1.026 13.974 15.160
    1955.824 3.875 30.713 2.089
62 54.000 5.898 168.309 38.872 4.567 14.682 .987 13.224 12.332
    1730.914 3.791 39.893 2.095
63 54.500 5.898 160.731 33.333 3.888 14.451 .853 12.696 10.682
    1636.808 3.805 38.086 2.096
64 55.000 5.895 165.682 36.634 4.263 14.638 .940 11.633 10.824

```

	582.271 3.844 38.281 2.087
65	55.500 5.891 166.195 36.876 4.335 14.669 .935 11.243 10.629
	2000.043 3.951 35.107 2.085
66	56.000 5.902 157.681 31.251 3.636 14.341 .802 11.467 10.239
	1836.508 3.869 34.912 2.102
67	56.500 5.891 135.590 16.971 2.167 13.455 .388 11.848 11.381
	2000.005 3.465 36.377 2.142
68	57.000 5.891 137.413 18.026 2.352 13.542 .400 12.789 14.560
	1955.824 3.461 39.258 2.133
69	57.500 5.859 147.492 24.680 3.385 13.931 .506 14.364 18.033
	2000.001 3.430 40.820 2.099
70	58.000 5.867 149.641 26.062 3.578 14.018 .534 14.961 19.697
	1955.824 3.684 43.506 2.069
71	58.500 5.859 158.219 30.183 4.284 14.523 .584 16.050 20.851
	1955.826 3.664 41.455 2.068
72	59.000 5.863 164.683 33.897 4.657 14.835 .694 17.476 21.832
	1955.826 3.738 38.428 2.080
73	59.500 5.871 184.546 30.118 4.123 17.517 .620 18.511 19.807
	1955.826 3.861 36.230 2.101
74	60.000 5.867 186.331 31.247 4.209 17.591 .660 18.924 19.375
	1955.826 3.707 38.574 2.110
75	60.500 5.883 190.721 34.024 4.510 17.774 .737 19.138 20.650
	1955.826 3.580 42.139 2.099
76	61.000 5.895 191.975 34.570 4.585 17.854 .748 18.719 22.149
	1955.826 3.613 41.211 2.068
77	61.500 5.910 182.661 27.854 3.957 17.560 .538 18.142 22.714
	2000.001 3.697 40.625 2.078
78	62.000 5.910 156.055 4.390 2.340 17.203 -.340 17.775 21.876
	2000.000 3.926 36.084 2.106
79	62.500 5.902 157.206 4.954 2.417 17.270 -.328 17.691 21.099
	1955.824 3.857 36.377 2.154
80	63.000 5.902 175.246 15.961 3.432 18.068 .020 17.189 21.182
	2000.001 3.865 37.207 2.135
81	63.500 5.918 212.148 49.607 5.197 18.437 1.415 16.003 18.470
	2000.000 3.793 40.283 2.102
82	64.000 5.930 218.102 53.858 5.687 18.630 1.525 14.378 15.627
	2000.000 3.633 42.920 2.052
83	64.500 5.922 222.955 56.744 6.016 18.853 1.601 12.621 12.807
	28.702 3.682 41.650 2.045
84	65.000 5.930 230.055 61.889 6.559 19.075 1.747 11.779 10.523
	20.456 3.699 41.797 2.048

85	65.500	5.922	200.865	44.503	5.187	17.736	1.140	11.198	9.749	
	22.522	3.758	39.111	2.066						
86	66.000	5.926	189.674	38.519	4.602	17.145	.959	10.409	9.960	53.597
	3.604	40.137	2.084							
87	66.500	5.934	191.698	39.993	4.856	17.208	.976	9.753	10.131	43.523
	3.549	43.408	2.089							
88	67.000	5.926	194.598	42.144	5.168	17.293	1.016	8.913	9.661	12.966
	3.312	47.656	2.074							
89	67.500	5.926	192.149	40.896	5.064	17.157	.974	8.045	8.935	11.226
	3.328	48.779	2.039							

D

Tabela de Correlação de Parâmetros de Perfis

Este apêndice apresenta a tabela de correlação de parâmetros de perfis com suas principais utilizações.

Parâmetro	Nome Completo	Principais Utilizações
DEPT	Depth	Profundidade do poço em relação a uma profundidade de referência.
CALI	Caliper	Diâmetro interno do poço, importante para avaliação de integridade do poço e dimensionamento de ferramentas.
SGR	Spectral Gamma Ray	Medição de radiação natural, útil na identificação de litologias e correlação estratigráfica.
CGR	Spectral Gamma Ray (Uranium Corrected)	Medição de radiação de urânio corrigida, usada para estimar a concentração de urânio nas formações geológicas.
THOR	Thorium	Medição de radiação de tório, importante para análises geoquímicas e de correlação estratigráfica.
URAN	Uranium	Medição de radiação de urânio, útil para identificação de litologias e análises geológicas.
POTA	Potassium	Medição de radiação de potássio, auxilia na identificação de litologias e análises geoquímicas.
ILD	Deep Induction Resistivity	Resistividade de indução profunda, utilizada para estimar a resistividade do fluido no poço.
ILM	Medium Induction Resistivity	Resistividade de indução média, auxilia na caracterização das formações geológicas e avaliação de fluidos.
SFLU	Shallow Resistivity	Resistividade superficial, importante para identificação de fluidos e determinação de porosidade.
PEF	Photoelectric Factor	Fator fotoelétrico, utilizado para estimar a mineralogia e a porosidade das formações.
NPHI	Neutron Porosity	Porosidade de nêutrons, usada para quantificar a quantidade de fluido nas formações geológicas.
RHOB	Bulk Density	Densidade <i>bulk</i> , importante para estimar a densidade das rochas e avaliar a composição das formações.
BS	Bit Size	Tamanho da broca, utilizado para monitorar a largura do poço durante a perfuração e para avaliar a integridade do poço.

Tabela D.1: Tabela de Correlação de Parâmetros de Perfis