

**UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC**  
**CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA – PPGEM**

**JESSICA DE SOUZA BRUGOGNOLLE**

**OTIMIZAÇÃO APLICADA A MODELAGEM DE PROCESSOS GEOLÓGICOS**

**JOINVILLE**

**2022**

**JESSICA DE SOUZA BRUGOGNOLLE**

**OTIMIZAÇÃO APLICADA A MODELAGEM DE PROCESSOS GEOLÓGICOS**

Dissertação apresentada como requisito parcial para obtenção do título de mestre em Engenharia Mecânica pelo Programa de Pós-Graduação em Engenharia Mecânica do Centro de Ciências Tecnológicas – CCT, da Universidade do Estado de Santa Catarina – Udesc.

Orientador: Prof. Dr. Eduardo Lenz Cardoso

Co-orientadora: Profa. Dra. Lindaura Maria Steffens

**JOINVILLE**

**2022**

**Ficha catalográfica elaborada pelo programa de geração automática da  
Biblioteca Setorial do CCT/UDESC,  
com os dados fornecidos pelo(a) autor(a)**

Brugognolle, Jessica  
OTIMIZAÇÃO APLICADA A MODELAGEM DE  
PROCESSOS GEOLÓGICOS / Jessica Brugognolle. -- 2022.  
118 p.

Orientador: Eduardo Lenz  
Coorientadora: Lindaura Steffens  
Dissertação (mestrado) -- Universidade do Estado de  
Santa Catarina, Centro de Ciências Tecnológicas, Programa  
de Pós-Graduação em Engenharia Mecânica, Joinville, 2022.

1. Otimização. 2. Modelo geológico. 3. Simulação. 4.  
Função objetivo. 5. Calibração. I. Lenz, Eduardo. II. Steffens,  
Lindaura. III. Universidade do Estado de Santa Catarina,  
Centro de Ciências Tecnológicas, Programa de  
Pós-Graduação em Engenharia Mecânica. IV. Título.

**JESSICA DE SOUZA BRUGOGNOLLE**

**OTIMIZAÇÃO APLICADA A MODELAGEM DE PROCESSOS GEOLÓGICOS**

Dissertação apresentada como requisito parcial para obtenção do título de mestre em Engenharia Mecânica pelo Programa de Pós-Graduação em Engenharia Mecânica do Centro de Ciências Tecnológicas – CCT, da Universidade do Estado de Santa Catarina – Udesc.

Orientador: Prof. Dr. Eduardo Lenz Cardoso

Co-Orientadora: Profa. Dra. Lindaura Maria Steffens

**BANCA EXAMINADORA**

Prof. Dra. Lindaura Maria Steffens

CESFI/UDESC

Presidente

Membros:

Prof. Dr. Luiz Adolfo Hegele Junior

CCT/UDESC

Titular

Dr. Olinto Gomes de Souza Júnior

Petrobras

Titular

Dr. Luis Fernando Lamas de Oliveira

Petroleum Experts Ltda

Suplente

Balneário Camboriú, 15 de agosto de 2022.

Dedico este trabalho aos meus pais, Maria e Mauricio, e à toda minha família pelo incentivo e apoio que sempre me deram.

## **AGRADECIMENTOS**

Em primeiro lugar agradeço a Deus, por me dar o dom da vida e me permitir vivenciar a experiência do mestrado e da pesquisa.

Agradeço aos meus pais, Maria e Mauricio, por serem tão presentes e participarem de todo esse trajeto, sempre me dando forças e me ensinando valores que carregarei para o resto da vida.

À minha família, Mariana, Murilo, Lucas, Érica, Fabiola e Sidney, pelo apoio incondicional de sempre e por alegrarem meus dias mesmo com a distância.

Ao Gisleude, por estar ao meu lado em momentos difíceis me acalmando e em momentos felizes compartilhando as vitórias alcançadas. Obrigada por toda ajuda de sempre.

À Dra. Lindaura Steffens e ao Dr. Luis Lamas, por acreditarem na minha capacidade e me auxiliarem durante todo este trabalho. Estendo o agradecimento a todos professores e pesquisadores que compartilharam seus conhecimentos e experiências.

Agradeço à Universidade do Estado de Santa Catarina e todos seus colaboradores que fazem possível esse ambiente de aprendizado e formação.

Meu agradecimento à Petrobras por financiar esta pesquisa e dar todo o suporte necessário para a realização deste trabalho.

“Nada é inventado, já que está escrito primeiro na natureza. A originalidade consiste em voltar à origem.” (Antoni Gaudí)

## RESUMO

Tratando-se da simulação de reservatórios na indústria de óleo e gás, é necessário obter um modelo geológico do campo para reproduzir os fluxos de hidrocarbonetos nos reservatórios e tomar decisões, entre outros aspectos, acerca da viabilidade econômica. Esses modelos integram dados (poços, sísmicos) e interpretações geológicas. Os *Stratigraphic Forward Models* (SFM), que consistem na modelagem de processos geológicos considerando os princípios de conservação de massa e energia, reproduzem os processos da bacia sedimentar para fornecer a distribuição de fácies da mesma e são uma opção cada vez mais usada para a modelagem. No entanto, por serem simulações de processos geológicos, os resultados não necessariamente horam as informações conhecidas (poços e sísmica). Assim os modelos precisam ser calibrados para que os resultados sejam o mais coerente possível com os dados disponíveis. Este trabalho visa realizar essa calibração por meio de uma função objetivo (FO) que traduz, de forma clara e quantitativa, o grau de similaridade entre os resultados numéricos dos SFM e os dados de poços. Assim, foi desenvolvida uma FO especificamente para a calibração desses modelos, a qual busca a melhor correlação entre os dados observados nos poços e os resultados da simulação, levando a um valor que traduz a similaridade geológica entre esses dados. Como os resultados da simulação e os dados de poços de hidrocarbonetos não possuem o mesmo número de camadas, é necessário realizar um agrupamento das camadas do poço de hidrocarbonetos para calcular a FO. Visto que há muitas combinações possíveis de realizar tal agrupamento demandaria muito tempo computacional para realizar todas as possibilidades. Portanto, aplica-se métodos de otimização para que o cálculo da FO seja obtido em um tempo operacionalmente viável. A partir disso então é desenvolvida e implementada uma ferramenta de ajuste através de um algoritmo de inversão por meio de métodos de otimização. Os métodos de otimização utilizados concentram-se em meta-heurísticas, como algoritmo genético (AG) e *particle swarm optimization* (PSO). Buscando validar a metodologia proposta e desenvolvida foram realizados vários testes, tanto para avaliar o desempenho da FO como da ferramenta de calibração, a fim de encontrar os melhores parâmetros de entrada para os SFM. Os resultados obtidos foram excelentes na maioria dos casos, levando a modelos mais próximos dos dados observados nos poços em um tempo computacional praticável.

**Palavras-chave:** Otimização. Modelo geológico. Simulação. Função objetivo. Calibração.

## ABSTRACT

When it comes to reservoir simulation in the oil and gas industry, it is necessary to obtain a geological model of the field to reproduce the hydrocarbon flows in the reservoirs and make decisions, among other aspects, regarding economic viability. These models integrate data (wells, seismic) and geological interpretations. Stratigraphic Forward Models (SFM), which consist of modeling geological processes considering the principles of conservation of mass and energy, provide the distribution of sedimentary basin facies and are an increasingly used option for modeling. However, since they are simulations of geological processes, the results do not necessarily match known information (wells and seismic). Thus, the models need to be calibrated for the results to be as consistent as possible with the available data. This work aims to perform this calibration through an objective function (OF) that translates, in a clear and quantitative way, the degree of similarity between the numerical results of the SFM and the well data. Thus, an OF was specifically developed for the calibration of these models, which pursues the best correlation between the observed well data and the simulation results, leading to a value that translates the geological similarity between these data. Since the simulation results and the geological well data do not have the same number of layers, it is necessary to perform a grouping of the geological well layers to calculate the OF. Because there is a lot of possible combinations to perform such a grouping, it would demand a lot of computational time to perform all of them. Hence, optimization methods are applied so that the OF calculation is obtained in an operationally feasible time. Thereafter a fitting tool is developed and implemented through an inversion algorithm by using optimization methods. The optimization methods used are centered on meta-heuristics, such as genetic algorithm (GA) and particle swarm optimization (PSO). With the goal of validating the proposed and developed methodology, several tests were performed, both to evaluate the performance of the OF and the calibration tool, in order to find the best input parameters for the SFMs. The results obtained were excellent in most cases, leading to models closer to the observed data in the wells in a feasible computational time.

**Keywords:** Optimization. Geological model. Simulation. Objective function. Calibration.

## LISTA DE ILUSTRAÇÕES

Figura 2.1 - Uma sucessão de canais representada por símbolos de litofácies e um gráfico de Cant e Walker (1976) (à esquerda) e sua descrição sintática (uma sequência de códigos).....	34
Figura 2.2 – Representações de funções convexas (a) e (b) e função não-convexa (c). .....	38
Figura 3.1 – Fluxograma ilustrativo do processo de metodologia para elaboração da função objetivo, calibração e aplicação de métodos de otimização.....	50
Figura 3.2 – Fluxograma ilustrativo do processo de calibração utilizando métodos de otimização.....	51
Figura 3.3 - Fluxograma ilustrativo do processo de cálculo da função objetivo utilizando métodos de otimização (ilustrados dentro do contêiner). .....	51
Figura 4.1 - Poço com 21 camadas (esquerda) e dados simulados com 6 células (direita).....	54
Figura 4.2 - Correlação entre os dados simulados (esquerda) e as camadas de poços agrupadas como resultado da função objetivo proposta (direita). ..	56
Figura 4.3 – Inicialização da otimização através do algoritmo genético com cada célula recebendo uma espessura aleatória (cuja soma corresponde a espessura total do poço) para a criação das “camadas” de maneira a permitir a comparação com o poço simulado. Cada uma das 5 colunas representa a espessura das camadas e cada uma das 10 linhas representa um indivíduo da geração atual.....	60
Figura 4.4 – Primeira população a apresentar uma solução candidata que satisfaz a restrição, representada pelo indivíduo 1. ....	61
Figura 4.5 - Seleção dos indivíduos que apresentaram menor valor da função objetivo para iniciar a geração seguinte. ....	61
Figura 4.6 - Representação de alguns cruzamentos para os indivíduos 4 a 8. ....	62
Figura 4.7 - Representação de mutações para os indivíduos 5, 6 e 8. ....	62
Figura 4.8 - Inicialização da otimização através do PSO com cada célula recebendo uma espessura aleatória (cuja soma corresponde a espessura total do poço) para a criação das camadas, de maneira a permitir a comparação com o poço simulado. Cada uma das 5 colunas representa a espessura	

das camadas e cada uma das 10 linhas representa um indivíduo da geração atual. ....	64
Figura 4.9 – Resultado do cálculo das velocidades das partículas da geração inicial do método. ....	65
Figura 4.10 - Resultado do cálculo das velocidades das partículas da próxima geração do método. ....	66
Figura 4.11 - Resultado do cálculo do valor das partículas da próxima geração do método. Cada uma das 5 colunas representa a camada simulada e cada uma das 10 linhas representa uma partícula da geração em questão. ..	67
Figura 4.12 - Primeira população a apresentar uma solução candidata que satisfaz a restrição, representada pelo indivíduo 1 destacado em vermelho. ....	67
Figura 5.1 – Representação da localização dos três poços do <i>Mixed Model</i> . ....	69
Figura 5.2 – Todas as fácies definidas no <i>Mixed Model</i> a partir de intervalos de valores de propriedades. ....	70
Figura 5.3 – Sequência geológica de dois poços iguais, observado à esquerda e simulado à direita. ....	76
Figura 5.4 – Gráfico do parâmetro incerto ‘coeficiente de difusão de areia’ pelo valor da FO total com três pontos destacados: distante, intermediário e melhor, com seus respectivos erros relativos. ....	78
Figura 5.5 - Gráfico do parâmetro incerto ‘altura para cálculo do volume de sedimentos da fonte 1’ pelo valor da FO total com três pontos destacados: distante, intermediário e melhor, com seus respectivos erros relativos. ....	78
Figura 5.6 - Sequências dos poços GF20, DR8 e AB3 obtidas com diferentes valores para o parâmetro incerto ‘coeficiente de difusão de areia’. Da esquerda para a direita para cada poço: distante da referência, melhor valor (destacado com um contorno em vermelho), intermediário e poço observado. ....	80
Figura 5.7 - Sequências dos poços GF20, DR8 e AB3 obtidas com diferentes valores para o parâmetro incerto ‘altura para o cálculo do volume de sedimento da fonte 1’. Da esquerda para a direita para cada poço: distante da referência, melhor valor (destacado com um contorno em vermelho), intermediário e poço observado. ....	81

Figura 5.8 - Gráfico do parâmetro incerto ‘coeficiente de difusão de areia’ no topo para o PSO (esquerda- com pontos destacados para avaliação das sequências dos poços) e o AG (direita) e do parâmetro incerto ‘altura para o cálculo do volume de sedimento da fonte 1’ na base para o PSO (esquerda- com pontos destacados para avaliação das sequências dos poços) e o AG (direita).....	84
Figura 5.9 - Sequências do poço GF20, DR8 e AB3, correspondentes aos valores ótimos obtidos pelos algoritmos PSO e AG para o parâmetro incerto ‘coeficiente de difusão de areia’. Da esquerda para a direita: melhor valor calibrado pelo PSO, melhor valor calibrado pelo AG e poço observado.	86
Figura 5.10 - Sequências do poço GF20, DR8 e AB3, correspondentes aos valores ótimos obtidos pelos algoritmos PSO e AG para o parâmetro incerto ‘altura para o cálculo do volume de sedimento da fonte 1’. Da esquerda para a direita: melhor valor calibrado pelo PSO, melhor valor calibrado pelo AG e poço observado. ....	87
Figura 5.11 - Sequências dos poços GF20, DR8 e AB3 correspondentes a diferentes valores para o parâmetro incerto ‘coeficiente de difusão de areia’. Da esquerda para a direita para cada poço: distante da referência, melhor valor (destacado com um contorno em vermelho), intermediário e poço observado. ....	89
Figura 5.12 - Sequências dos poços GF20, DR8 e AB3 correspondentes a diferentes valores para o parâmetro incerto ‘altura para o cálculo do volume de sedimento da fonte 1’. Da esquerda para a direita para cada poço: distante da referência, melhor valor (destacado com um contorno em vermelho), intermediário e poço observado.....	90
Figura 5.13 - Gráfico do comportamento da FO para o parâmetro incerto ‘coeficiente de difusão de areia’ obtidos pelo PSO (esquerda) e AG (direita) com intervalo inferior (topo) e superior (base).....	91
Figura 5.14 - Gráfico do comportamento da FO para o parâmetro incerto ‘altura para o cálculo do volume de sedimento da fonte 1’ obtidos pelo PSO (esquerda) e AG (direita) com intervalo inferior (topo) e superior (base). ....	92

Figura 5.15 - Gráficos dos quatro parâmetros incertos de altura para o cálculo de vazão fluvial para duas fontes diferentes pelo valor de suas respectivas FO, utilizando PSO como método de otimização da calibração. ....	95
Figura 5.16 - Gráficos dos quatro parâmetros incertos de altura para o cálculo de vazão fluvial para duas fontes diferentes pelo valor de suas respectivas FO, utilizando AG como método de otimização da calibração.....	96
Figura 5.17 - Sequências dos poços GF20, DR8 e AB3 obtidas com diferentes valores para os quatro parâmetros incertos de 'altura para o cálculo de vazão fluvial'. Da esquerda para a direita para cada poço: distante da referência, poço observado e melhor valor encontrado pelo PSO.....	97
Figura 5.18 - Sequências dos poços GF20, DR8 e AB3 com diferentes valores para quatro parâmetros incertos de 'altura para o cálculo de vazão fluvial'. Da esquerda para a direita para cada poço: distante da referência, poço observado e melhor valor encontrados pelo AG.....	98
Figura 5.19 - Gráficos de quatro parâmetros incertos de altura para o cálculo de vazão fluvial para duas fontes diferentes pelo valor de suas respectivas FO, utilizando PSO como método de otimização da calibração. ....	101
Figura 5.20 - Gráficos dos quatro parâmetros incertos de altura para o cálculo de vazão fluvial para duas fontes diferentes pelo valor de suas respectivas FO, utilizando AG como método de otimização da calibração.....	102
Figura 5.21 - Sequências dos poços GF20, DR8 e AB3 correspondentes a diferentes valores para quatro parâmetros incertos de 'altura para o cálculo de vazão fluvial'. Da esquerda para a direita para cada poço: melhor valor, mais distante da referência encontrados pelo PSO e poço observado.	103
Figura 5.22 - Sequências dos poços GF20, DR8 e AB3 correspondentes a diferentes valores para quatro parâmetros incertos de 'altura para o cálculo de vazão fluvial'. Da esquerda para a direita para cada poço: melhor valor, mais distante da referência encontrados pelo AG e poço observado. ...	104

## LISTA DE TABELAS

Tabela 2.1 - Comparação entre os métodos empregados por cada autor, com vantagens e desvantagens.....	31
Tabela 4.1 - Ilustração dos agrupamentos possíveis (colunas) dos dados de poço para cada camada simulada (linhas) para o exemplo sintético de dados de poço com 21 camadas e dados simulados com 6 camadas.....	55
Tabela 5.1 - Tabela de definição de fácies utilizada no <i>Mixed Model</i> . ....	70
Tabela 5.2– Comparação entre resultados da Força Bruta e os algoritmos de Dijkstra, AG e PSO. ....	73
Tabela 5.3 - Comparação dos resultados da força bruta na calibração de um parâmetro inversível. ....	77
Tabela 5.4 - Comparação entre resultados da calibração de um parâmetro inversível pelos algoritmos AG e PSO. ....	83
Tabela 5.5 - Comparação entre resultados da calibração de quatro parâmetros inversíveis pelos algoritmos AG e PSO. ....	93
Tabela 5.6 - Comparação entre resultados da calibração de quatro parâmetros inversíveis pelos algoritmos AG e PSO com $\alpha$ e $\beta$ iguais a 1 e ponderados pelas equações.....	100

## LISTA DE ABREVIATURAS E SIGLAS

3D	Tridimensional
AG	Algoritmo Genético
CCT	Centro de Ciência Tecnológicas
CESFI	Centro de Educação Superior da Foz do Itajaí
CILAMCE	Congresso Ibero-Latino Americano de Métodos Computacionais em Engenharia
DIONISOS	<i>Diffusive Oriented—Normal and Inverse—Simulation of Sedimentation</i>
EPET	Departamento de Engenharia de Petróleo
FO	Função Objetivo
L-BFGS-B	<i>Limited Memory Quasi-Newton</i>
PSO	<i>Particle Swarm Optimization</i>
RJMCMC	<i>Reversible-jump Markov chain Monte Carlo</i>
TNC	<i>Truncated Newton method</i>
SFM	<i>Stratigraphic Forward Models</i>
SLSQP	<i>Sequential Least Squares Programming</i>
Udesc	Universidade do Estado de Santa Catarina

## LISTA DE SÍMBOLOS

$d^A$	Distância entre atributos das sequências
$d^{AS}$	Distância calculada para cada poço
$d^E$	Distância euclidiana
$d^F$	Distância entre fácies das sequências
$d^T$	Distância total ponderada entre todos os poços
$g$	Agrupamento referente ao menor valor da função objetivo encontrado na população anterior
$k$	Iteração atual
$l_p$	Espessura total de interesse do poço de hidrocarbonetos
$l_s$	Espessura total de interesse das células simuladas
$n$	Número total de parâmetros
$n_F$	Número total de fácies no agrupamento
$n_p$	Número de camadas do poço
$n_{pi}$	Número total de parâmetros inversíveis
$p$	Agrupamento referente ao menor valor da função objetivo encontrado na população atual
$P_i$	Parâmetro $i$
$r$	Número aleatório
$s$	Número de camadas simuladas
$v_{ij}$	Velocidade da partícula $i$ na dimensão $j$
$v_{max}$	Velocidade máxima
$v_{min}$	Velocidade mínima
$x_{ij}$	Agrupamento da partícula $i$ na dimensão $j$
$\alpha$	Coeficiente de peso para a distância entre fácies
$\beta$	Coeficiente de peso para a distância entre atributos
$\mu$	Constante da penalidade
$\rho$	Penalidade da restrição
$\phi_g$	Fator de escala para se afastar da melhor posição conhecida da população
$\phi_p$	Fator de escala para se afastar da melhor posição conhecida da partícula

$\Omega$

Fator de escala da velocidade da partícula

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>15</b>
1.1	JUSTIFICATIVAS .....	18
1.2	HIPÓTESE .....	19
1.3	OBJETIVOS .....	20
1.4	ORGANIZAÇÃO DO TEXTO .....	20
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	<b>22</b>
2.1	MODELAGEM GEOLÓGICA .....	22
2.2	MODELAGEM ESTRATIGRÁFICA <i>FORWARD</i> .....	24
2.3	CALIBRAÇÃO .....	25
2.4	FUNÇÃO OBJETIVO .....	32
2.5	OTIMIZAÇÃO .....	36
2.6	SUMÁRIO .....	46
<b>3</b>	<b>METODOLOGIA</b> .....	<b>47</b>
<b>4</b>	<b>MÉTODOS DE OTIMIZAÇÃO APLICADOS A MODELAGEM DE PROCESSOS GEOLÓGICOS</b> .....	<b>52</b>
4.1	FUNÇÃO OBJETIVO .....	52
4.1.1	<b>FORMULAÇÃO MATEMÁTICA DA OTIMIZAÇÃO INTERNA</b> .....	<b>56</b>
4.1.2	<b>FORMULAÇÃO MATEMÁTICA DA OTIMIZAÇÃO EXTERNA</b> .....	<b>58</b>
4.2	ALGORITMO GENÉTICO .....	59
4.3	<i>PARTICLE SWARM OPTIMIZATION</i> .....	63
<b>5</b>	<b>APLICAÇÃO E RESULTADOS</b> .....	<b>68</b>
5.1	ANÁLISE DO COMPORTAMENTO DA FUNÇÃO OBJETIVO .....	71
5.1.1	<b>Casos Sintéticos</b> .....	<b>71</b>
5.1.2	<b>Validação da Função Objetivo</b> .....	<b>75</b>
5.1.3	<b>Análise do Comportamento da Função Objetivo</b> .....	<b>76</b>
5.2	ANÁLISE DO FLUXO DE TRABALHO DA CALIBRAÇÃO .....	82
5.2.1	<b>Estudo de caso 1: Calibração de um parâmetro inversível - <i>Mixed</i></b> .....	<b>83</b>
5.2.1.1	<i>Testes sobre o comportamento da FO quanto aos Intervalos de Incerteza</i> .....	91
5.2.2	<b>Estudo de caso 3: Calibração de quatro parâmetros inversíveis - <i>Mixed</i></b> <b>93</b>	
5.2.2.1	<i>Testes sobre os pesos das fácies e espessuras (<math>\alpha</math> e <math>\beta</math>) - ponderação</i> .....	99

<b>6</b>	<b>CONCLUSÕES E PERSPECTIVAS FUTURAS .....</b>	<b>106</b>
	<b>REFERÊNCIAS.....</b>	<b>109</b>

## 1 INTRODUÇÃO

A primeira etapa da fase de prospecção de petróleo é a realização do estudo geológico da bacia. Para isso, é necessária uma análise de dados geológicos e geofísicos para que se tenha um amplo conhecimento da região a fim de traçar um plano estratégico de exploração que maximize os lucros e minimize os riscos. Parte desse estudo é a reconstituição das condições de formação da área estudada através de simulações e expertise dos geólogos. (THOMAS, 2001).

A produção de petróleo a partir de reservatórios de hidrocarbonetos costuma ser avaliada e monitorada através de simulações numéricas de escoamento em meios porosos.

Essas simulações integram tanto os dados de engenharia, como número, posição e características dos poços que definem a malha de drenagem do reservatório de hidrocarbonetos, e também propriedades físicas dos fluidos e rochas.

Assim, a descrição do reservatório e a propriedades físicas a elas associadas (porosidade, permeabilidade, entre outros) são de grande importância para uma simulação dos escoamentos e as decisões que esses resultados fundamentam.

A descrição do reservatório pode ser feita através de uma representação 3D de uma malha numérica discretizada do reservatório de hidrocarbonetos real. As propriedades que vão popular este modelo vem em grande parte de dados de poços que, sozinhos, representam uma pequena proporção do reservatório inteiro. Assim, faz-se necessário o uso de métodos de extrapolação desses dados de poços para o modelo 3D inteiro. Uma técnica clássica de extrapolação faz uso de técnicas geoestatísticas e de dados sísmicos, que representam uma informação regional na mesma escala que o modelo 3D de reservatório, mas indireta das propriedades necessárias para a simulação de escoamento.

Uma limitação ligada ao uso de métodos geoestatísticos é a baixa representatividade das estimativas feitas devido ao fato de não incluir os processos geológicos que resultaram na formação do reservatório de hidrocarbonetos.

Uma outra metodologia para tentar reconstruir uma imagem realista da distribuição de propriedades num reservatório de hidrocarbonetos consiste em usar métodos de simulação numérica dos processos geológicos que resultam na deposição dos sedimentos e na formação dos reservatórios de hidrocarbonetos.

*Stratigraphic Forward Models (SFM)* são resultados de simulações que reproduzem fenômenos físicos e/ou químicos em um ambiente deposicional durante um intervalo de tempo. São utilizadas regras físicas simplificadas para simular processos geológicos, como leis de difusão para simular o transporte e a deposição de sedimentos. Os cálculos são feitos a partir de equações diferenciais com alguns parâmetros de controle, como quantidade e tipo de sedimentos, espaço de acomodação, declividade, fluxos e ondas, etc. A simulação resulta em sequências estratigráficas 3D de alguns parâmetros, como batimetria (medição científica da lâmina d'água) e proporções de sedimentos, entre outras, as quais são traduzidas para fácies.

O software utilizado para as simulações estratigráficas neste trabalho é o DionisosFlow® (BEICIP-FRANLAB, 2007), utilizado para gerar modelos estratigráficos 3D a partir da simulação de processos sedimentares com alguns parâmetros fornecidos pelo usuário, como taxa de subsidência, eustasia, aporte sedimentar, batimetria, energias de ondas, entre outros. Desta forma, o software resulta na arquitetura de fácies em um intervalo do tempo geológico (que posteriormente será convertido em espessuras), gerando um modelo da estratigrafia e sedimentologia a fim de reduzir o risco de exploração de campos de petróleo.

Os resultados dessas simulações, apesar de robustos, ainda podem divergir da realidade. Sendo necessário realizar uma calibração a fim de obter resultados mais precisos e evitar o acúmulo de incertezas nas etapas posteriores da simulação de reservatórios da indústria de petróleo. Para obter resultados mais precisos, é realizada a calibração a fim de honrar os resultados obtidos nas simulações com os dados observados nos poços. O principal problema para realizar essa calibração está diretamente ligado à definição de uma função objetivo (FO) consistente. A função objetivo nesses casos geralmente é uma medida de dissimilaridade entre o resultado da simulação e os dados observados nos poços. No caso dos SFM, também é necessário incorporar informações

geológicas para gerar resultados aceitáveis. Duan *et al.* (2001) propõem um método quantitativo para essa função objetivo, aplicando técnicas de correlações automatizadas de poços. No entanto, essa proposta não satisfaz totalmente as situações operacionais da indústria de óleo e gás, porque supõe que ambos resultados da simulação e dados observados em poços possuem a mesma resolução e número de camadas. Além disso, não leva em consideração as variações dos parâmetros ao comparar fácies. Por exemplo, a distância entre as fácies A e B será sempre a mesma, independentemente se possuem uma diferença maior ou menor quanto à proporção de sedimentos. Portanto, é necessária uma modificação para torná-la mais apta a essas situações reais de modelagem estratigráfica. Diante disso, este trabalho busca desenvolver uma função objetivo, baseada em Duan *et al.* (2001), que forneça uma medida quantitativa da dissimilaridade entre os resultados da simulação e os dados observados nos poços, de forma que o resultado seja geologicamente representativo.

Para resolver o problema de consistência entre as simulações e os dados de poços de hidrocarbonetos não possuírem o mesmo número de camadas, é possível dividir o poço de hidrocarbonetos em camadas de menor espessura e, posteriormente, agrupá-las em um número de camadas igual ao da simulação. Nota-se que esse procedimento incide em um problema de combinação, visto que há muitas maneiras de realizar tal agrupamento. Portanto, para cada agrupamento possível, calcula-se o valor da FO e o agrupamento ótimo resultante é o que gera o menor valor calculado. Desta maneira, o cálculo da função objetivo proposta pode ser encontrado através do método da Força Bruta, por exemplo. O método de Força Bruta neste contexto é dado pela realização do cálculo da função objetivo a partir de todos os possíveis candidatos à solução da mesma. No entanto, isso gera um número de execuções da função objetivo muito grande, levando a um alto custo computacional que impede sua realização pela indústria. Para solucionar esse problema é possível utilizar métodos de otimização. Esses métodos são técnicas matemáticas que visam encontrar a melhor solução em um tempo computacional praticável. As abordagens aqui utilizadas foram algoritmos de otimização estocástica baseados em meta-heurísticas, como Algoritmo Genético (AG) e *Particle Swarm Optimization* (PSO).

Os resultados obtidos por essas abordagens são comparados com a Força Bruta, quando o tempo de execução é possível, e com o algoritmo de Dijkstra, estudado e implementado por outros integrantes do projeto de pesquisa, para os demais casos; visto que ambos resultam em um mínimo global.

Portanto, este trabalho visa primeiramente desenvolver um método de cálculo da FO para obter quantitativamente o grau de dissimilaridade entre os resultados numéricos e os dados de poços. Para isso, aplica-se métodos de otimização que tornam esse processo menos custoso computacionalmente e viável para aplicação na indústria. Por fim, a FO é empregada na implementação do workflow de calibração de modelos de SFM, realizando a inversão dos parâmetros de entrada da simulação para buscar um modelo que melhor corresponda entre dados simulados e dados observados nos poços.

## 1.1 JUSTIFICATIVAS

Um ponto crucial na indústria de óleo e gás é a viabilidade econômica de projetos, fazendo com que as decisões dependam de previsões de produção de petróleo. Para isso, são gerados modelos geológicos para realizar simulações de reservatórios para reproduzir os fluxos de hidrocarbonetos. Nos casos em que se utiliza SFM, é então realizada a calibração destes a fim de honrar os dados de poços. Atualmente, o processo de ajuste é realizado manualmente por meio de tentativa e erro, ou seja, escolhe-se um conjunto de valores de parâmetros de entrada para realizar a simulação e, após isso, avalia-se os resultados de acordo com o grau de aproximação com os dados observados (poços). A partir disso, escolhe-se um novo conjunto de valores de parâmetros de entrada com o objetivo de melhorar a aproximação dos resultados de simulação com os dados observados, repetindo-se o processo até obter um resultado que honre suficientemente os dados observados nos poços. Dependendo da quantidade de poços, esse trabalho pode se tornar custoso em termos de tempos computacionais e de recursos humanos. Deste modo, este projeto visa promover uma metodologia de calibração assistida para gerar modelos geológicos mais confiáveis e fazê-lo em um tempo operacionalmente

praticável, de forma mais eficiente, automatizada e rápida do que o método de tentativa e erro.

Na literatura, há propostas de funções objetivo, porém geralmente não há representatividade geológica suficiente. Logo, este trabalho busca o desenvolvimento de uma função objetivo mais adequada, que visa estimar a similaridade entre os resultados da simulação e os dados de poço quantitativamente e que seja geologicamente representativa. Neste caso, partindo de uma função objetivo de um trabalho de referência, será desenvolvida, implementada e testada uma nova função objetivo modificada para se adequar a nova proposta e que possa atuar no fluxo de trabalho de calibração dos SFM.

O estudo se dará por meio de um levantamento bibliográfico de funções objetivos e métodos de otimização existentes e relevantes ao campo de interesse. Posteriormente, haverá o desenvolvimento de uma nova função objetivo, baseada nas anteriores e com modificações que tornem possível sua aplicação na área de petróleo, pela necessidade da representação geológica por se tratar de uma formação rochosa. Tanto o cálculo da função objetivo, como a inversão dos parâmetros de entrada na modelagem dos SFM serão executados através dos métodos de otimização estudados. E, por fim, ocorrerão testes das novas propostas para avaliar a eficiência dos métodos no problema citado.

## 1.2 HIPÓTESE

Este trabalho visa o estudo e aplicação de métodos de otimização na etapa de simulação de modelos geológicos da indústria de óleo e gás. Desta forma, tem-se a hipótese investigada e que se deseja apurar sua validação ou negação:

“É possível aplicar métodos de otimização à modelagem *forward* de processos geológicos para se obter modelos calibrados com dados de poços”.

### 1.3 OBJETIVOS

O objetivo principal deste trabalho é desenvolver e testar uma metodologia assistida capaz de executar a calibração automatizada de modelos *forward*, realizando a comparação entre dados de poços e dados simulados através de uma função objetivo.

Sendo os objetivos específicos:

- Realizar o estudo das metodologias de ajuste entre dados observados e resultados da simulação SFM.
- Estabelecer uma função objetivo como medida quantitativa de similaridade entre os dados de poços e dados simulados e que seja representativa geologicamente.
- Estudo de métodos de otimização.
- Aplicar métodos de otimização para obter resultados em um tempo operacionalmente viável.
- Desenvolver uma ferramenta de ajuste de modelos geológicos de reservatórios de petróleo.
- Incorporar essa metodologia no fluxo de trabalho de modelagem de reservatórios.

### 1.4 ORGANIZAÇÃO DO TEXTO

O Capítulo 1 apresenta a introdução do trabalho, com a descrição do problema abordado e explicação sucinta dos tópicos desenvolvidos. Este capítulo também conta com a justificativa da proposta, a elaboração da hipótese e os objetivos a serem alcançados.

O Capítulo 2 dedica-se à revisão bibliográfica dos temas aqui abordados, modelagem geológica, modelagem estratigráfica *forward*, calibração, função objetivo e otimização, expondo o que foi estudado por alguns autores e as propostas existentes na literatura atualmente, servindo como base para o desenvolvimento de novas abordagens apresentadas nesse trabalho.

O Capítulo 3 trata da metodologia utilizada para o desenvolvimento do trabalho, apresentando o fluxograma dos métodos.

O Capítulo 4 discorre sobre os métodos de otimização aplicados a modelagem de processos geológicos em si, apresentando o desenvolvimento da nova proposta de função objetivo juntamente com a utilização da otimização na simulação de reservatórios na indústria de óleo e gás.

O Capítulo 5 destina-se a aplicar a nova proposta em casos sintéticos, *benchmark tests* e apresentando os resultados obtidos, suas implicações e as análises correspondentes.

Por fim, o Capítulo 6 traz as conclusões obtidas através de todo o estudo realizado até o momento e ainda discorre acerca das perspectivas futuras sobre quais podem ser os próximos passos.

## 2 REVISÃO BIBLIOGRÁFICA

Esse capítulo descreve a revisão bibliográfica dos temas aqui abordados, modelagem geológica, modelagem estratigráfica *forward*, calibração, função objetivo e otimização. Ou seja, é exposto o que foi estudado por alguns autores e as propostas existentes na literatura atualmente, servindo como base para o desenvolvimento de novas abordagens apresentadas neste trabalho.

### 2.1 MODELAGEM GEOLÓGICA

O petróleo é proveniente da matéria orgânica que se deposita em sedimentos de baixa permeabilidade, não havendo circulação interna da água. Condições termoquímicas adequadas levam à conversão de matéria orgânica na rocha geradora em óleo e/ou gás natural. Após esse processo, o óleo migra para uma rocha reservatório (rocha de alta porosidade) cercada por uma rocha selante que impede a migração do fluido (rochas de baixa permeabilidade e alta resistência capilar) de forma que o petróleo fica aprisionado. Ou seja, uma rocha com vazios interligados (poroso e permeável) atua como reservatório e outra camada de rocha com baixa permeabilidade age uma barreira para interromper o fluxo de óleo, mantendo-o dentro do reservatório.

As empresas com licença de exploração de petróleo em uma determinada área começam sua exploração com pesquisas geológicas e geofísicas. A pesquisa geológica é feita através da análise de formações rochosas para determinar possíveis reservas de petróleo. Por outro lado, a geofísica envolve o uso de técnicas como sismologia, modelagem e processamento de dados para conduzir pesquisas aprofundadas sobre as propriedades físicas dessas rochas para estimar a estrutura geológica. E após isso, é perfurado um poço de exploração para verificar se há petróleo na região e avaliar o potencial da descoberta quanto a uma descrição precisa do tamanho, forma e produtividade dos depósitos.

Parte dessa pesquisa é a realização da modelagem geológica. Para Selley (2016), a modelagem da bacia pode ser projetada para uma, duas ou três dimensões, e é realizada por meio de recursos computacionais. A modelagem

unidimensional é limitada à construção de uma curva de histórico de soterramento para um determinado ponto na bacia (a localização de um poço, por exemplo). Já a modelagem bidimensional consiste na geologia reconstruída por *backstripping* da história da bacia a partir de perfis sísmicos, sendo necessário estimar a profundidade de deposição de cada camada e o histórico de compactação. A modelagem tridimensional (3D) é semelhante à modelagem anterior, mas analisa e interpreta o volume, não apenas uma seção transversal. E neste trabalho, será tratada a modelagem 3D.

Para Caumon *et al.* (2009), entender as estruturas de subsuperfície é essencial para a modelagem quantitativa de processos geológicos. Uma vez que é impossível acessar diretamente o subsolo, exceto por meio de poços, a maior parte das informações é adquirida por processos de coleta indireta. A modelagem geológica 3D é uma maneira de melhorar a interpretação de dados, visualizando o modelo que está sendo criado e fornecendo suporte para simulação numérica de fluxo. A construção de um modelo 3D requer decisões interpretativas, e mesmo para os geólogos experientes, essa interpretação costuma ser qualitativa, podendo torná-la imprecisa e às vezes até equivocada. Essa modelagem também é um método de obtenção de dados quantitativos, para avaliar ou prever a produção de petróleo. Nesse caso, um dos principais problemas é estimar as propriedades petrofísicas da rocha, como a porosidade, e essas distribuição das propriedades dependem principalmente do tipo de rocha e do ambiente de deposição (ambiente lagunar, costeiro, fluvial, etc.). Logo, o modelo 3D é uma representação digital desta informação estrutural. A modelagem também depende da escala escolhida, suposições anteriores sobre o objeto geológico de estudo, a aplicação pretendida, a quantidade de informação disponível e a qualidade e limitações do(s) equipamento(s), como processamento e memória.

Uma metodologia convencional utilizada atualmente na indústria de óleo e gás é a krigagem, que consiste em um método de estimativa, fornecendo o melhor valor mediano com base na covariância, podendo ser utilizada para o refinamento de malhas, por exemplo. Seu estudo se iniciou com o trabalho de Krige (1951). Ele se propôs a resolver a estimativa do teor do minério, um problema comum na mineração para engenheiros e investidores, avaliação que

na época era determinada por fórmulas simples baseadas na experiência real. Seu objetivo era unir a experiência prática e métodos estatísticos especializados em prol da resolução de muitos problemas existentes, como a avaliação de minas. Posteriormente, esse método começou a ser utilizado também na indústria de petróleo.

## 2.2 MODELAGEM ESTRATIGRÁFICA *FORWARD*

Alguns autores desenvolveram modelos numéricos de simulação quantitativa para reproduzir as condições físicas de um sistema natural que representam a produção, o transporte e a deposição de sedimentos em uma bacia sedimentar. Entre eles, surgiu a modelagem estratigráfica *forward* para reproduzir tais modificações físicas no ambiente deposicional durante um dado intervalo de tempo, através de parâmetros composicionais (quantidade e tipo de sedimentos) e de controles ambientais (declividade, energia de ondas, entre outros).

Granjeon e Joseph (1999) estabeleceram uma modelagem estratigráfica *forward* 3D com escalas macroscópicas de tempo e espaço (dezenas de milhões de anos e dezenas a centenas de quilômetros). O modelo é baseado nas leis de fluxo e, através da equação de difusão generalizada, simula o transporte de sedimentos, relacionado à inclinação da bacia, à capacidade de transporte da água e à disponibilidade de sedimentos. O modelo reproduz corretamente o conceito de estratigrafia de sequência, devido às mudanças no nível do mar por exemplo, tornando possível a caracterização das fácies, como a proporção de areia, folhelho e carbonato. O modelo também acaba sendo uma boa ferramenta quantitativa quanto ao entendimento da estratigrafia de bacias sedimentares.

O objetivo de Granjeon e Joseph (1999) foi desenvolver um modelo *forward* usando métodos determinísticos, ou seja, leis físicas detalhadas aliadas a perfis de poços e/ou dados sísmicos em estudos de exploração. Para isso, foi desenvolvido o *Diffusive Oriented—Normal and Inverse—Simulation Of Sedimentation* (DIONISOS), simulação de sedimentação orientada à difusão normal e reversa, em português. São utilizadas leis da dinâmica dos fluidos para estabelecer um conjunto de equações de difusão 3D aplicáveis a diferentes

litologias ou tamanhos de grãos, tornando possível reproduzir a estrutura sedimentar da bacia. Esse software quantifica a geometria média da unidade sedimentar e o conteúdo médio das fácies, como a proporção de areia, folhelho e carbonato.

O modelo numérico *forward* se baseia na reconstrução de processos geológicos em intervalos de tempo, iniciando de um ponto no passado para outro tempo mais recente. Para isso, o modelo quantifica a taxa de deposição ou erosão em cada intervalo de tempo e em cada ponto da bacia a partir da combinação de duas equações principais: a lei de transporte, para identificar a quantidade de sedimento devido à atividade do rio ou das ondas; e a equação de continuidade para sedimentos, para estipular que todo sedimento trazido ou produzido na bacia deve ser depositado ou retirado em determinada posição na bacia. Também há a lei de compactação clássica que relaciona a porosidade da rocha com a profundidade do soterramento. O estudo de Granjeon e Joseph (1999) também permitiu definir leis macroscópicas aplicáveis a diferentes litologias ou tamanhos de grãos em ambientes continentais e marinhos. Essa metodologia foi aplicada no desenvolvimento do software *DionisosFlow*® (MARFISI *et al.*, 2016).

Para Faria *et al.* (2017), a modelagem estratigráfica *forward* é um método útil para avaliar o papel dos parâmetros no processo de deposição de rochas sedimentares. Eles utilizaram o software *DionisosFlow*® na Bacia de Santos (Brasil) para testar possíveis cenários de deposição no Aptiano da Bacia de Santos. Diferentes parâmetros foram testados a fim de reproduzir a distribuição de fácies observada nos dados de poços disponíveis, sendo que as melhores condições ambientais foram a taxa de deposição de carbonato lenta e a oscilação na superfície do lago. Logo, a SFM pode ser usada de forma preditiva para a exploração e exploração de hidrocarbonetos.

### 2.3 CALIBRAÇÃO

Os resultados dos SFM devem ser avaliados e calibrados, pois muitas vezes podem não corresponder suficientemente às informações nos dados do poço. Atualmente, esse ajuste é realizado manualmente por tentativa e erro,

demandando tempo e interpretação qualitativa dos profissionais envolvidos. O resultado bem-sucedido da calibração deve ser o conjunto de parâmetros de entrada da simulação que leve a um modelo que corresponda melhor aos dados observados no poço. Essa calibração pode ser realizada por meio do processo de inversão. Diversos autores desenvolveram diferentes métodos para a solução desse problema e abaixo estão citadas algumas destas propostas.

A modelagem estratigráfica envolve um grande número de parâmetros determinados manualmente através de suposições e para Bornholdt e Westphal (1998), esse é um problema de otimização, resolvido por eles através da aplicação de um algoritmo genético. Ou seja, o processo de verificação desses parâmetros manualmente, agora seria automatizada, levando muito menos tempo do que a modelagem convencional. Esse algoritmo permite encontrar rapidamente valores adequados para esses parâmetros de entrada. Também é possível gerar várias soluções possíveis dependendo da quantidade de restrições (dados de poços, por exemplo), tornando possível que os profissionais experientes tomem a decisão sobre qual modelo é mais razoável nas condições geológicas. Além de dados de poços, também é possível utilizar os dados sísmicos que contêm informações sobre a espessura e geometria do reservatório, uma vez que parte da otimização é comparar o modelo estratigráfico com os dados geológicos. Os autores também citam que um número adequado de parâmetros de entrada do algoritmo genético deve ser mantido e que para muitos destes, o algoritmo deve ser aplicado em vários estágios, utilizando subconjuntos de parâmetros.

Segundo Cross e Lessenger (1999), a inversão estratigráfica é uma técnica quantitativa para extrair os valores dos parâmetros (nível do mar, disponibilidade de sedimentos, entre outros) dos dados estratigráficos. Primeiro, é necessário um modelo *forward* que simule a formação por meio de um conjunto de parâmetros de entrada e um conjunto de dados observados para realizar a comparação. Depois, um conjunto de equações que comparam o valor do modelo *forward* com o valor observado, para ajustar os valores dos parâmetros de entrada e simular modelos melhores. Logo, a diferença entre os dados simulados e observados é reduzida através de um método baseado em gradiente proposto pelos autores até que uma boa correspondência seja alcançada. Um

dos objetivos da modelagem inversa é estimar uma faixa de valores dos parâmetros de entrada para que seja possível gerar um grande número de modelos *forward* com a estratigrafia real e prever a localização de reservatórios potenciais, fontes de hidrocarbonetos e rochas selantes. Além disso, é possível obter o mínimo global mais rápido do que procedimentos alternativos, porém as restrições devem ser lineares e a função objetivo deve ser diferenciável.

Para Karssenberg *et al.* (2001), modelos *forward* podem fornecer uma previsão mais realista de estruturas sedimentares, mas não têm sido amplamente utilizados devido à dificuldade de calibração utilizando dados de poços, perfis sísmicos, entre outros. Eles propõem a simulação de Monte Carlo para gerar campos aleatórios que definem a topografia inicial da planície de inundação, produzindo diferentes modelos de saída para cada execução e verificando o ajuste em relação a cinco poços verticais hipotéticos dentro de uma faixa de tolerância predeterminada. Também é possível aumentar o número de poços para melhorar o modelo, mas na prática exigirá muito esforço computacional, especialmente quanto ao tempo de cálculo. Esse método também depende da quantidade de informações prévias disponíveis e pode ser aplicado tanto em grandes escalas como pequenas. Outra vantagem é a possibilidade de obter uma relação entre o número de dados observados e a precisão da predição do modelo.

Wijns *et al.* (2004) propõem uma metodologia inversa iterativa para fornecer um possível caminho a seguir na calibração de modelos geológicos, baseada em revisões de especialistas dos modelos resultantes e modificação dos parâmetros de entrada. Ou seja, em um exemplo sintético, alteram-se 9 variáveis de entrada com pequenas diferenças e realizam-se 10 simulações. Após isso, um geólogo classifica os resultados em ordem de semelhança com perfil real e as duas ou três simulações melhores classificadas são utilizadas como base para o algoritmo genético gerar a próxima rodada de 10 simulações. Esse procedimento é feito até que uma correspondência satisfatória entre dados simulados e observados seja encontrada. Com base nos resultados obtidos, esse método tem a vantagem de convergir em poucas gerações. No entanto, existe a possibilidade de as soluções ficarem presas no mínimo local e, ao

dependem da complexidade dos resultados, pode ser difícil a classificação subjetiva.

Para Charvin *et al.* (2009), desde a década de 70, os modelos estratigráficos conceituais são baseados na ideia de que o principal ponto de controle é o espaço. Mesmo considerando outros parâmetros (suprimento de sedimentos, eficiência do transporte, etc.) recentemente, ainda é necessário analisar as interações que ocorrem durante o processo de deposição sedimentar. Os autores propõem um novo método combinando uma inversão não linear com a resposta do modelo estratigráfico *forward* para inferir os principais parâmetros ambientais, como o fornecimento de sedimentos e o nível relativo do mar. O método combina o algoritmo Monte Carlo via cadeia de Markov com Saltos Reversíveis, *Reversible-jump Markov chain Monte Carlo* (RJMCMC) em inglês, e o algoritmo de Têmpera Simulada com uma função de verossimilhança para quantificar a consistência entre os dados simulados e observados. Foram adicionados ruídos aos dados para testar o método e houve validação, uma vez que foram encontrados todos os parâmetros de entrada para produzir uma simulação que resulte em um modelo condizente com a realidade desconhecida, havendo convergência e resolvendo o problema de cálculo excessivo. Isso enfatiza a robustez do esquema inverso e torna possível avaliar muitos parâmetros ambientais e analisar a incerteza na distribuição de fácies. No entanto, milhares de simulações foram feitas para atingir a convergência, fazendo com que isso impactasse diretamente os custos computacionais. No entanto, a grande quantidade de simulações realizadas diminuiu a chance de as soluções ficarem presas no mínimo local e disponibiliza uma gama completa de amostras.

Falivene *et al.* (2014) acreditam que a precisão das características dos reservatórios da bacia é importante para avaliar os riscos e incertezas da exploração de óleo e gás. Os modelos estratigráficos *forward* integram informações conhecidas, processos geológicos em um modelo numérico; e calibrá-los com dados sísmicos ou de poço, pode melhorá-los significativamente. A ferramenta utilizada por eles é o algoritmo de inversão, um aprimoramento do algoritmo de vizinhança de busca direta, sem gradientes, que visa amostrar funções objetivas multimodais; e a convergência também é acelerada através do

processamento paralelo em *clusters* de computador. O resultado é um conjunto de modelos geológicos representativos consistentes com os parâmetros previamente determinados, restrições e limites de tolerância. A análise do modelo calibrado possibilita a previsão do local onde as armadilhas estratigráficas são mais prováveis de se desenvolver, que estão relacionadas às interações entre batimetria, subsidência, características das fontes de sedimentos e parâmetros de transporte de sedimentos. Os resultados também mostram que a combinação de modelagem estratigráfica *forward* com os métodos de inversão podem ser usados como ferramentas de apoio para exploração convencional e previsão de existência de reservatório. Também são necessárias milhares de simulações durante o processo de inversão, o que pode levar alguns dias, dependendo do número de parâmetros de entrada variáveis e da resolução do modelo.

Segundo Sacchi *et al.* (2015), a modelagem *forward* expressa a distribuição espacial da litologia de acordo com o processo físico e as condições ambientais no momento da deposição. Devido à limitação de informações de dados subsuperfícies e dos custos computacionais, a aplicação da inversão nesses modelos não foi bem estabelecida. No estudo de Sacchi *et al.* (2015) são usados também dados sísmicos e perfis de alguns poços para examinar a inversão com a modelagem *forward* desenvolvida na *Delft University of Technology*, o SimClast. Para isso, três funções objetivos foram propostas para realizar a comparação e a inversão do modelo foi feita através de Quasi-Monte Carlo, realizando-se também o estudo do impacto dos parâmetros de entrada. Neste caso, o modelo é mais sensível à topografia inicial e ao ponto de entrada do sedimento, por exemplo. E os resultados sugerem que a avaliação desses dados permite uma redução na incerteza nos modelos geoestatísticos em comparação com o fluxo de trabalho convencional. Obteve-se resultados bons ao trabalhar com toda a bacia, mas ao limitar a calibração apenas para o reservatório, o método foi menos bem-sucedido.

Duan *et al.* (2017) apresentam uma função objetivo para comparar as sequências estratigráficas entre dados observados em poços e resultados da simulação. E como método de calibração, os autores utilizam o algoritmo genético e a têmpera simulada. As maiores vantagens da função objetivo

proposta são: calcular tanto as distâncias entre fácies como a distância entre as espessuras, considerar a ordem vertical dos poços e poder ser adaptada para levar em consideração hiatos. No entanto, para obter bons resultados na calibração, se faz necessário a análise de sensibilidade e convergência dos parâmetros incertos. Além disso, é possível se obter uma mesma solução a partir de diferentes conjuntos de parâmetros de entrada.

Abaixo é apresentada a Tabela 5.2 comparativa entre os trabalhos acima citados, com a função objetivo, o método de calibração, as vantagens e as desvantagens dos estudos de cada autor.

Tabela 2.1 - Comparação entre os métodos empregados por cada autor, com vantagens e desvantagens.

Autores	Função objetivo	Método de calibração	Vantagens	Desvantagens
Bornholdt e Westphal (1998)	Função própria	Algoritmo genético	<ul style="list-style-type: none"> <li>- Menos tempo que o convencional</li> <li>- Produz uma variedade de soluções possíveis</li> </ul>	<ul style="list-style-type: none"> <li>- Dividir em estágios para trabalhar com muitos parâmetros</li> </ul>
Cross e Lessenger (1999)	-	Método baseado em gradiente (proposto pelos autores)	<ul style="list-style-type: none"> <li>- Mínimo localizado mais rápido do que procedimentos alternativos</li> </ul>	<ul style="list-style-type: none"> <li>- As restrições devem ser lineares</li> <li>- A função objetivo deve ser diferenciável</li> </ul>
Karssenberget al. (2001)	-	Monte Carlo	<ul style="list-style-type: none"> <li>- Aplicação em grandes e pequenas escalas</li> <li>- Relação entre número de dados observados e precisão da predição</li> </ul>	<ul style="list-style-type: none"> <li>- Requer muito tempo computacional</li> <li>- Depende da quantidade de informações prévias disponíveis</li> </ul>
Wijns et al. (2004)	Ranking por geocientistas	Algoritmo genético	<ul style="list-style-type: none"> <li>- Convergência em poucas gerações</li> </ul>	<ul style="list-style-type: none"> <li>- Possibilidade de ficar preso no mínimo local</li> <li>- Resultados complexos podem ser difíceis de ranquear</li> </ul>
Charvin et al. (2009)	Função de verossimilhança	Monte Carlo via cadeia de Markov com Saltos Reversíveis e Temperatura Simulada	<ul style="list-style-type: none"> <li>- Gama completa de soluções amostrada (não-singularidade)</li> <li>- Chance diminuída de ficar preso no mínimo local</li> </ul>	<ul style="list-style-type: none"> <li>- Qualidade do resultado e tempo computacional dependem da quantidade de informações prévias disponíveis</li> </ul>
Failivene et al. (2014)	Função erro	Variação do algoritmo de vizinhança	<ul style="list-style-type: none"> <li>- Calibração permite processamento paralelo</li> <li>- Considera combinações de parâmetros incertos</li> </ul>	<ul style="list-style-type: none"> <li>- Parâmetros incertos selecionados influenciam no tempo computacional e resultados</li> </ul>
Sacchi et al. (2015)	Três funções de ajuste	Quasi-Monte Carlo	<ul style="list-style-type: none"> <li>- Melhores resultados para calibração de toda a bacia</li> </ul>	<ul style="list-style-type: none"> <li>- Grande influência das incertezas relacionadas aos parâmetros reservatório</li> <li>- Menos bem-sucedida ao considerar somente o reservatório</li> </ul>
Duan et al. (2017)	Função própria	Algoritmo genético e Temperatura Simulada	<ul style="list-style-type: none"> <li>- Considera as distâncias entre fácies e espessuras</li> <li>- Considera ordem vertical dos poços</li> <li>- Pode ser adaptada para considerar hiatos</li> </ul>	<ul style="list-style-type: none"> <li>- Necessária ajuda da análise de sensibilidade e convergência dos parâmetros incertos antes de iniciar a calibração</li> <li>- Mesma solução alcançada por diferentes conjuntos de parâmetros</li> </ul>

Fonte: elaborado pela autora (2022).

Assim, diante do estudo realizado na literatura, conclui-se que a calibração automática dos SFM envolve três problemas principais: 1) a definição de uma função objetivo (FO) quantitativa e geologicamente representativa; 2) a escolha de um algoritmo de inversão e 3) gerar um modelo compatível para realizar a simulação. Este trabalho busca atuar e propor métodos para resolver os dois primeiros desafios.

O algoritmo de inversão tratado pelos autores também pode ser resolvido através de métodos de otimização e este tópico será abordado na seção 2.5. Além disso, muitos autores demonstram que uma das principais dificuldades de se obter modelos calibrados, é pela necessidade de uma função objetivo apta que guie o processo de calibração. Em virtude das vantagens apresentadas pela função objetivo proposta por Duan *et al.* (2017), escolheu-se seguir por uma metodologia similar. Porém, existem também algumas limitações que serão explicadas com mais detalhes nas próximas seções, bem como as alterações realizadas para lidar com tais dificuldades. Além disso, nota-se que muitos autores focam nos métodos de calibração e abordam a função objetivo de forma muito sucinta ou apenas citando-a. Portanto, existe uma necessidade de tratar a função objetivo de forma mais aprofundada e que pode ser a base para que os resultados da calibração sejam mais bem-sucedidos.

## 2.4 FUNÇÃO OBJETIVO

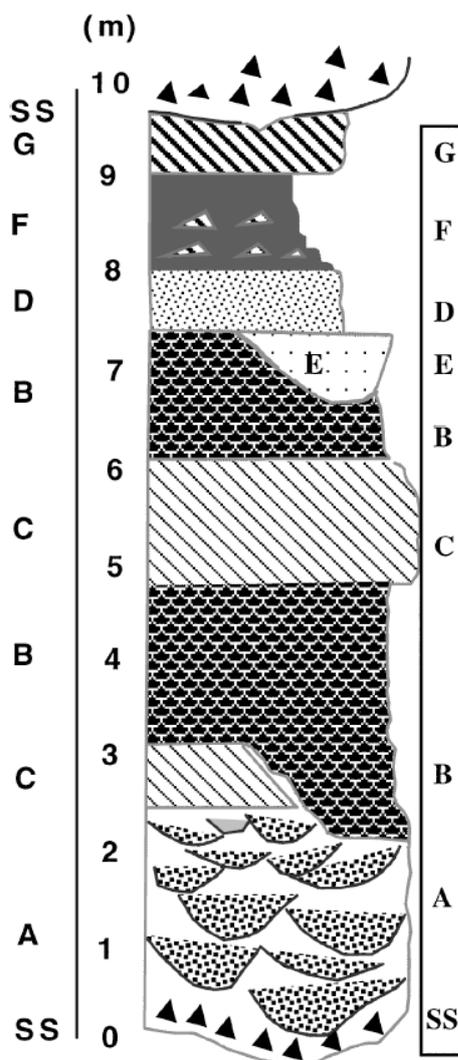
Nos trabalhos dos autores mencionados na seção anterior, percebeu-se que uma técnica quantitativa de comparação para uma sequência sedimentar é necessária na modelagem estratigráfica inversa. Os autores mostram sua aplicação na simulação de sucessões sedimentares unidimensionais e bidimensionais para comparar os resultados simulados com um conjunto de dados observados para medir se eles são correspondidos de maneira suficientemente similares.

Assim, buscando contribuir para o desafio mencionado o estudo da função objetivo desenvolvida neste trabalho deu-se pela realização do entendimento da função objetivo proposta por Duan *et al.* (1999), (2001) e Duan (2017), pois apresenta vantagens relacionadas ao problema proposto neste trabalho, como

calcular tanto as distâncias entre fácies como a distância entre as espessuras, considerar a ordem vertical dos poços e a possibilidade de adaptações, levando em consideração os hiatos, por exemplo. A FO proposta por Duan *et al.* (1999), (2001) e Duan (2017) tem por objetivo calcular a distância entre sucessões sedimentares para comparar formalmente sua dissimilaridade. Essas sucessões são representadas de forma unidimensional por uma sequência de símbolos de litofácies e seus atributos, neste caso a espessura. Para isso, soma-se a distância sintática entre a diferença de litofácies verticais entre duas sucessões e a distância dos atributos, que mede a diferença de espessura das litofácies correspondentes.

Primeiramente, é descrita uma representação sintática atribuída às sucessões sedimentares e é definida uma medida de dissimilaridade. De maneira geral, pode-se usar um conjunto de símbolos para codificar as litofácies, e depois organizá-los sequencialmente, obtendo uma sequência de símbolos representativa das litofácies, conforme o exemplo da Figura 2.1.

Figura 2.1 - Uma sucessão de canais representada por símbolos de litofácies e um gráfico de Cant e Walker (1976) (à esquerda) e sua descrição sintática (uma sequência de códigos).



Fonte: Duan *et al.* (2001).

A sequência da esquerda, neste caso, seria o código da litofácies com sua espessura (atributo) entre parênteses, SS(0,0) A(2,5) C(0,5) B(2,0) C(1,0) B(1,3) D(0,7) F(1,0) G(0,8) SS(0,0). Assim é possível definir a dissimilaridade entre duas sucessões sedimentares e posteriormente classificar essas sequências curtas em grupos através do agrupamento.

A fim de tornar duas sequências iguais existem três operações possíveis para se realizar, sendo elas, substituição, exclusão e inserção. A distância de Levenshtein é então definida pelo número mínimo de substituições, exclusões e inserções necessárias para transformar a sequência 1 na sequência 2. Por

exemplo, para transformar a sequência 'abc' em 'bde' é necessário excluir o 'a' (resultando na sequência 'bc'), substituir 'c' por 'd' (resultando na sequência 'bd') e por fim inserir o 'e' (resultando na sequência 'bde'). Além disso, ainda há a distância de Levenshtein generalizada, em que cada uma dessas operações possui um peso diferente. A distância entre atributos é a distância Euclidiana entre as espessuras comparadas. Portanto, a equação da distância total,  $d^{AS}$ , das sequências  $\vec{x}$  e  $\vec{y}$  é definida pela equação (1),

$$d^{AS}(\vec{x}, \vec{y}) = \alpha d^F(\vec{x}, \vec{y}) + \beta d^A(\vec{x}', \vec{y}'), \quad (1)$$

sendo

$d^F(\vec{x}, \vec{y})$ : distância entre fâcies das sequências;

$\alpha$ : coeficiente de peso para a distância entre fâcies;

$d^A(\vec{x}', \vec{y}')$ : distância entre atributos das sequências;

$\beta$ : coeficiente de peso para a distância entre atributos;

$\vec{x}', \vec{y}'$ : atributos das sequências correspondentes.

Para melhor entendimento da proposta dos autores, considera-se o seguinte exemplo, de três sequências  $\vec{x}$ ,  $\vec{y}$  e  $\vec{z}$ , com seus atributos correspondentes, dadas por,

$\vec{x}$ : a(10)b(5)c(4)

$\vec{y}$ : a(2)b(5)c(4)

$\vec{z}$ : b(5)c(4).

Calculando a distância entre as sequências, considerando os pesos  $\alpha$  e  $\beta$  igual a 1, tem-se:

Para  $\vec{x}$  e  $y$ ,

$$d^F(\vec{x}, \vec{y}) = 0$$

$$d^A(\vec{x}', \vec{y}') = |2 - 10| + |5 - 5| + |4 - 4| = 8$$

$$d^{AS}(\vec{x}, \vec{y}) = \alpha d^F(\vec{x}, \vec{y}) + \beta d^A(\vec{x}', \vec{y}') = 1 \times 0 + 1 \times 8 = 8.$$

Para  $\vec{x}$  e  $\vec{z}$ ,

$$d^F(\vec{x}, \vec{z}) = 1 \text{ (inserção de a)}$$

$$d^A(\vec{x}', \vec{z}') = |0 - 10| + |5 - 5| + |4 - 4| = 10$$

$$d^{AS}(\vec{x}, \vec{z}) = \alpha d^F(\vec{x}, \vec{z}) + \beta d^A(\vec{x}', \vec{z}') = 1 \times 1 + 1 \times 10 = 11.$$

Para  $y$  e  $z$ ,

$$d^F(\vec{y}, \vec{z}) = 1 \text{ (inserção de a)}$$

$$d^A(\vec{y}', \vec{z}') = |0 - 2| + |5 - 5| + |4 - 4| = 2$$

$$d^{AS}(\vec{y}, \vec{z}) = \alpha d^F(\vec{y}, \vec{z}) + \beta d^A(\vec{y}', \vec{z}') = 1 \times 1 + 1 \times 2 = 3.$$

Na seção 4.1, haverá mais detalhes sobre a nova FO proposta e as diferenças em relação ao que foi aqui descrito, visto que as mudanças indicadas a tornam mais adaptada para o setor de óleo e gás e possuem uma representatividade geológica maior.

A FO é um dos principais elementos da calibração, pois seu valor quantitativo será o guia para os métodos de otimização buscarem os melhores valores dos parâmetros inversíveis, gerando um modelo estratigráfico que honre os dados dos poços de hidrocarbonetos. Para isso, o valor da FO deve decrescer e chegar ao mínimo valor possível. A próxima seção irá abordar alguns métodos de otimização existentes e os utilizados para realizar os agrupamentos das camadas dos poços de hidrocarbonetos no cálculo do valor da FO e para executar a calibração dos parâmetros de entrada da simulação neste trabalho.

## 2.5 OTIMIZAÇÃO

Métodos de otimização nos últimos anos vêm atingindo um grau de avanço e são utilizados num amplo espectro de aplicações nas mais diversas áreas. Além disso, com o rápido avanço da tecnologia e computadores, que estão se tornando cada vez mais poderosos, permitem equivalentemente, que o tamanho e a complexidade dos problemas que podem ser resolvidos usando técnicas de otimização também sejam aumentadas. Métodos de otimização, juntamente com modernas ferramentas de desenho assistido por computador,

também estão sendo utilizadas para aprimorar a criatividade e automatização de processos de engenharia, como a desenvolvida neste projeto.

Otimização é um processo de escolha da entrada da função objetivo que produz a melhor saída (menor valor da FO). Neste trabalho, é utilizada para executar o cálculo da FO de maneira rápida e para escolher os parâmetros de entrada da simulação que farão com que o modelo resultante seja o mais próximo possível da realidade.

Problemas de otimização geralmente envolvem maximizar ou minimizar uma função objetivo, que podem envolver restrições que limitam as soluções possíveis. Isso é discorrido de forma mais completa para os problemas de otimização deste trabalho nas seções de formulação matemática 4.1.1 e 4.1.2.

Se algo pode ser modelado matematicamente, muitas vezes pode ser otimizado. Existem problemas simples em que é fácil estimar a solução correta, porém para problemas mais complexos, isso pode se tornar difícil. Supor uma solução e verificá-la (tentativa e erro), pode levar muito tempo. Por isso, é necessário utilizar métodos especiais, chamados algoritmos de otimização, para encontrar respostas para a maioria desses problemas.

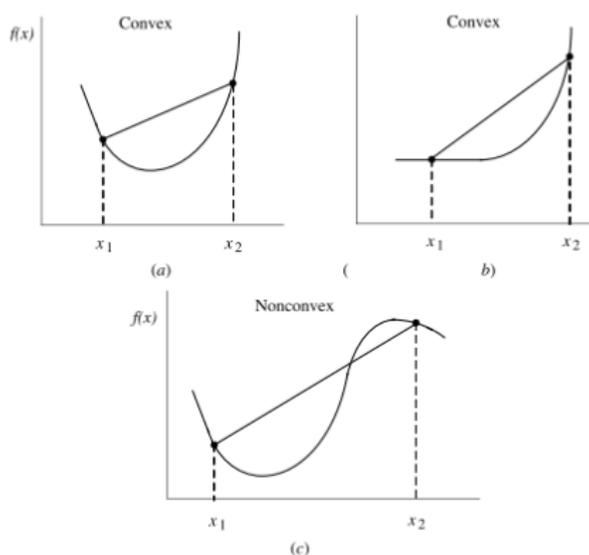
Ao se trabalhar com otimização, também é necessário observar a distinção entre variáveis contínuas e variáveis discretas (reais ou inteiras). Ou seja, algumas variáveis podem ser representadas por uma faixa contínua de valores, como massa ou velocidade, e outras só podem ser representadas por quantidades inteiras, como o número de pessoas ou a quantidade de camadas de um poço, segundo AlphaOpt (2017). Essa análise é necessária porque os tipos de variáveis envolvidas no problema afetam os métodos de otimização que podem ser utilizados.

Outro estudo fundamental do problema a ser otimizado é a verificação da convexidade. Uma função objetivo é convexa se o resultado da função de qualquer combinação entre dois pontos do domínio resulte em um valor que é igual ou menor do que a combinação do valor da função nesses pontos. Isso pode ser expresso matematicamente pela equação (2),

$$f((1 - \lambda)\vec{x}_1 + \lambda\vec{x}_2) \leq (1 - \lambda)f(\vec{x}_1) + \lambda f(\vec{x}_2), \quad (2)$$

para  $\vec{x} \in \mathbb{R}$  e  $\lambda \in (0,1)$ . Ou seja, se o segmento da reta secante que passa por estes dois pontos  $(x_1, f(x_1))$  e  $(x_2, f(x_2))$  sempre está acima ou coincide com o gráfico de  $f$  para qualquer escolha de pontos neste intervalo. A Figura 2.2 apresenta alguns exemplos de funções convexas e não-convexas.

Figura 2.2 – Representações de funções convexas (a) e (b) e função não-convexa (c).



Fonte: Alves (2019).

Além disso, a função objetivo pode contar com restrições que descrevem o que pode ou não ser uma solução viável, ou outras condições que uma solução deve satisfazer. Essas restrições podem ser de igualdade ou de desigualdade. Para contornar isso durante a otimização, é possível aplicar uma penalidade ou testar a restrição para indicar se a solução é factível ou não.

Existe na literatura distintas maneiras propostas para abordar tais restrições. Um método clássico para tratar restrições é a penalidade, sendo estática ou dinâmica. Na abordagem de Powell e Skolnick (1993), é verificada a viabilidade de cada solução e caso a mesma seja inviável, um termo de penalidade é somado ao valor da FO. Esse número pode ser constante, assumindo um valor fixo, ou variável, sendo alterado a cada iteração. Esse foi o método escolhido para tratar as restrições neste trabalho e mais informações podem ser encontradas na seção 4.1.1, equação (10).

Também é possível utilizar o critério de viabilidade, proposto por Deb (2000), através do seguinte mecanismo de seleção: (1) entre uma solução viável e uma solução inviável, escolhe-se a viável; (2) entre soluções viáveis, escolhe-se a que resulta em um menor valor da FO; e (3) entre duas soluções inviáveis, escolhe-se a solução com menor grau de violação de restrições.

Uma outra forma de lidar com restrições é através da classificação estocástica por Runarsson e Yao (2000), que se baseia nos valores relativos da FO ao se comparar duas soluções e na soma de violações das restrições. Para isso, é utilizado um parâmetro de controle que classifica as soluções de forma a selecionar os valores mínimos da FO com menor grau de soma de violações das restrições.

Otimizadores são ferramentas poderosas, mas é preciso experiência e prática para saber qual método é o mais indicado para cada situação. Alguns dos tipos de otimização são: estocástica, meta-heurística e baseada em gradiente.

A otimização estocástica é uma classe de algoritmos que empregam certo grau de aleatoriedade para encontrar soluções ótimas, em que as restrições ou os parâmetros dependem de variáveis aleatórias, segundo Luzia e Rodrigues (2009).

Já a otimização baseada em gradientes é fundamentada nas derivadas que descrevem a inclinação de uma função, analisando se aumenta ou diminui em uma determinada direção, ou em várias direções (dimensões). Desta forma, esses gradientes ajudam o otimizador a perceber em qual direção encontrar o melhor valor. Logo, encontrar esse gradiente da função objetivo é a parte importante da otimização, podendo ser realizado por diferenciação analítica, diferenciação numérica e diferenciação automática, segundo AlphaOpt (2017).

O primeiro passo do algoritmo baseado em gradiente é escolher uma direção de busca. Para isso, o otimizador avalia a inclinação tomando a derivada da sua posição atual. Essa informação, junto com outras regras do método utilizado, é aplicada para escolher uma direção para seguir a busca. Também é necessário decidir o quanto seguir na direção escolhida, isso é chamado tamanho do passo. Esse valor precisa ser ótimo para que não seja muito lento ou não passe muito do valor que se deseja encontrar.

Os algoritmos baseados em gradiente têm vantagens e limitações: são amplamente utilizados, têm desempenho rápido e se adaptam a problemas grandes. Porém, exigem funções suaves e contínuas para o cálculo dos gradientes, e pode se tornar computacionalmente caro. Além disso, alguns podem ser propensos a encontrar mínimos locais, ao invés de ótimos globais.

Nos últimos anos foram desenvolvidos novos algoritmos que buscam combinar abordagens heurísticas de forma eficiente para explorar um espaço de busca. Para Luzia e Rodrigues (2009), as meta-heurísticas são métodos de solução que contam com estratégias para realizar procedimentos de busca locais, visando realizar uma procura robusta no espaço de soluções enquanto escapa de mínimos locais. Também foi incorporado o conceito de vizinhança para estabelecer meios de se afastar desses mínimos locais. Possui a vantagem de poder ser aplicada em problemas sobre os quais há poucas informações quanto à solução ótima, ou seja, há poucos dados heurísticos disponíveis previamente. Além disso, é um método mais rápido e uma alternativa à Força Bruta quando o espaço de solução é muito grande. No entanto, dada uma solução candidata ao problema, não há garantia de otimalidade, podendo resultar em um mínimo local.

Abaixo são apresentados alguns estudos na área de otimização, bem como a contribuição de alguns autores em ordem cronológica.

Segundo McLaughlin (1742), maneiras de resolver questões relativas a máximos e mínimos são derivadas da geometria. Os métodos para traçar tangentes às curvas podem ser compreendidos pelo método de fluxões (taxa instantânea de mudança em um determinado ponto), por exemplo. Cauchy *et al.* (1847) propuseram o primeiro método baseado em gradiente. Segundo Lemaréchal (2012), Cauchy *et al.* realizavam cálculos de astronomia, como o cálculo da órbita do corpo celeste em que havia muitas incógnitas, e resolver equações muito grandes era um problema de otimização na época. Isso se deve ao fato de que muitas vezes não era possível eliminar algumas equações até que restasse apenas uma para resolver, ou essa equação resultante era muito complexa. Logo, houve a menção da convergência, em que se o valor encontrado não for o mínimo, é possível reduzi-lo para um valor ainda menor até convergir para o valor mínimo. Foi ele que fez a primeira contribuição de método

de gradiente para resolver problemas de otimização irrestrita. Na época, Cauchy *et al.* não pareciam acreditar que esse método sempre encontrará uma solução, mas a sequência decrescente de valores deve convergir para um mínimo local ou pelo menos um ponto estacionário. Atualmente, sabe-se que é necessária alguma forma de uniformidade a partir da continuidade do objetivo.

Em 1917, Harris Hancock publicou o primeiro livro sobre otimização, incluindo o histórico da otimização até a data. Para o autor, os matemáticos sempre se interessaram em problemas de máximo e mínimo, até mesmo antes da descoberta do cálculo, por exemplo, o problema da menor reta que pode ser traçada de um ponto a uma seção cônica (Euclides 300 a.C.). Já o teorema de Fermat para encontrar máximos e mínimos locais de funções diferenciáveis a partir da derivada da função igual a zero foi de suma importância para o desenvolvimento o cálculo conhecido hoje. Por sua vez, a teoria da otimização também se desenvolveu rapidamente após a descoberta do cálculo diferencial com as contribuições de Newton e Leibnitz e alguns autores desenvolveram teorias novas e poderosas para encontrar o valor máximo e/ou mínimo das funções.

Em 1932, Karl Menger propôs um dos problemas de otimização mais conhecidos. Menger *et al.* (1932) o chamaram de “problema do mensageiro”, também conhecido como *traveling salesman problem*, definido como a menor rota para percorrer uma série de cidades, ou seja, encontrar o caminho mais curto conectando um número finito de pontos, cuja distância entre cada par é conhecida. Esse problema coloca à prova o senso comum de que a escolha do caminho mais curto para o próximo ponto é sempre a melhor, pois geralmente não leva ao caminho mais curto total. Este problema é comumente resolvido através de um número limitado de tentativas, pois na época não existia uma regra conhecida que pudesse reduzir o número de tentativas abaixo do número de permutações possíveis.

Ford e Fulkerson (1954) estabeleceram o campo da otimização combinatória através de um problema de rede ferroviária com o objetivo de maximizar o fluxo entre duas cidades, havendo cidades intermediárias no caminho, e cada par com uma capacidade de fluxo diferente. Através desse problema, surgiu o teorema do fluxo máximo e corte mínimo. Quando é traçada

uma linha dividindo as cidades em duas partes (não necessariamente iguais, mas deixando a cidade origem e a cidade destino em partes diferentes) e soma-se a capacidade das linhas de fluxo cortadas, define-se que o fluxo máximo se dá pelo corte que resulta na menor capacidade somada total, ou seja, o valor do fluxo máximo será igual ao valor dessa capacidade mínima total do corte.

Os principais desenvolvimentos na área de métodos numéricos de otimização irrestrita foram realizados na década de 1960 no Reino Unido. Os métodos de otimização irrestrita mais famosos são: Gradiente, Gradiente Conjugado, Newton, Quasi-Newton. Posteriormente, na década de 1970 surgiram outros métodos como o *Broyden*, *Fletcher*, *Goldfarb e Shanno* (BFGS), *Limited memory* (L-BFGS), etc. A evolução destes métodos se deu basicamente pela busca de otimizar seu custo computacional e abrangência de aplicações, buscando formas alternativas para o cálculo da matriz Hessiana e formas alternativas de armazenamento. E desenvolvimento do método simplex por George Dantzig e Koopmans em 1947, para problemas de programação linear e o anúncio do princípio da otimalidade em 1957 proposto por Richard Bellman para problemas de programação dinâmica que impulsionou o desenvolvimento dos métodos de otimização restrita. Existem vários métodos baseados em gradientes para problemas restritos, tais como: métodos com penalidades, Lagrangeano Aumentado, Gradiente Projetado, entre outros. E os seguintes estudados e aplicados neste projeto de pesquisa por outros integrantes: os métodos de Newton truncados (TNC), *Limited Memory Quase-Newton* (L-BFGS-B), *Sequential Least Squares Programming* (SLSQP). Breves descrições de alguns destes métodos são apresentados na sequência.

A otimização pode ser realizada também através de métodos Quasi-Newton para encontrar máximos e mínimos locais de funções. O primeiro algoritmo Quasi-Newton foi proposto por Davidon (1959) para determinar numericamente o mínimo local de uma função diferenciável com múltiplas variáveis. O algoritmo se baseia na determinação de uma matriz que caracteriza o comportamento da função em relação ao mínimo. Além disso, esse processo para encontrar cada mínimo local não necessita de muitas iterações se comparado ao método tradicional de Newton.

Para Nash (2000), os métodos de Newton truncados (TNC) são adequados para resolver problemas grandes de otimização não linear. A solução é feita pela resolução aproximada das equações de Newton usando um algoritmo iterativo, em que a cada passo, a estimativa atual da solução é atualizada. O solucionador interno é truncado, ou seja, executado apenas por um número limitado de iterações. Isso resulta em um método duplamente iterativo: uma iteração externa para o problema de otimização não linear e uma iteração interna para as equações de Newton. A iteração interna é normalmente interrompida ou truncada antes que a solução para as equações de Newton seja obtida. Para isso, o solucionador interno precisa produzir uma boa aproximação em um número finito de iterações. Outro pré-requisito é um bom condicionamento para o algoritmo interno. Em cada iteração externa, uma solução aproximada é encontrada para as equações de Newton. Esse método pode ser ajustado para atingir a taxa de convergência desejada e limitar o cálculo da solução em pontos distantes demais.

*Limited Memory Quase-Newton Bound (L-BFGS-B)* é um algoritmo de memória limitada usado para resolver grandes problemas de otimização não lineares sujeitos a limites simples nas variáveis. É usado em problemas difíceis de se obter a matriz hessiana ou em problemas muito densos. Além disso, também pode ser utilizado em problemas irrestritos. O método faz parte da família dos métodos Quasi-Newton e visa resolver o problema do custo computacional, sendo o único método Quasi-Newton de memória limitada capaz de lidar com limites nas variáveis. O conhecimento do gradiente da função FO não é obrigatório e também não é necessário ter conhecimento da matriz hessiana da função; por isso, esse algoritmo é indicado para resolver grandes problemas, em que se é difícil obter a hessiana da função. A cada iteração do L-BFGS-B, uma aproximação da matriz hessiana é atualizada. Essa matriz de memória limitada é usada para definir um modelo quadrático da função objetivo. Uma direção de busca é então calculada usando dois estágios. Primeiro: o método de projeção de gradiente (BERTSEKAS, 1982); (CONN, GOULD, & TOINT, 1988); (LEVITIN & POLYAK, 1966); (MORÉ & TORALDO, 1989) é usado para identificar um conjunto de variáveis ativas, ou seja, aquelas que são mantidas nos limites. Então, um modelo quadrático é aproximadamente

minimizado em relação às variáveis livres. A direção de busca é definida como o vetor que leva da iteração atual até este minimizador aproximado. Segundo: uma busca de linha é realizada ao longo da direção de busca usando a sub-rotina descrita em Moré e Thunberg (1994). É um método fácil de se aplicar, pois não é necessário fornecer informações sobre a matriz hessiana ou estrutura da FO. Os requisitos de armazenamento são modestos e podem ser controlados, sendo o custo da iteração baixo e independente das propriedades da FO. No entanto, esse método não converge rapidamente e, em problemas difíceis, pode ser preciso muitas avaliações da função para convergir. Em problemas altamente mal condicionados, pode não haver uma alta precisão na solução.

*Sequential Least Squares Programming* (SLSQP) é um método de otimização por programação quadrática sequencial que se baseia na resolução de uma sequência de subproblemas, gerados a partir do problema inicial, e cujas soluções convergem para a solução do problema inicial. É um método iterativo para problemas de otimização com restrições lineares e não lineares. Nos subproblemas gerados, a FO é uma aproximação quadrática da FO original e as restrições são aproximações lineares das restrições originais, por isso o nome “programação quadrática”. O método SLSQP é usado para gerar os resultados dos subproblemas durante as iterações. Ele minimiza a FO por meio de uma busca bidirecional ao longo de cada vetor de busca, utilizando os mínimos quadrados. Também é necessário informar um ponto de partida inicial. A otimização por mínimos quadrados tem como objetivo principal encontrar o melhor ajuste para um conjunto de dados, procurando minimizar a soma dos quadrados das diferenças entre o valor estimado e os dados observados. O otimizador SLSQP é um solucionador local, que não se restringe a problemas convexos, podendo ser implementado para modelos pequenos e grandes. Essa abordagem tem como principal vantagem modelar problemas com restrições de desigualdade. Além disso, possui convergência quadrática e pode convergir mesmo com pontos de partida remotos (estimativa inicial ruim).

Entre os métodos utilizados para realizar tal otimização, encontra-se também a classe dos algoritmos inspirados na natureza, em que o primeiro avanço ocorreu na década de 60. Essa área da computação é inspirada nos processos evolutivos das espécies e possui como características a realização de

um processo iterativo, um conjunto de candidatos às soluções definido como população e se dá através de uma busca guiada. Essa busca pode levar em conta os princípios da seleção natural por exemplo, como é o caso do algoritmo genético (AG). Para Goldberg *et al.* (2016), o problema a ser resolvido é transformado em uma função com algumas variáveis e conjuntos destes serão as populações do método. Essas variáveis funcionam como informações genéticas que passarão por uma evolução artificial de acordo com regras da seleção e a busca será direcionada a favorecer as variáveis que levem ao melhor resultado procurado. Fazendo com que esses algoritmos evolucionários constituam uma busca robusta o suficiente para levar aos resultados de forma eficaz e em um tempo computacional menor.

O algoritmo genético pertence à classe de algoritmos evolutivos, ou seja, é baseado na biologia evolutiva em que ocorre hereditariedade (com seleção natural), cruzamento e mutação. Essa técnica é aplicada a um problema de otimização a partir uma população inicial de indivíduos aleatórios (soluções candidatas aleatórias) e cada geração é aprimorada a partir dos resultados obtidos (valor da função objetivo), guiando para o melhor resultado global (HOLLAND, 1973).

Outro algoritmo de otimização é o *Particle Swarm Optimization* (KENNEDY, 1995) que pode ser traduzido para Otimização por Enxame de Partículas e é um algoritmo meta-heurístico, ou seja, utiliza combinações aleatórias (estocástico) e o histórico dos melhores resultados para direcionar a busca.

Mais informações sobre os algoritmos de otimização AG e PSO são encontradas nas seções 4.2 e 4.3, respectivamente, em que são descritas suas aplicações para a problemática deste trabalho.

O algoritmo de Dijkstra foi um método estudado e implementado por outros integrantes do projeto de pesquisa com resultados iguais ao da Força Bruta, porém em um tempo de execução extremamente inferior, na ordem poucos de segundos. Como o mesmo será utilizado para comparações de resultados em casos que o tempo da Força Bruta é inviável, a ideia conceitual dele é brevemente apresentada a seguir.

O algoritmo de Dijkstra é um método utilizado para encontrar os caminhos mais curtos entre nós de um grafo. O método é conhecido pelo próprio nome de seu autor e sua publicação data de 1959. Dijkstra (1959) explica o algoritmo através de um grafo (árvore), onde os pares de nós são conectados por ramos com um valor de custo entre cada par, havendo pelo menos um caminho entre quaisquer dois nós. Por exemplo, para encontrar o caminho mais curto entre dois nós P e Q, os valores dos ramos intermediários são somados a partir de P, até que o ponto Q seja alcançado. Logo, iniciando de P, verifica-se o menor caminho até o nó seguinte para armazená-lo. Todos os nós são considerados e o valor dos ramos calculados para verificar o menor custo. Quando um nó é totalmente analisado e gera um valor maior do que atual, é descartado. Se o nó analisado resulta em um valor menor do que o atual, ele o substitui para dar continuidade à busca. Quando não há mais nós a serem analisados, o caminho que gera o menor valor é o resultado do algoritmo.

## 2.6 SUMÁRIO

Dentro do escopo, este trabalho contribui para a calibração assistida da modelagem estratigráfica *forward*. Com base nos estudos aqui mencionados, nos próximos capítulos será proposta uma nova função objetivo para comparar de forma quantitativa os resultados obtidos pela simulação através do software *DionisosFlow*® e os dados observados em poços. Também serão aplicados algoritmos de otimização para que o cálculo dessa função objetivo seja executado dentro de um tempo operacionalmente viável. Além disso, os algoritmos de otimização também serão utilizados para realizar a calibração do modelo, de forma a encontrar os parâmetros de entrada ótimos que resultem em um modelo estratigráfico aceitável, ou seja, que resulte em um valor mínimo para a função objetivo proposta.

### 3 METODOLOGIA

A partir da revisão bibliográfica, desenvolveu-se uma função objetivo para traduzir quantitativamente a dissimilaridade entre os resultados da simulação e os dados de poços. Essa função recupera os resultados de uma simulação do *DionisosFlow*® e compara com os dados de poços disponíveis, devolvendo um valor numérico da dissimilaridade entre os resultados da simulação e os dados observados, sendo parte fundamental para a calibração. Desta forma, executa-se a função objetivo proposta para avaliar se os resultados são aceitáveis e se há uma boa representatividade geológica. Caso esses critérios não sejam satisfeitos, busca-se o aprimoramento dessa função objetivo até que esteja adequada para o objetivo a que se propõe.

A função objetivo proposta, no entanto, pode ter um alto custo computacional em casos com muitas camadas de dados do poço e muitas camadas resultantes da simulação, uma vez que sua execução se dá pela Força Bruta, ou seja, cálculo de todos os candidatos a solução; isso será melhor descrito no capítulo (4) em que a função será apresentada com todos os detalhes. Diante disso, se faz necessário aplicar métodos de otimização que reduzam o tempo de cálculo da FO e que retorne uma comparação entre dados simulados e observados (poço) igualmente satisfatória, semelhante ao resultado da Força Bruta. Neste caso, são aplicados dois métodos de otimização: Algoritmo Genético (AG) e *Particle Swarm Optimization (PSO)*. Então, executa-se a função objetivo proposta utilizando otimização para avaliar se os resultados e o tempo de execução são aceitáveis. Caso esses critérios não sejam satisfeitos, busca-se o aprimoramento da otimização através de algumas variáveis até que esteja compatível com o resultado da Força Bruta e o tempo seja operacionalmente executável. Esse processo pode ser visualizado na Figura 3.1.

Por fim, é possível tratar da calibração em si. Para calcular a FO, precisa-se de uma definição das fácies observadas nos poços, com base em um conjunto de propriedades de saída do simulador. Uma tabela junta as informações de intervalos de valores das saídas do modelo que servem para definir as fácies. Os dados da tabela de definição das fácies são tratados através de normalização

para evitar que o algoritmo seja enviesado pelas variáveis com maior ordem de grandeza. Esse procedimento tem como objetivo distribuir esses dados dentro do intervalo de valores de 0 (zero) a 1 (um).

Depois de extraídos os dados da simulação, é calculada a distância entre as fácies de cada célula simulada com cada fácies geológicas dos arquivos *.las*. Também são determinadas as fácies em cada célula simulada a partir dos valores resultantes da simulação para cada parâmetro da tabela de definição de fácies.

Por fim, o algoritmo de otimização calcula o valor da FO para cada poço de hidrocarbonetos interpretado e o resultado total é a média ponderada dos valores de cada poço.

Para a realização deste processo também serão aplicados métodos de otimização supracitados. O algoritmo escolhe um conjunto de valores de parâmetros de entrada para realizar a simulação e, após isso, avalia os resultados de acordo com o grau de aproximação com os dados observados (poços) através da função objetivo. Depois, um novo conjunto de valores de parâmetros de entrada é escolhido e um novo valor da função objetivo é calculado, a fim de nortear a busca dos novos parâmetros de entrada, repetindo-se o processo até obter um resultado que seja suficientemente satisfatório, como ilustrado na Figura 3.2. Essa calibração automatizada é então aplicada a estudos de casos para avaliar se os resultados são aceitáveis. Em caso negativo, buscase o aprimoramento da metodologia de calibração, como a aplicação adequada da penalidade para resolver o problema de restrição da FO, a ponderação entre os poços/espessuras no cálculo da FO total, implementação de outras técnicas de otimização, como métodos baseados em gradiente e bayesiana, a refatoração do código para torná-lo mais robusto, entre outros até que esteja resultando em um modelo estratigráfico calibrado adequadamente.

Para a sua validação, a calibração é executada para alguns casos e os resultados são apresentados e discutidos, bem como a conclusão do estudo e perspectivas futuras.

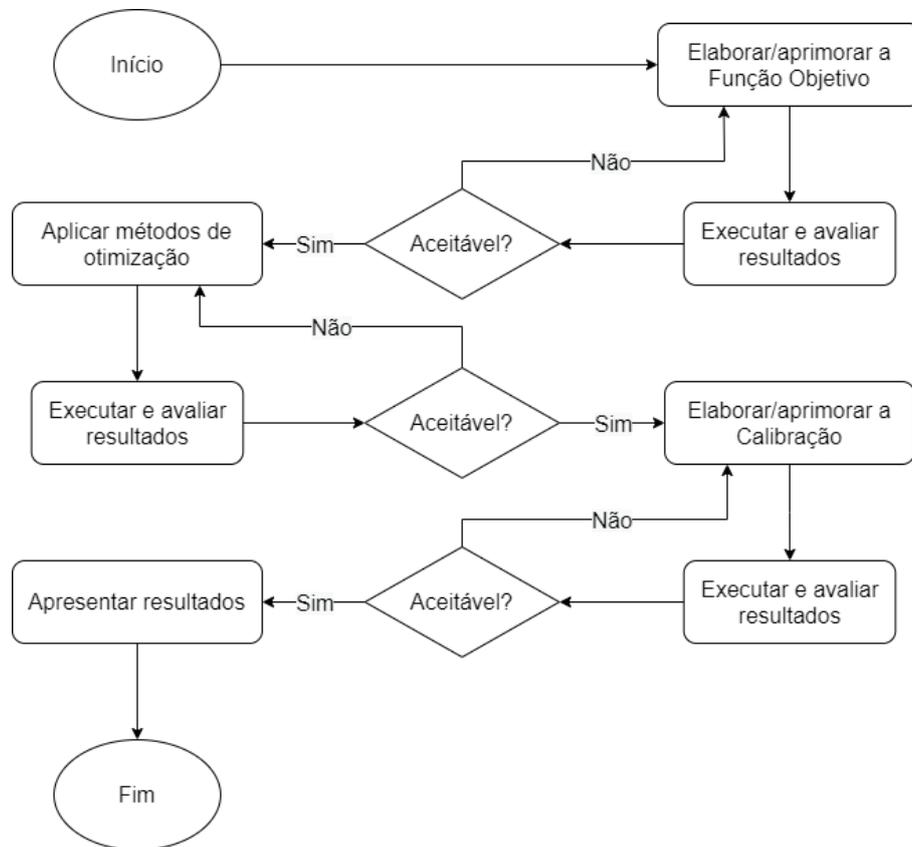
A metodologia adotada para desenvolver uma solução para o problema descrito e alcançar os objetivos propostos é conduzida como uma pesquisa exploratória, visto que a função objetivo e a calibração de modelos *forward* ainda

são pouco praticadas na área de petróleo devido ao alto custo computacional e há possibilidade de desenvolver técnicas mais apropriadas para resolver esse problema. Além disso, também é uma pesquisa aplicada, pois é uma solução prática com viabilidade de utilização na indústria através do algoritmo desenvolvido. Os dados obtidos com a função objetivo resultam em uma análise quantitativa de similaridade, tratados de forma numérica. No entanto, esses dados são interpretados geologicamente em seguida, trazendo também a abordagem qualitativa e tornando esta pesquisa mista.

A Figura 3.1 apresenta o fluxograma da metodologia com todas as etapas desenvolvidas no trabalho e a

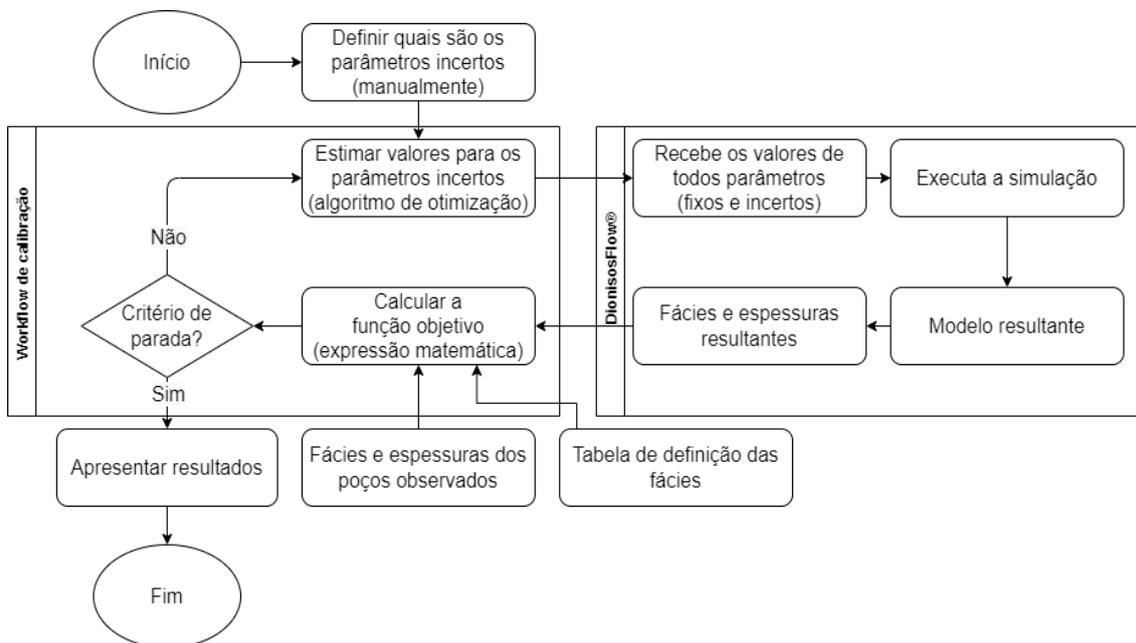
Figura 3.2 ilustra o processo de calibração (otimização externa), descrevendo como o algoritmo busca o melhor modelo baseado nos dados de poços disponíveis, e a Figura 3.3 mostra as etapas do cálculo da função objetivo (otimização interna).

Figura 3.1 – Fluxograma ilustrativo do processo de metodologia para elaboração da função objetivo, calibração e aplicação de métodos de otimização.



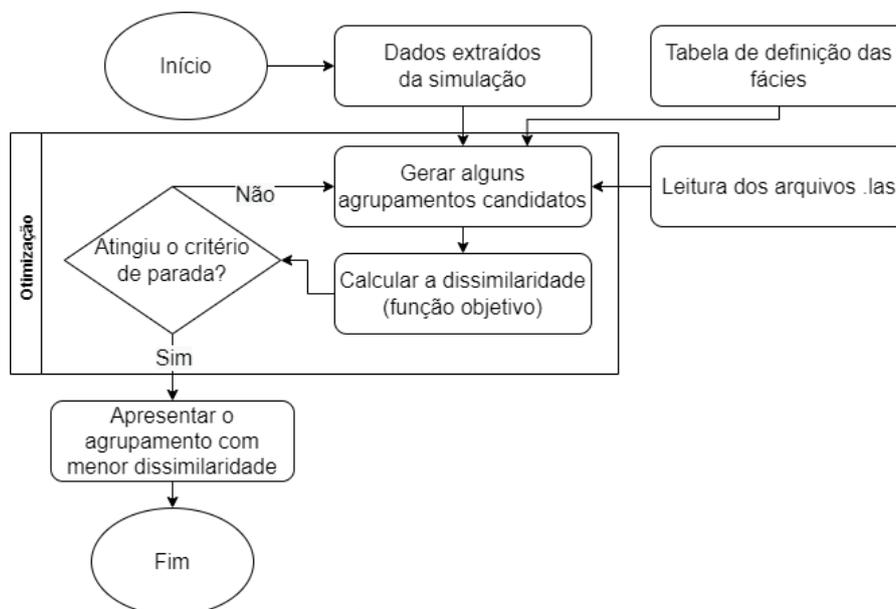
Fonte: elaborado pela autora (2021).

Figura 3.2 – Fluxograma ilustrativo do processo de calibração utilizando métodos de otimização.



Fonte: elaborado pela autora (2021).

Figura 3.3 - Fluxograma ilustrativo do processo de cálculo da função objetivo utilizando métodos de otimização (ilustrados dentro do contêiner).



Fonte: elaborado pela autora (2021).

## 4 MÉTODOS DE OTIMIZAÇÃO APLICADOS A MODELAGEM DE PROCESSOS GEOLÓGICOS

Esse capítulo descreve os métodos de otimização aplicados a modelagem de processos geológicos em si, apresentando o desenvolvimento da nova proposta da função objetivo e a utilização da otimização na simulação de reservatórios na indústria de óleo e gás.

A otimização será utilizada para realizar a calibração dos parâmetros de entrada na simulação estratigráfica do reservatório utilizando a nova função objetivo proposta, a fim de tornar seu valor o menor possível. O valor igual a zero resultante da função objetivo significa que a estratigrafia simulada por meio do software é exatamente igual a estratigrafia observada no poço, para essa localização em questão. Logo, a calibração se dá pela minimização do valor da FO utilizando métodos de otimização.

### 4.1 FUNÇÃO OBJETIVO

Os dados do poço e os dados simulados possuem comprimento total diferentes e são divididos em camadas com espessuras que também podem divergir entre si quando comparadas. Para resolver essa situação e buscando o desenvolvimento de uma função objetivo quantitativa, mas que reproduza os processos geológicos ocorridos, está sendo proposto aqui uma nova abordagem de acordo com Brugognolle *et al.* (2020) na qual se realiza uma transformação nos dados do poço, para que seja possível comparar com os resultados da simulação do *DionisosFlow*®. Essas transformações são, inserção de um hiato, ou seja, um evento geológico de espessura 0m; e adição, que significaria o agrupamento de uma ou até todas as camadas seguintes do poço. Neste caso, o agrupamento poderia gerar uma célula do poço contendo várias fácies, fazendo com que a distância seja ponderada pela ocorrência relativa de cada uma dessas fácies.

Essa abordagem é devida ao fato de que a saída do *DionisosFlow*® é um conjunto de valores resultante dos parâmetros do modelo, com conhecimento das distribuições dos resultados tanto em tempo (taxa de sedimentação), quanto

em espessura. Já o poço possui descrições que não contêm a informação de tempo, fazendo sentido permitir a inserção de hiatos e de considerar várias observações como sendo depositadas num mesmo intervalo de tempo, comparável com o passo de tempo do *DionisosFlow*<sup>®</sup>. Algumas vantagens desta opção são, não assumir que os hiatos acontecem só antes ou depois de um intervalo geológico estudado; não assumir uma taxa de sedimentação constante no poço; não perder nenhuma informação durante o *upscaling* e levar em consideração a proporção de ocorrência de cada fácies na comparação entre o resultado simulado e o observado no poço.

Na nova proposta, a distância relacionada a fácies, será calculada com os valores disponibilizados pelo *DionisosFlow*<sup>®</sup> (por exemplo, batimetria e proporção de areia) para os dados simulados e utilizando-se a tabela para os dados do poço. Ou seja, seleciona-se na tabela a posição da fácies simulada e encontra-se a fronteira mais próxima com a fácies do poço. Através desses valores, é possível calcular uma distância euclidiana e, se houver no agrupamento mais de uma fácies, essa distância é multiplicada pela porcentagem de cada fácies do grupo, gerando uma ponderação para cada fácies. Assim, a nova proposta de função objetivo para calcular a distância entre as fácies se baseia na equação (1) dada por Duan. O termo que na função de Duan que é denotada de distância de Levenshtein, foi reformulado e se dá matematicamente pela equação (3),

$$d^F(\vec{x}, \vec{y}) = \sum_1^{n_F} (\%fácies_i \times d_i^E(\vec{x}, \vec{y})), \quad (3)$$

sendo

$d^F(\vec{x}, \vec{y})$ : distância entre fácies das sequências;

$\%fácies_i$ : porcentagem da fácies  $i$  no agrupamento da sequência do poço;

$d_i^E(\vec{x}, \vec{y})$ : distância euclidiana das fácies  $i$  no agrupamento da sequência do poço, comparada com a fácies da camada simulada;

$n_F$ : número total de fácies no agrupamento da sequência do poço.

Em que a distância euclidiana é definida por

$$d_i^E(\vec{x}, \vec{y}) = \sqrt{(P1_{poço} - P1_{simulado})^2 + \dots + (Pn_{poço} - Pn_{simulado})^2}, \quad (4)$$

sendo

$P_{i_{poço}}$ : parâmetro  $i$  dos dados do poço (exemplo: proporção de areia);

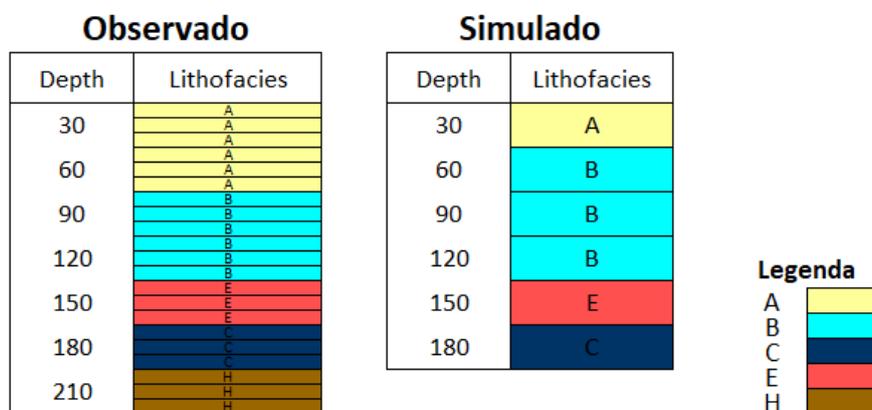
$P_{i_{simulado}}$ : parâmetro  $i$  dos dados simulados (exemplo: proporção de areia);

$n$ : número total de parâmetros.

Portanto, a equação da distância total das sequências  $\vec{x}$  e  $\vec{y}$  é definida de forma similar à função proposta de Duan, dada pela equação (1). Entretanto, o termo  $d^F(\vec{x}, \vec{y})$  foi alterado pela equação (3), como descrito acima.

Uma forma de calcular a função objetivo é realizar seu cálculo para todas as possibilidades de agrupamento possíveis e verificar o menor valor encontrado, isso é chamado de método da Força Bruta. O resultado é o melhor agrupamento dos dados de poço ao correlacioná-lo aos dados simulados. Para ilustrar o cálculo da FO através da Força Bruta, considera-se um exemplo sintético com 21 camadas para os dados do poço com resolução igual a 10m e 6 camadas para os dados simulados com resolução igual a 30m, conforme apresentado na Figura 4.1.

Figura 4.1 - Poço com 21 camadas (esquerda) e dados simulados com 6 células (direita).



Fonte: elaborado pela autora (2022).

O algoritmo proposto simula todas as possibilidades de agrupamento possíveis, a fim de selecionar o agrupamento que resulte na menor distância total. A Tabela 4.1 exibe parte desses agrupamentos para este exemplo sintético, com a numeração inserida na primeira coluna. As outras colunas representam as espessuras e proporção de fácies agrupadas para cada camada dos dados simulados.

Tabela 4.1 - Ilustração dos agrupamentos possíveis (colunas) dos dados de poço para cada camada simulada (linhas) para o exemplo sintético de dados de poço com 21 camadas e dados simulados com 6 camadas.

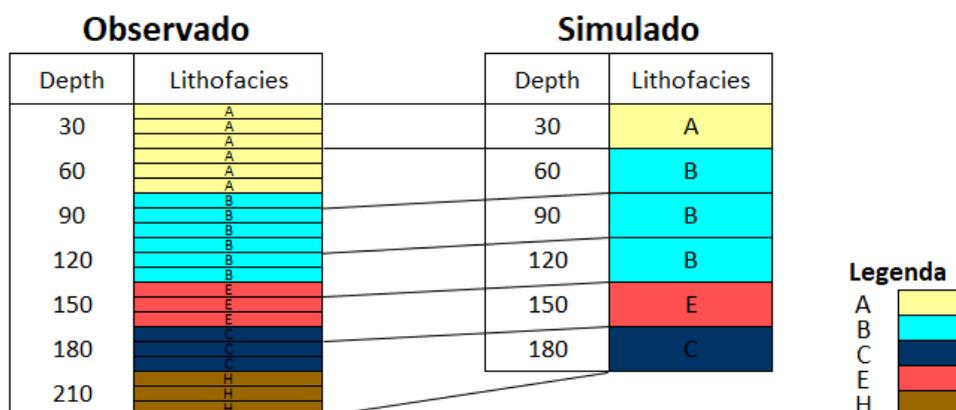
Agrupamento das camadas do poço												
Agrupamento	Camada simulada 1		Camada simulada 2		Camada simulada 3		Camada simulada 4		Camada simulada 5		Camada simulada 6	
	Espessura	Fácies	Espessura	Fácies	Espessura	Fácies	Espessura	Fácies	Espessura	Fácies	Espessura	Fácies
1	Hiato	-	Hiato	-	Hiato	-	Hiato	-	Hiato	-	210	28.6% A; 28.6% B; 14.3% E14.3% C; 14.3% H
2	Hiato	-	Hiato	-	Hiato	-	Hiato	-	10	100% A	200	25.0% A; 30.0% B; 15.0% E15.0% C; 15.0% H
3	Hiato	-	Hiato	-	Hiato	-	Hiato	-	20	100% A	190	21.1% A; 31.6% B; 15.8% E15.8% C; 15.8% H
4	Hiato	-	Hiato	-	Hiato	-	Hiato	-	30	100% A	180	16.7% A; 33.3% B; 16.7% E16.7% C; 16.7% H
...	...	...	...	...	...	...	...	...	...	...	...	...
23	Hiato	-	Hiato	-	Hiato	-	10	100% A	Hiato	-	200	25.0% A; 30.0% B; 15.0% E15.0% C; 15.0% H
24	Hiato	-	Hiato	-	Hiato	-	10	100% A	10	100% A	190	21.1% A; 31.6% B; 15.8% E15.8% C; 15.8% H
25	Hiato	-	Hiato	-	Hiato	-	10	100% A	20	100% A	180	16.7% A; 33.3% B; 16.7% E16.7% C; 16.7% H
26	Hiato	-	Hiato	-	Hiato	-	10	100% A	30	100% A	170	11.8% A; 35.3% B; 17.6% E17.6% C; 17.6% H
...	...	...	...	...	...	...	...	...	...	...	...	...
1794	Hiato	-	Hiato	-	10	100% A	Hiato	-	Hiato	-	30	25.0% A; 30.0% B; 15.0% E15.0% C; 15.0% H
1795	Hiato	-	Hiato	-	10	100% A	Hiato	-	10	100% A	20	21.1% A; 31.6% B; 15.8% E15.8% C; 15.8% H
1796	Hiato	-	Hiato	-	10	100% A	Hiato	-	20	100% A	10	16.7% A; 33.3% B; 16.7% E16.7% C; 16.7% H
1797	Hiato	-	Hiato	-	10	100% A	Hiato	-	30	100% A	0	11.8% A; 35.3% B; 17.6% E17.6% C; 17.6% H
...	...	...	...	...	...	...	...	...	...	...	...	...
65.780	210	28.6% A; 28.6% B; 14.3% E14.3% C; 14.3% H	Hiato	-								

Fonte: elaborado pela autora (2022).

Por exemplo, o agrupamento 1 teria um hiato para as 5 primeiras camadas simuladas e a última camada seria o agrupamento das 21 camadas do poço, resultando em uma espessura de 210m e razão de fácies de 28.6% A; 28.6% B; 14.3% E14.3% C; 14.3% H. Para o agrupamento 25, haveria um hiato para a primeira, segunda e terceira camadas simuladas, uma espessura de 10m de fácies A para a terceira camada simulada, uma espessura de 20m de fácies A para a quarta camada simulada, e as demais 18 camadas do poço restantes formariam a quinta camada, com espessura de 180m e proporção de fácies de 16.7% A; 33.3% B; 16.7% E16.7% C; 16.7% H.

As camadas de dados do poço foram agrupadas de todas as 65.780 formas possíveis, considerando também o hiato. A Figura 4.2 mostra a correlação do melhor agrupamento encontrado, com o valor da FO igual a 30,0.

Figura 4.2 - Correlação entre os dados simulados (esquerda) e as camadas de poços agrupadas como resultado da função objetivo proposta (direita).



Fonte: elaborado pela autora (2022).

O número de combinações aumenta fatorialmente com o número de células simuladas e exponencialmente com o número de dados de poços, o que pode tornar o método impraticável para fins operacionais, pois a Força Bruta envolve um alto custo computacional. Logo, opta-se por utilizar algoritmos de otimização para realizar esse agrupamento para que sequências mais curtas sejam agrupadas em sequências maiores a fim de se adequar aos objetivos.

#### 4.1.1 FORMULAÇÃO MATEMÁTICA DA OTIMIZAÇÃO INTERNA

Como descrito anteriormente, a função objetivo pode ser definida matematicamente pelas equações

$$d^{AS}(\vec{x}, \vec{y}) = \alpha d^F(\vec{x}, \vec{y}) + \beta d^A(\vec{x}', \vec{y}'), \quad (1)$$

$$d^F(\vec{x}, \vec{y}) = \sum_1^{n_F} (\%fácies_i \times d_i^E(\vec{x}, \vec{y})) \quad (3)$$

e

$$d_i^E(\vec{x}, \vec{y}) = \sqrt{(P1_{poço} - P1_{simulado})^2 + \dots + (Pn_{poço} - Pn_{simulado})^2}. \quad (4)$$

Para realizar o cálculo da função objetivo, considera-se o problema de otimização

$$\min d^{AS}(\vec{x}, \vec{y}), \quad \vec{x}', \vec{y}' \in \mathbb{R}_+^n, \quad (5)$$

sendo a espessura total de interesse do poço de hidrocarbonetos  $l_p$ , a espessura total de interesse das células simuladas nas coordenadas do poço  $l_s$  e o número de camadas simuladas  $s$ , as restrições são dadas por

$$\sum x'_i = l_p, \quad i = 1, s, \quad (6)$$

$$\sum y'_j = l_s, \quad j = 1, s. \quad (7)$$

E a região factível do problema é

$$S_1 = \{ \vec{x}', \vec{y}' \in \mathbb{R}_+^n \mid \sum x'_i = l_p, \quad i = 1, p, \sum y'_j = l_s, \quad j = 1, s \}. \quad (8)$$

Logo, a função objetivo tem um mínimo global em  $\vec{x}^*, \vec{y}^*$  para

$$d^{AS}(\vec{x}^*, \vec{y}^*) \leq d^{AS}(\vec{x}, \vec{y}), \quad \forall \vec{x}^*, \vec{y}^* \in S_1. \quad (9)$$

Para o cálculo da FO no workflow de calibração desenvolvido, essas restrições serão tratadas através de uma penalidade expressa matematicamente por

$$\rho(\vec{x}, \vec{y}) = 1 + \mu \left[ \sum x'_i - l_p \right], \quad i = 1, s - 1, \quad (10)$$

para  $\sum_1^{s-1} x'_i > l_p$ , onde a constante  $\mu > 0$  é fixa. Neste caso, trabalha-se com um grau de liberdade a menos e a última camada para  $\sum_1^{s-1} x'_i \leq l_p$  é dependente do agrupamento candidato proposto pelo algoritmo e definida por

$$x'_s = l_p - \sum x'_i, \quad i = 1, s - 1. \quad (11)$$

#### 4.1.2 FORMULAÇÃO MATEMÁTICA DA OTIMIZAÇÃO EXTERNA

A função objetivo total é utilizada para calibrar o modelo completo de um reservatório com vários poços e a FO mostrada na seção anterior é definida localmente poço a poço. Como o objetivo é obter o melhor resultado do modelo envolvendo todos os poços, faz-se necessário a minimização da FO total que pode ser definida de diferentes formas, como a proposta a seguir definida matematicamente pela equação

$$d^T(\vec{z}) = \sum_{k=1}^{np} d^{AS}(\vec{x}, \vec{y}(\vec{z}))_k / np, \quad (12)$$

em que  $d^T$  é a distância total a ser minimizada,  $\vec{z}$  é o *array* de parâmetros inversíveis e  $np$  é o número total de poços. Essa é uma das definições e uma possibilidade de aprimorar o processo de calibração é definir outras formas para o cálculo de  $d^T(\vec{z})$ , ponderando de outras maneiras, através das espessuras dos poços, por exemplo. Para realizar o cálculo da função objetivo total, considera-se o problema de otimização

$$\min d^T(\vec{z}), \quad \vec{z} \in \mathbb{R}^{npi}, \quad (13)$$

sendo  $npi$  o número total de parâmetros inversíveis, a restrição é dada por

$$z_{l_{\min}} < z_l < z_{l_{\max}}, \quad l = 1, npi. \quad (14)$$

E a região factível do problema é

$$S_2 = \{\vec{z} \in \mathbb{R}^{npi} \mid z_{l_{\min}} < z_l < z_{l_{\max}}, \quad l = 1, npi\}. \quad (15)$$

Logo, a função objetivo total tem um mínimo global em  $\vec{z}^*$  para

$$d^T(\vec{z}^*) \leq d^T(\vec{z}), \quad \forall \vec{z}^* \in S_2. \quad (16)$$

## 4.2 ALGORITMO GENÉTICO

O algoritmo inicia com um número de indivíduos (soluções candidatas) aleatórios, ou seja, um número randômico de camadas agrupadas do poço que serão correlacionadas com cada camada do poço simulado. Esses indivíduos formam a primeira população e cada solução terá o seu valor calculado (através da função objetivo já mencionada). Os indivíduos que geram os menores valores da FO iniciarão a segunda geração de indivíduos (hereditariedade com seleção natural). Essa segunda geração também terá indivíduos com cruzamento (troca do valor de uma das camadas pelo valor de outra camada) e mutação (valores aleatórios, assim como a população inicial). O valor da FO será calculado para cada indivíduo da segunda população também e os indivíduos respectivos aos menores valores iniciarão a terceira população, com cruzamento e mutação também. Novas populações serão geradas até atingir o número máximo de iterações totais (número de populações) ou o número máximo de iterações sem que ocorra alteração no valor da função objetivo.

O algoritmo genético utilizado neste trabalho foi implementado utilizando a biblioteca "*genetic algorithm*" no Python (SOLGI, 2020). Para isso, é necessário inserir alguns argumentos para criar o modelo e posteriormente executá-lo. O primeiro argumento é a função objetivo que irá ser calculada para cada correlação possível entre o poço simulado e o poço observado. O número de variáveis a serem otimizadas (dimensão do problema) para achar a melhor correlação é dado pelo número de camadas simuladas, ou seja, a espessura de cada camada no poço de maneira a permitir a comparação com os dados de simulação. E, por fim, é informado os limites da variável, ou seja, a espessura máxima de cada camada do poço. Essa espessura pode variar de 0 (hiato) até a espessura total do poço. Outros argumentos permitem controlar o funcionamento próprio do algoritmo: o número da população (padrão: 100 correlações/indivíduos por geração/iteração de otimização), porcentagem de indivíduos que a nova geração irá herdar da geração anterior (padrão: 30%), a probabilidade de ocorrer cruzamento na nova geração (padrão: 50%) e a probabilidade de ocorrer mutação na nova geração (padrão: 10%).

Para melhor entendimento, considera-se um exemplo executado no algoritmo para ilustrar o funcionamento do mesmo. Assim, tem-se que a primeira iteração ocorre de forma 100% aleatória. Na Figura 4.3, tem-se 5 camadas simuladas (número de colunas) e 10 indivíduos para cada geração (número de linhas). Cada célula irá receber um número aleatório dentro do limite estabelecido (0 a 21 camadas do poço) que será o número de camadas agrupadas do poço. E para cada indivíduo (cada linha) será calculado o valor da função objetivo. Além disso, pelas restrições propostas nas Equações (6) e (7), é necessário que a soma de camadas do agrupamento, soma de cada linha, seja igual à soma de camadas do poço de hidrocarbonetos (observado). Por isso, é imposta uma penalidade para as soluções candidatas que não satisfaçam a restrição.

Figura 4.3 – Inicialização da otimização através do algoritmo genético com cada célula recebendo uma espessura aleatória (cuja soma corresponde a espessura total do poço) para a criação das “camadas” de maneira a permitir a comparação com o poço simulado. Cada uma das 5 colunas representa a espessura das camadas e cada uma das 10 linhas representa um indivíduo da geração atual.

Indivíduo	Camada simulada				
	1	2	3	4	5
1	0	4	12	8	7
2	20	5	1	2	5
3	10	15	9	10	1
4	5	15	3	19	8
5	7	13	2	18	17
6	13	18	16	12	4
7	15	5	14	12	19
8	15	5	14	12	19
9	18	9	12	20	6
10	7	21	20	14	18

Fonte: elaborado pela autora (2022).

Para a segunda iteração em diante, o algoritmo irá selecionar uma porcentagem dos indivíduos que apresentaram menor valor da função objetivo da geração anterior e os demais indivíduos terão uma chance de ocorrer

cruzamento e/ou mutação. E após algumas gerações, a primeira solução viável, que satisfaz a restrição, é encontrada e está representada na Figura 4.4.

Figura 4.4 – Primeira população a apresentar uma solução candidata que satisfaz a restrição, representada pelo indivíduo 1.

Camada simulada					
Indivíduo	1	2	3	4	5
1	1	9	10	1	0
2	5	2	9	8	6
3	1	5	9	6	13
4	11	1	5	21	2
5	5	9	19	5	6
6	19	5	18	4	7
7	15	8	18	7	6
8	12	12	9	5	17
9	17	11	14	18	9
10	15	18	9	19	20

Fonte: elaborado pela autora (2022).

Supondo que os indivíduos 1 e 4 do exemplo tiveram os menores valores após calcular a função objetivo, tem-se o início da próxima geração, conforme mostra a Figura 4.5.

Figura 4.5 - Seleção dos indivíduos que apresentaram menor valor da função objetivo para iniciar a geração seguinte.

Camada simulada					
Indivíduo	1	2	3	4	5
1	1	9	10	1	0
2	5	2	9	8	6
3	1	5	9	6	13
4	11	1	5	21	2
5	5	9	19	5	6
6	19	5	18	4	7
7	15	8	18	7	6
8	12	12	9	5	17
9	17	11	14	18	9
10	15	18	9	19	20



Camada simulada					
Indivíduo	1	2	3	4	5
1	1	9	10	1	0
2	1	9	10	1	0
3	11	1	5	21	2
4	1	9	10	1	0
5					
6					
7					
8					
9					
10					

Fonte: elaborado pela autora (2022).

O cruzamento é a troca do valor de uma das células da geração anterior por outra célula diferente também da geração anterior. No exemplo, tem-se que o sexto indivíduo é igual ao terceiro, porém com a segunda célula trocada pela

quinta célula do primeiro indivíduo. Este cruzamento está destacado em vermelho na Figura 4.6 para exemplificar.

Figura 4.6 - Representação de alguns cruzamentos para os indivíduos 4 a 8.

Indivíduo	Camada simulada				
	1	2	3	4	5
1	1	9	10	1	0
2	1	9	10	1	0
3	11	1	5	21	2
4	1	9	10	1	0
5	16	1	5	21	2
6	19	0	5	21	2
7	11	1	5	21	2
8	11	6	5	21	2
9	11	1	5	21	2
10	11	1	5	21	2

Fonte: elaborado pela autora (2020).

As mutações são realizadas de duas formas. Em uma delas, a célula irá receber um número aleatório dentro do limite estabelecido pela espessura total do poço, semelhante à primeira geração, como é possível observar nos indivíduos 5 e 6. No segundo tipo de mutação, a célula irá receber um número aleatório dentro intervalo de outros dois indivíduos. No exemplo, o oitavo indivíduo terá sua segunda célula preenchida por valores aleatórios no intervalo dos números das células do primeiro e terceiro indivíduos, conforme representado na Figura 4.7.

Figura 4.7 - Representação de mutações para os indivíduos 5, 6 e 8.

Indivíduo	Camada simulada					Indivíduo	Camada simulada				
	1	2	3	4	5		1	2	3	4	5
1	1	9	10	1	0	1	1	9	10	1	0
2	1	9	10	1	0	2	1	9	10	1	0
3	11	1	5	21	2	3	11	1	5	21	2
4	1	9	10	1	0	4	1	9	10	1	0
5	16	1	5	21	2	5	16	1	5	21	2
6	19	0	5	21	2	6	19	0	5	21	2
7	11	1	5	21	2	7	11	1	5	21	2
8	11	(1,9)	5	21	2	8	11	6	5	21	2
9	11	1	5	21	2	9	11	1	5	21	2
10	11	1	5	21	2	10	11	1	5	21	2

Fonte: elaborado pela autora (2022).

As iterações são executadas até que ocorra o critério de parada. Sendo que este pode ser de dois tipos: número máximo de iterações totais ou número máximo de iterações sem que ocorra alteração no valor da função objetivo, ou seja, sem a descoberta de agrupamentos que levem a um valor menor da função objetivo. Por fim, o resultado é o agrupamento referente ao menor valor calculado da função objetivo.

### 4.3 PARTICLE SWARM OPTIMIZATION

No caso deste trabalho, o PSO é utilizado para procurar a melhor correlação possível, o que significa a melhor maneira de comparar o poço simulado com o poço observado, no menor tempo possível. Além disso, é inspirado no comportamento social de algumas espécies de animais (partículas) quando estão em conjunto (enxame), em que o movimento de cada partícula é influenciado pelo melhor resultado local conhecido, guiando para o melhor resultado global, atualizando a população a cada iteração.

O PSO foi implementado utilizando a biblioteca “*pyswarm*” no Python (LEE, 2014). Para isso, é necessário inserir alguns argumentos. O primeiro argumento é a função objetivo que irá ser calculada para cada conjunto de camadas agrupadas. O limite inferior e superior que a variável pode assumir são o segundo e o terceiro argumento respectivamente e é dado pelo intervalo possível de espessura de cada camada de zero para um hiato até a espessura total do poço. Outros argumentos permitem controlar o funcionamento próprio do algoritmo: o número de partículas de cada geração (padrão: 100), o fator de escala da velocidade da partícula  $\Omega$  (padrão: 0,5), o fator de escala para procurar longe da melhor posição conhecida da partícula  $\phi_p$  (padrão: 0,5) e o fator de escala para procurar longe da melhor posição conhecida da população  $\phi_g$  (padrão: 0,5).

Para melhor entendimento, considera-se um exemplo para ilustrar o funcionamento do algoritmo. Deste modo, tem-se que a primeira iteração ocorre de forma 100% randômica. Na Figura 4.8, tem-se 5 camadas simuladas (número de colunas) e 10 partículas para cada geração (número de linhas). Cada partícula irá receber um número aleatório dentro do limite estabelecido de

espessuras (0 a 21 camadas do poço). Para cada partícula (correlação) será calculado o valor da função objetivo. Além disso, pelas restrições impostas nas Equações (6) e (7), é necessário que a soma de camadas do agrupamento, soma de cada linha, seja igual à soma de camadas do poço de hidrocarbonetos (observado). Por isso, é imposta uma penalidade para as soluções candidatas que não satisfaçam a restrição.

Figura 4.8 - Inicialização da otimização através do PSO com cada célula recebendo uma espessura aleatória (cuja soma corresponde a espessura total do poço) para a criação das camadas, de maneira a permitir a comparação com o poço simulado. Cada uma das 5 colunas representa a espessura das camadas e cada uma das 10 linhas representa um indivíduo da geração atual.

$x_{ij}^0$	Dimensão (camada simulada)				
Partícula	1	2	3	4	5
1	11	4	14	0	7
2	21	13	5	19	9
3	18	3	11	18	0
4	20	4	2	16	7
5	13	8	10	9	12
6	13	3	5	6	20
7	18	7	1	15	4
8	20	6	18	10	3
9	16	3	12	19	3
10	15	8	12	18	10

Fonte: elaborado pela autora (2022).

Também é calculada a velocidade inicial de cada partícula para todas as dimensões (número de camadas simuladas) através das equações,

$$v_{max} = n_p - 0, \quad (17)$$

$$v_{min} = -v_{max}, \quad (18)$$

$$v_{ij} = v_{min} + r(v_{max} - v_{min}), \quad (19)$$

sendo  $v_{max}$  e  $v_{min}$  as velocidades máxima e mínima, respectivamente;  $n_p$  o número de camadas do poço;  $v_{ij}$  a velocidade da partícula  $i$  na dimensão  $j$  e  $r$  um número aleatório.

Figura 4.9 – Resultado do cálculo das velocidades das partículas da geração inicial do método.

$v_{ij}^0$	Dimensão (camada simulada)				
	1	2	3	4	5
<b>Partícula</b>					
<b>1</b>	-8	-10	-5	19	9
<b>2</b>	-1	-15	-10	13	6
<b>3</b>	-9	-21	-3	-19	3
<b>4</b>	-11	-3	-1	-6	20
<b>5</b>	7	11	0	9	-21
<b>6</b>	-16	13	-11	4	18
<b>7</b>	7	1	-5	-1	-13
<b>8</b>	16	-15	-18	-9	-9
<b>9</b>	-19	9	10	-11	-3
<b>10</b>	-14	15	8	14	-15

Fonte: elaborado pela autora (2022).

Assim, para a próxima iteração em diante, o algoritmo irá calcular a nova velocidade de cada partícula para todas as dimensões (número de camadas simuladas) por meio da equação

$$v_{ij}^k = \Omega \cdot v_{ij}^{k-1} + \phi_p r_1 (p - x_{ij}^{k-1}) + \phi_g r_2 (g - x_{ij}^{k-1}), \quad (20)$$

sendo  $v_{ij}^k$  e  $v_{ij}^{k-1}$  as velocidades da partícula  $i$  na dimensão  $j$  da população/iteração atual ( $k$ ) e anterior ( $k - 1$ ), respectivamente;  $\Omega$  o fator de escala da velocidade da partícula;  $\phi_p$  e  $\phi_g$  são os fatores de escala para se afastar do melhor agrupamento conhecido da população atual e anterior, respectivamente;  $p$  o agrupamento referente ao menor valor da função objetivo encontrado na população atual;  $x_{ij}^{k-1}$  o agrupamento da partícula  $i$  na dimensão  $j$  da população anterior;  $g$  o agrupamento referente ao menor valor da função objetivo encontrado na população anterior;  $r_1$  e  $r_2$  números aleatórios.

Tem-se o resultado do cálculo das velocidades das partículas da próxima geração, conforme apresentado na Figura 4.10.

Figura 4.10 - Resultado do cálculo das velocidades das partículas da próxima geração do método.

$v_{ij}^1$	Dimensão (camada simulada)				
	1	2	3	4	5
<b>Partícula</b>					
<b>1</b>	-4	-5	-3	10	4
<b>2</b>	-1	-15	-10	13	6
<b>3</b>	-9	-21	-3	-19	3
<b>4</b>	-11	-3	0	-6	20
<b>5</b>	7	11	0	9	-21
<b>6</b>	-16	13	-11	4	18
<b>7</b>	7	1	-5	-1	-13
<b>8</b>	16	-15	-18	-9	-9
<b>9</b>	-19	9	10	-11	-3
<b>10</b>	-14	15	8	14	-15

Fonte: elaborado pela autora (2022).

Portanto, com a velocidade calculada, é possível obter os novos agrupamentos através da seguinte equação (21),

$$x_{ij}^k = x_{ij}^{k-1} + v_{ij}^k, \quad (21)$$

sendo  $x_{ij}^k$  e  $x_{ij}^{k-1}$  os agrupamentos da partícula  $i$  na dimensão  $j$  da população atual ( $k$ ) e anterior ( $k - 1$ ), respectivamente e  $v_{ij}^k$  velocidade da partícula  $i$  na dimensão  $j$  da população atual.

Figura 4.11 - Resultado do cálculo do valor das partículas da próxima geração do método. Cada uma das 5 colunas representa a camada simulada e cada uma das 10 linhas representa uma partícula da geração em questão.

$x_{ij}^1$	Dimensão (camada simulada)				
Partícula	1	2	3	4	5
1	7	1	11	10	11
2	20	2	5	21	15
3	9	18	8	1	3
4	9	1	2	10	21
5	20	19	10	18	9
6	3	16	6	10	21
7	21	8	4	14	9
8	21	9	0	1	6
9	3	12	21	8	0
10	1	21	20	21	5

Fonte: elaborado pela autora (2022).

E após algumas gerações, a primeira solução viável, que satisfaz a restrição, é encontrada e está representada na Figura 4.12.

Figura 4.12 - Primeira população a apresentar uma solução candidata que satisfaz a restrição, representada pelo indivíduo 1 destacado em vermelho.

$x_{ij}^{\dots}$	Dimensão (camada simulada)				
Partícula	1	2	3	4	5
1	9	0	9	0	3
2	4	0	6	0	7
3	7	0	10	0	8
4	4	0	11	0	8
5	8	0	10	1	3
6	7	7	11	1	4
7	12	0	9	0	2
8	8	0	7	0	3
9	6	4	11	0	3
10	4	6	13	1	1

Fonte: elaborado pela autora (2022).

Assim, as iterações são executadas até que ocorra o critério de parada, sendo o número máximo de iterações totais. Por fim, o resultado é o agrupamento referente ao menor valor calculado da função objetivo.

## 5 APLICAÇÃO E RESULTADOS

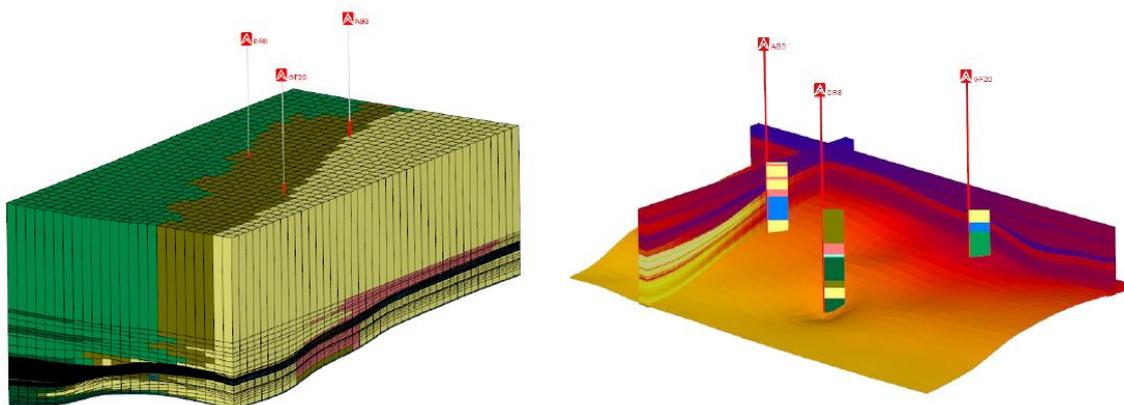
As abordagens descritas nas seções anteriores foram implementadas e aplicadas em diferentes estudos de casos buscando validar a metodologia aqui proposta e avaliar o desempenho dos métodos. Primeiramente, foram aplicadas para casos sintéticos criados para avaliar o desempenho do cálculo da FO pela Força Bruta<sup>1</sup>, por Dijkstra e pelos métodos de otimização por AG e PSO. Posteriormente, para avaliar o comportamento e validar a FO, como também o desenvolvimento da metodologia da calibração dos modelos *forward*, foram realizadas análises com estudos de casos com um modelo de referência do software *DionisosFlow*®, que descreve um modelo mais próximo da realidade da indústria.

A validação e a análise dos resultados do fluxo de trabalho de calibração foram realizadas por meio de vários testes. Os testes iniciais foram realizados com os dados do tutorial *DionisosFlow*®, mais especificamente o tutorial *Mixed Model* (BEICIP-FRANLAB, 2017). Esse modelo é derivado de um estudo de caso real do período Paleogeno (70 a 24 milhões de anos), com um reservatório misto de carbonato de recife do Eoceno (segunda época do Paleogeno) e rocha selante clástica do Oligoceno (terceira época do Paleogeno), com influência de sobrecarga nas espessuras e com dimensões 84.000m (42 células) por 50.000m (25 células). Os três poços de hidrocarbonetos de referência (GF20, DR8 e AB3), representados na Figura 5.1, foram construídos a partir dos resultados da simulação utilizando os mesmos valores de parâmetros usados no tutorial. Os três poços simulados também são resultantes da simulação, de acordo com os parâmetros escolhidos pelos próprios métodos de otimização.

---

<sup>1</sup> Método em que a dissimilaridade entre o poço simulado e o poço observado (FO) é calculada para todos os agrupamentos possíveis (todas as combinações).

Figura 5.1 – Representação da localização dos três poços do *Mixed Model*.



Fonte: BEICIP-FRANLAB (2017).

O modelo *Mixed* contém quatro tipos de sedimentos, são eles: areia, silte, carbonato e recife. Todos os sedimentos possuem seus respectivos tamanho de grão e densidades, e são utilizados na simulação de mapas de proporção de sedimentos, demais propriedades e parâmetros para definição de fácies. Areia e silte chegam ao domínio através de duas fontes de aporte de sedimentos siliciclásticos, ambas localizadas nas fronteiras do modelo, com aportes sendo realizados ao longo dos intervalos de tempo definidos. A fonte S1 está localizada ao sul do modelo e adiciona sedimentos ao ambiente no período compreendido entre 70Ma a 28,5Ma. Já a fonte S2, também localizada ao sul, está ativa somente no período entre 70Ma a 65Ma. Os sedimentos carbonato e recife são produzidos em função do tempo e da profundidade e, por sua vez, a produção é influenciada por parâmetros ambientais como: energia das ondas, transporte de sedimentos e conteúdo de sedimentos em solo marinho. Para este modelo, a produção de carbonatos é fixada em 20 metros por Ma para todos os intervalos de idades (70, 58, 56, 39 e 0Ma) e sua eficiência de produção é definida para faixas batimétricas de 0 a 100 metros.

Simulado o modelo, são definidas as fácies a partir dos mapas de proporção de sedimentos e outras propriedades. Ao todo são criadas dez fácies, sendo importante lembrar que a fácies *unknown* representam todas as células do modelo que não se encaixam em outras fácies definidas pelo usuário. A Figura 5.2 a seguir reúne todas as fácies definidas para o modelo *Mixed*.

Figura 5.2 – Todas as fácies definidas no *Mixed Model* a partir de intervalos de valores de propriedades.

1	Unknown	
2	Facies_Carbonate	
3	Facies_Reef	
4	Facies_Sand	
5	Facies_DeepSilt	
6	Mixed_Clastics	
7	Mixed_Carbo	
8	Mixed_CarboSilt	
9	Facies_ShallowSilt	
10	Facies_SandChannel	

Fonte: BEICIP-FRANLAB (2017).

Para a definição das fácies, são utilizadas as proporções de silte, areia, carbonato e recife, a batimetria e o fluxo de água. A Tabela 5.1 mostra os parâmetros mínimos e máximos para cada propriedade, que são usados para identificar as fácies com base nos resultados do modelo.

Tabela 5.1 - Tabela de definição de fácies utilizada no *Mixed Model*.

Name	Bathymetry		Water		Carbonate		Reef		Sand		Silt	
	Min	Max	Min	Max	Min	Max	Min	Max	Min	Max	Min	Max
Facies_Carbonate					50	max						
Facies_Reef							50	max				
Facies_Sand									50	max		
Facies_SandChannel			85	max					50	max		
Facies_ShallowSilt	min	50									50	max
Facies_DeepSilt	50	max									50	max
Mixed_Carbo					15	50	15	50				
Mixed_Clastics									15	50	15	50
Mixed_CarboSilt					15	50					15	50

Fonte: BEICIP-FRANLAB (2017).

É importante observar que para o cálculo da função objetivo (otimização interna) de todos os testes, foi selecionado o método de Dijkstra por sempre resultar no mínimo global e obter esse valor de forma rápida, como poderá ser observado nos resultados apresentados na Tabela 5.2. Uma vez que na segunda

parte dos testes, focada na calibração, se faz necessário reduzir ruídos e obter os valores da função objetivo em tempo computacional praticável.

## 5.1 ANÁLISE DO COMPORTAMENTO DA FUNÇÃO OBJETIVO

### 5.1.1 Casos Sintéticos

Os primeiros estudos foram realizados para casos sintéticos considerando diferentes números de camadas para os poços e para os dados simulados. Os pesos  $\alpha$  e  $\beta$  são responsáveis por atribuir mais influência da distância entre fácies e da distância entre o atributo de espessura, respectivamente. Logo, manipulando esses valores, é possível gerar resultados em que as fácies tenham mais relevância ou as espessuras tenham mais interesse. Desta forma, a influência desses pesos foi estudada tanto para valores equivalentes (iguais a 1), quanto para valores diferentes, alterando o valor de  $\beta$  para 0,125. Neste caso, diferentes valores para os coeficientes de peso levam a agrupamentos diferentes, escolhidos heurísticamente ou por tentativa e erro, de acordo com os resultados gerados. O valor de  $\alpha$  seria maior para dar mais importância às fácies na correlação entre dados simulados e dados de poço. Os resultados do agrupamento ajudam a refinar a análise de sequências intermediárias, determinando de maneira correta e confiável os tipos de sequências curtas e seus padrões de agrupamento, fornecendo uma correlação de alta resolução de fácies entre dois poços. Foram realizados vários testes a fim de avaliar o desempenho e os resultados destas abordagens em termos de tempo computacional e valor da FO. No caso sintético mais simples, estudo de caso (1), foram consideradas 2 células de simulação (pseudo-poço) e 200 dados do poço (de hidrocarboneto). Para o estudo de caso (2) em diante, é aumentada uma célula simulada para cada até o caso (11), para que seja possível avaliar o aumento no tempo de execução. Os estudos de caso (12) e (13) possuem 4 células de simulação e 400 e 800 camadas do poço de hidrocarbonetos, respectivamente. Enquanto os estudos de caso (14) e (15) possuem 5 células de simulação e 400 e 800 camadas do poço de hidrocarbonetos, respectivamente. Os resultados obtidos estão apresentados na Tabela 5.2, em

que a primeira coluna apresenta o caso tratado, a segunda coluna informa o peso  $\beta$  adotado, a terceira, quarta, quinta e sexta colunas mostram o valor calculado para a FO, bem como o tempo de execução do código para a Força Bruta, Dijkstra, AG e PSO, respectivamente. As últimas duas colunas correspondem ao erro relativo (diferença percentual entre o valor exato e o valor obtido) gerado pelas abordagens do AG e PSO, em relação aos resultados obtidos por Dijkstra como referência, respectivamente.

Tabela 5.2– Comparação entre resultados da Força Bruta e os algoritmos de Dijkstra, AG e PSO.

Estudo de caso	$\beta$	Força Bruta	Dijkstra	AG	PSO	Erro relativo AG	Erro relativo PSO
(1)	1	FO: 26,296 Tempo: 0,016s	FO: 26,296 Tempo: 0,02s	FO: 26,298 Tempo: 2,564s	FO: 26,296 Tempo: 0,708s	0.0%	0.0%
200 células	0,125	FO: 3,546 Tempo: 0,022s	FO: 3,546 Tempo: 0,02s	FO: 3,546 Tempo: 2,276s	FO: 3,546 Tempo: 0,686s	0.0%	0.0%
camadas							
(2)	1	FO: 25,35 Tempo: 0,047s	FO: 25,35 Tempo: 0,013s	FO: 25,356 Tempo: 2,281s	FO: 25,35 Tempo: 0,869s	0.0%	0.0%
3 células	0,125	FO: 3,475 Tempo: 0,042s	FO: 3,475 Tempo: 0,011s	FO: 3,487 Tempo: 2,322s	FO: 3,475 Tempo: 0,881s	0.3%	0.0%
200 células							
camadas							
(3)	1	FO: 20,115 Tempo: 1,818s	FO: 20,115 Tempo: 0,024s	FO: 20,139 Tempo: 2,338s	FO: 20,115 Tempo: 1,016s	0.1%	0.0%
4 células	0,125	FO: 2,987 Tempo: 1,852s	FO: 2,987 Tempo: 0,023s	FO: 3,14 Tempo: 2,287s	FO: 3,14 Tempo: 0,999s	5.1%	5.1%
200 células							
camadas							
(4)	1	FO: 18,572 Tempo: 107s	FO: 18,572 Tempo: 0,034s	FO: 19,112 Tempo: 2,294s	FO: 18,879 Tempo: 1,066s	3.1%	1.8%
5 células	0,125	FO: 2,734 Tempo: 102s	FO: 2,734 Tempo: 0,034s	FO: 3,321 Tempo: 2,131s	FO: 2,757 Tempo: 1,206s	21.5%	0.8%
400 células							
camadas							
(5)	1	FO: 16,594 Tempo: 15902s	FO: 16,594 Tempo: 0,05s	FO: 16,735 Tempo: 2,085s	FO: 16,621 Tempo: 1,306s	0.8%	0.2%
6 células	0,125	FO: 2,575 Tempo: 55267s	FO: 2,575 Tempo: 0,045s	FO: 3,129 Tempo: 2,201s	FO: 2,621 Tempo: 1,302s	21.5%	1.8%
800 células							
camadas							
(6)	1	FO: 16,929 Tempo: 1132010s	FO: 16,929 Tempo: 0,06s	FO: 17,836 Tempo: 1,93s	FO: 17,06 Tempo: 1,476s	5.4%	0.8%
7 células	0,125		FO: 2,754 Tempo: 0,057s	FO: 2,882 Tempo: 2,12s	FO: 3,348 Tempo: 1,268s	4.6%	21.6%
200 células							
camadas							
(7)	1		FO: 13,189 Tempo: 0,071s	FO: 14,333 Tempo: 1,637s	FO: 13,75 Tempo: 1,479s	8.7%	4.3%
8 células	0,125		FO: 2,366 Tempo: 0,068s	FO: 2,976 Tempo: 1,998s	FO: 2,669 Tempo: 1,632s	25.8%	12.8%
200 células							
camadas							
(8)	1		FO: 3,696 Tempo: 0,086s	FO: 7,424 Tempo: 1,878s	FO: 11,507 Tempo: 1,576s	100.9%	211.3%
9 células	0,125		FO: 2,261 Tempo: 0,082s	FO: 3,78 Tempo: 1,84s	FO: 2,454 Tempo: 1,522s	67.2%	8.5%
200 células							
camadas							
(9)	1		FO: 3,696 Tempo: 0,093s	FO: 10,318 Tempo: 1,647s	FO: 13,973 Tempo: 1,822s	179.2%	278.1%
10 células	0,125		FO: 2,261 Tempo: 0,094s	FO: 3,513 Tempo: 1,561s	FO: 3,121 Tempo: 1,551s	55.4%	38.0%
200 células							
camadas							
(10)	1		FO: 4,597 Tempo: 0,106s	FO: 20,672 Tempo: 1,439s	FO: 11,176 Tempo: 1,748s	349.7%	143.1%
11 células	0,125		FO: 2,322 Tempo: 0,104s	FO: 4,968 Tempo: 1,794s	FO: 4,422 Tempo: 2,187s	114.0%	90.4%
200 células							
camadas							
(11)	1		FO: 5,784 Tempo: 0,119s	FO: 21,582 Tempo: 1,519s	FO: 6,053 Tempo: 2,246s	273.1%	4.7%
12 células	0,125		FO: 2,636 Tempo: 0,122s	FO: 4,139 Tempo: 1,486s	FO: 4,433 Tempo: 2,356s	57.0%	68.2%
200 células							
camadas							
(12)	1	FO: 59,893 Tempo: 17s	FO: 59,893 Tempo: 0,094s	FO: 59,944 Tempo: 2,658s	FO: 60,149 Tempo: 1,31s	0.1%	0.4%
4 células	0,125	FO: 7,905 Tempo: 17s	FO: 7,905 Tempo: 0,083s	FO: 7,925 Tempo: 2,644s	FO: 7,918 Tempo: 1,429s	0.3%	0.2%
400 células							
camadas							
(13)	1	FO: 139,828 Tempo: 151s	FO: 139,828 Tempo: 0,317s	FO: 139,923 Tempo: 3,028s	FO: 140,025 Tempo: 2,239s	0.1%	0.1%
4 células	0,125	FO: 17,853 Tempo: 150s	FO: 17,853 Tempo: 0,311s	FO: 17,872 Tempo: 3,429s	FO: 18,07 Tempo: 2,18s	0.1%	1.2%
800 células							
camadas							
(14)	1	FO: 58,498 Tempo: 1828s	FO: 58,498 Tempo: 0,147s	FO: 58,787 Tempo: 2,762s	FO: 58,765 Tempo: 1,471s	0.5%	0.5%
5 células	0,125	FO: 7,661 Tempo: 326353s	FO: 7,661 Tempo: 0,124s	FO: 7,71 Tempo: 2,507s	FO: 7,683 Tempo: 1,719s	0.6%	0.3%
400 células							
camadas							
(15)	1	FO: 138,478 Tempo: 101315057s	FO: 138,478 Tempo: 0,485s	FO: 138,735 Tempo: 3,182s	FO: 138,725 Tempo: 2,388s	0.2%	0.2%
5 células	0,125		FO: 17,64 Tempo: 0,467s	FO: 17,897 Tempo: 3,031s	FO: 17,879 Tempo: 2,339s	1.5%	1.4%
800 células							
camadas							

Fonte: elaborado pela autora (2022).

Analisando a Tabela 5.2, para os estudos de caso (1), (2), (12), (13), (14) e (15), os valores obtidos da FO são idênticos ou muito próximos para todos os métodos, demonstrando que em diversos casos a melhor correlação foi encontrada também nos métodos de otimização ou houve um erro relativo menor do que 2%. O que demonstra que os algoritmos AG e PSO não foram capazes de encontrar a melhor correlação, mas unicamente uma aproximação dessa. Isso ocorre quando o método encontra um mínimo local e, mesmo buscando soluções candidatas aleatórias, não consegue se afastar desse mínimo para buscar o ótimo global.

Entre os estudos de caso de (3) a (7), somente quatro valores encontrados superaram 20% de erro relativo, sendo eles os casos (4), (5) e (7) para o AG e o caso (6) para o PSO, todos para  $\beta = 0,125$ . Esses métodos também resultaram em uma redução drástica do tempo necessário para encontrar a melhor correlação, se comparado à Força Bruta. Por exemplo, para o estudo de caso (5), o resultado foi obtido na ordem de horas pela Força Bruta, enquanto pelo AG e PSO isso ocorreu na ordem de segundos. A melhora no desempenho é ainda mais visível e significativa quando se avalia os resultados obtidos para o estudo de caso (6), onde Força Bruta levou aproximadamente 13 dias para ser executada completamente, enquanto o resultado foi encontrado em menos de 3 segundos com o AG e o PSO, com valores da FO dentro de um erro aceitável.

O estudo de caso de (8) a (11), no entanto, apresentam divergências mais significativas dos resultados dados pelo AG e PSO ao compará-los com o algoritmo de Dijkstra. É importante observar que o cálculo da FO pelo método da Força Bruta em casos maiores é extremamente lento, demorando dias, o que se torna impraticável; neste caso, optou-se pela comparação com o método de Dijkstra que também sempre resulta em um mínimo global, mas com uma execução em menos de 1 segundo. Por mais versáteis que sejam os métodos de otimização AG e PSO, não é possível garantir que o mínimo global será encontrado sempre, resultando algumas vezes em um valor com erro relativo acima de 100%, sendo 350% o maior erro relativo entre todos os testes da tabela, obtido através do AG no caso (10) para  $\beta = 1$ . Como  $\beta$  é o peso da distância entre atributos (espessura), o valor da FO é maior para os casos em que  $\beta = 1$  porque há grandes diferenças entre as espessuras totais dos poços.

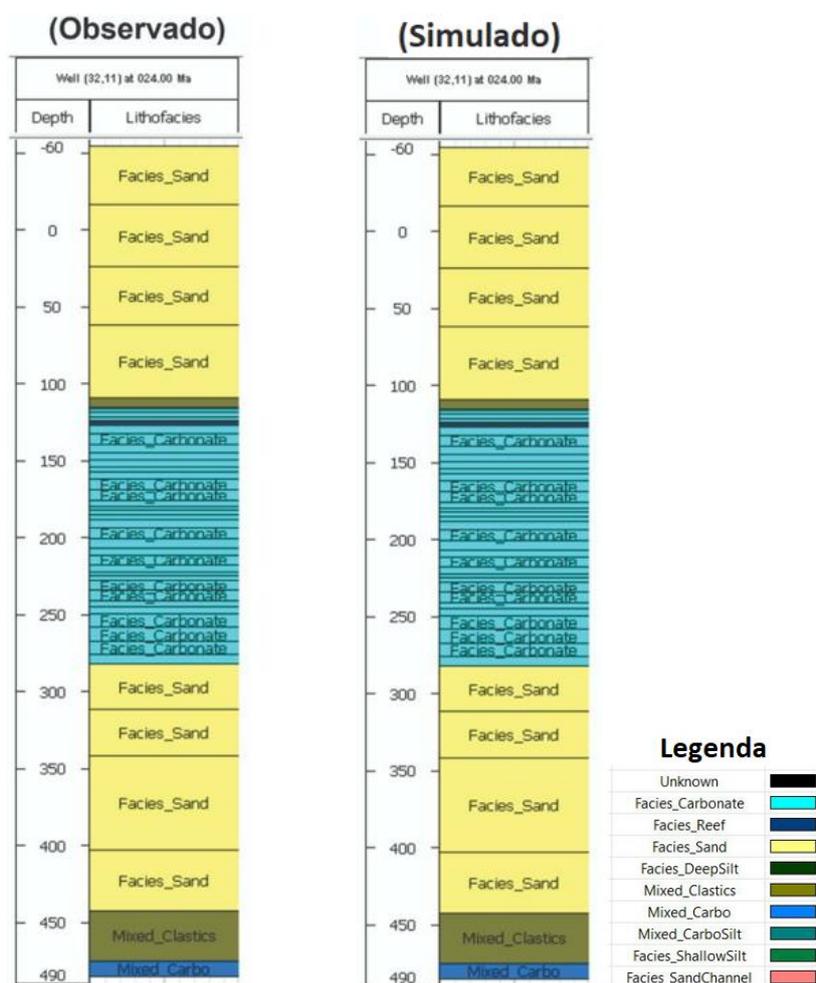
Logo, o erro relativo nesses casos também é maior, justamente por dar mais peso a essas espessuras. Também se verifica que esses erros relativos acima de 100% foram para casos em que o número de células simuladas foi aumentado, não as camadas do poço. Isso demonstra que a dificuldade dessa otimização está em dividir os dados geológicos em um determinado número de camadas, que quanto maior for, mais complexo para encontrar os melhores agrupamentos será.

Foi possível perceber que a aleatoriedade na população inicial do método influencia os resultados da FO através das otimizações. Ou seja, se a primeira população leva a um bom resultado, é mais fácil refinar esse valor nas próximas iterações do que iniciando com uma população/solução muito longe do mínimo global. Além disso, como o algoritmo também toma uma direção baseado nos valores obtidos inicialmente é mais fácil cair em um mínimo local e não ser capaz de sair dessa solução, mesmo com muitas iterações.

### **5.1.2 Validação da Função Objetivo**

O primeiro teste com o modelo de referência *Mixed Model* do *Dionisos Flow*® é a validação da função objetivo quanto a sua concepção e implementação. No qual, a comparação se deu entre poços de hidrocarbonetos criados didaticamente a partir de uma simulação com determinados parâmetros de entrada e poços simulados utilizados os mesmos valores. Logo, as espessuras e as fácies do poço observado e do poço simulado comparados são exatamente iguais, sendo constatada a validação da função quando o valor da função objetivo for igual a 0 (zero). Após a execução do algoritmo para esse teste, o valor da função objetivo calculada para o poço AB3 foi igual a  $3,52 \times 10^{-9}$ . A Figura 5.3 ilustra as fácies e respectivas espessuras dos dois poços, observado à esquerda e simulado à direita, que são iguais.

Figura 5.3 – Sequência geológica de dois poços iguais, observado à esquerda e simulado à direita.



Fonte: elaborado pela autora no DionisosFlow® (2021).

### 5.1.3 Análise do Comportamento da Função Objetivo

O segundo teste é a verificação do comportamento dos parâmetros incertos (ou inversíveis) para avaliar a regularidade da FO, ou seja, se ela apresenta um comportamento suave, convexo que admite um mínimo global. Neste caso, apenas um parâmetro foi alterado a cada execução do algoritmo de calibração e os valores testados foram definidos através de intervalos regulares dentro de uma faixa de valores predeterminada. Para essa análise, foram considerados os três poços de hidrocarbonetos de referência citados anteriormente e o cálculo será realizado pela ponderação destes, ou seja, a FO total definida na Equação (12).

Primeiramente foi analisado o comportamento da FO para o parâmetro 'coeficiente de difusão de areia'. Neste caso foram realizadas 26 simulações com um valor de referência igual a 130,5m<sup>2</sup>/ano em um intervalo de 0 a 261m<sup>2</sup>/ano. Outro parâmetro que o comportamento foi analisado foi a 'altura para cálculo do volume de sedimentos da fonte 1'. Para este parâmetro, foram realizadas 100 simulações com um valor de referência igual a 2240km em um intervalo de 0 a 4480km.

Os melhores valores para os parâmetros identificados pela Força Bruta<sup>2</sup>, seus respectivos valores da FO e erros relativos quando comparados com os valores de referência estão apresentados na Tabela 5.3. Note que em ambos os parâmetros foi possível identificar o valor ótimo possível dentro do intervalo predeterminado.

Tabela 5.3 - Comparação dos resultados da força bruta na calibração de um parâmetro inversível.

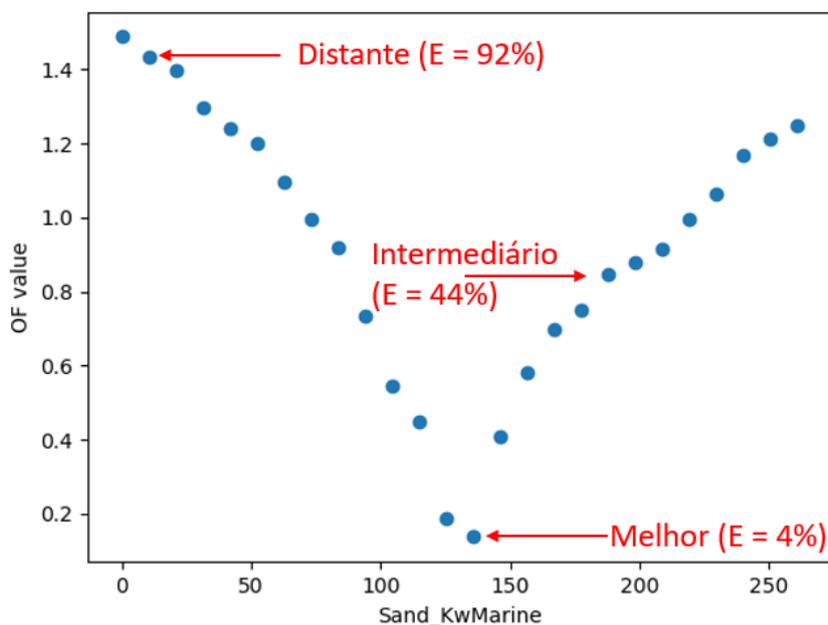
<b>Estudo de caso</b>	<b>Referência</b>	<b>Força Bruta</b>	<b>Erro relativo</b>
<b>Coeficiente de difusão de areia (m<sup>2</sup>/ano)</b>	Valor: 130,55	Valor: 135,725 FO: 0,138	4.0%
<b>Altura para o cálculo do volume de sedimento da fonte 1 (km)</b>	Valor: 2240	Valor: 2217,37 FO: 0,20	1.0%

Fonte: elaborado pela autora (2022).

Como os valores foram definidos através de intervalos regulares, o valor testado mais próximo da referência foi exatamente o resultado da calibração. A Figura 5.4 e a Figura 5.5 destacam ainda três valores testados para os parâmetros: um distante do valor de referência, outro intermediário e o melhor resultado encontrado. É possível visualizar através das curvas dos parâmetros pelo valor da FO que o comportamento destes é suave, convexo e admite um mínimo global. O valor da função objetivo aumenta à medida que o valor do parâmetro se afasta da referência.

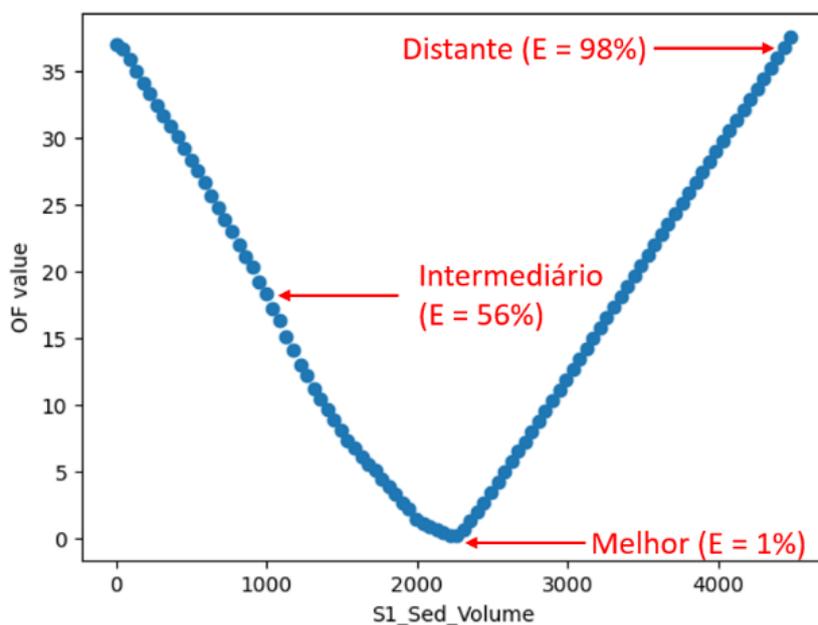
<sup>2</sup> Método em que os valores para os parâmetros incertos são testados em intervalos regulares.

Figura 5.4 – Gráfico do parâmetro incerto ‘coeficiente de difusão de areia’ pelo valor da FO total com três pontos destacados: distante, intermediário e melhor, com seus respectivos erros relativos.



Fonte: elaborado pela autora (2021).

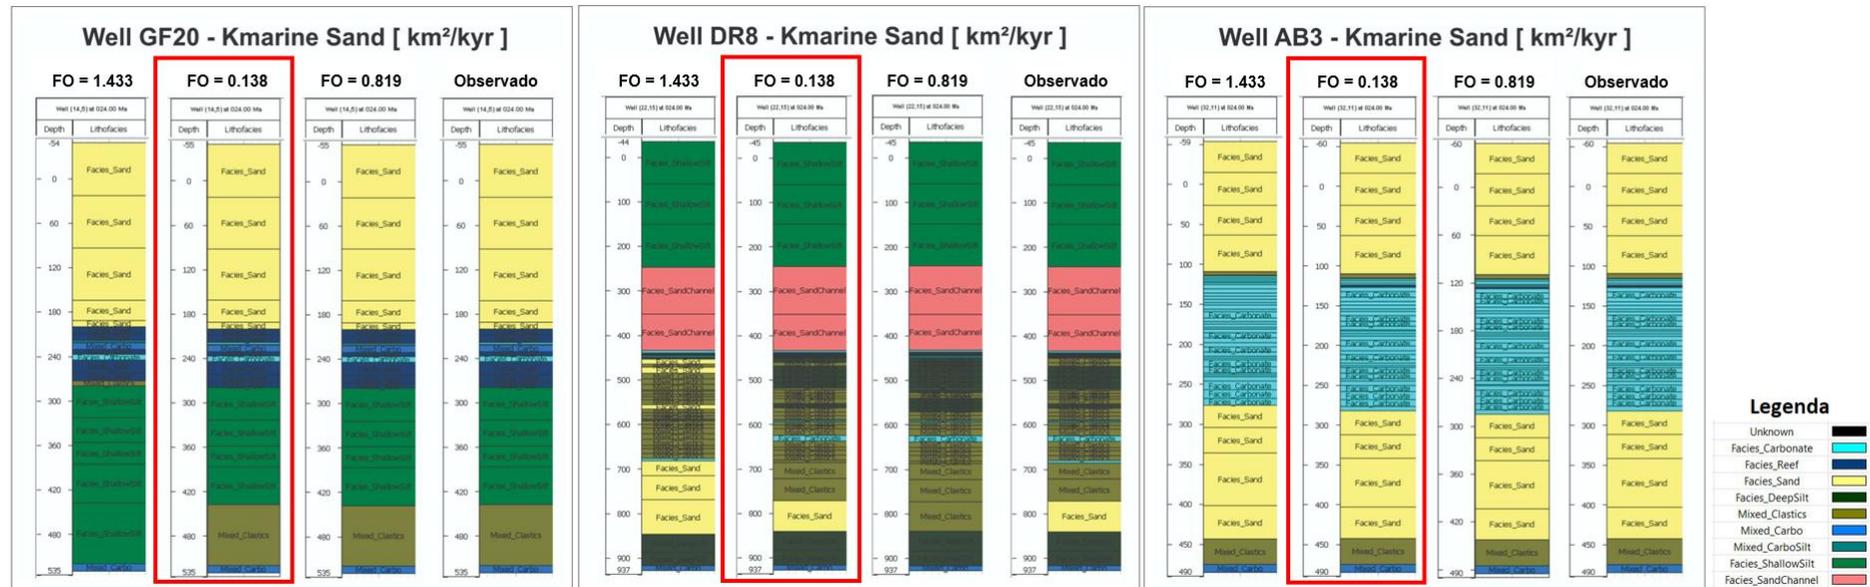
Figura 5.5 - Gráfico do parâmetro incerto ‘altura para cálculo do volume de sedimentos da fonte 1’ pelo valor da FO total com três pontos destacados: distante, intermediário e melhor, com seus respectivos erros relativos.



Fonte: elaborado pela autora (2021).

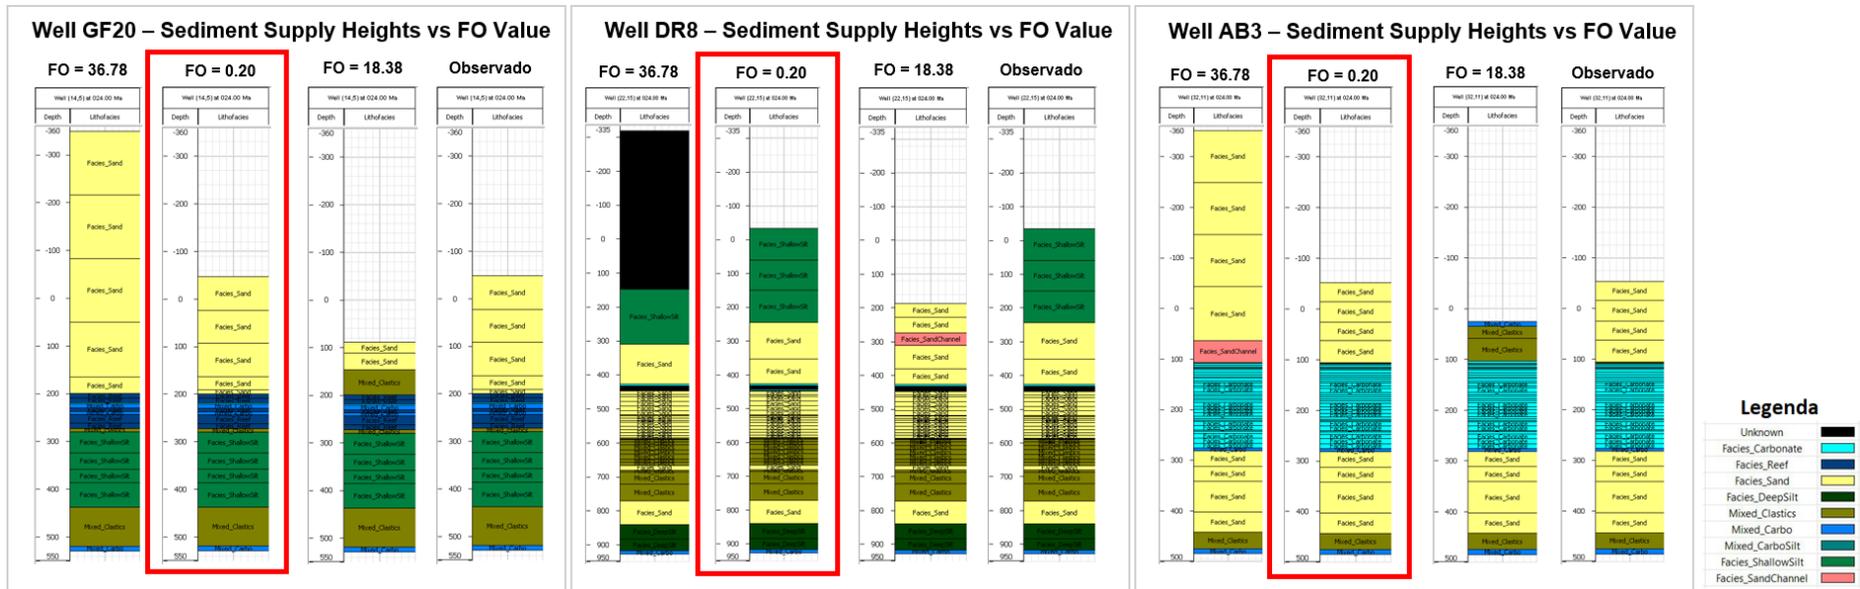
Para avaliar melhor os resultados fornecidos para este teste, foram extraídas as sequências dos pontos destacados nos gráficos que são apresentadas a seguir. A Figura 5.6 e a Figura 5.7 mostram sequências para os três poços (GF20, DR8 e AB3) para o caso teste do 'coeficiente de difusão de areia' e da 'altura para o cálculo do volume de sedimento da fonte 1', respectivamente. Em cada uma, tem-se da esquerda para a direita: a primeira sequência para um valor distante da referência, a segunda destacada pela borda vermelha para o melhor resultado encontrado, a terceira para um valor intermediário e a quarta sequência mais à direita sendo o poço de hidrocarbonetos (ou observado). As sequências dos poços auxiliam a compreender o comportamento da FO. É importante observar que mesmo não havendo diferenças geologicamente significativas, a FO consegue identificá-las. Pode-se notar que para o valor mais distante da referência (poço à esquerda), a sequência geológica possui fácies e espessuras diferentes do poço observado quando comparados. E quanto mais próximo da referência o valor do parâmetro estiver, melhor será sua correlação com o poço observado. Por exemplo, quando a FO é igual a 1,433 para a Figura 5.6, há muita diferença na base do poço DR8. Essas diferenças são significativamente reduzidas ao usar valores ótimos para os parâmetros, como pode ser notado nas sequências dos poços para o melhor valor encontrado, onde é quase imperceptível visualmente, honrando as sequências dos poços tanto em fácies como em espessuras quando comparadas com os poços observados.

Figura 5.6 - Sequências dos poços GF20, DR8 e AB3 obtidas com diferentes valores para o parâmetro incerto 'coeficiente de difusão de areia'. Da esquerda para a direita para cada poço: distante da referência, melhor valor (destacado com um contorno em vermelho), intermediário e poço observado.



Fonte: elaborado pela autora no DionisosFlow® (2021).

Figura 5.7 - Sequências dos poços GF20, DR8 e AB3 obtidas com diferentes valores para o parâmetro incerto ‘altura para o cálculo do volume de sedimento da fonte 1’. Da esquerda para a direita para cada poço: distante da referência, melhor valor (destacado com um contorno em vermelho), intermediário e poço observado.



Fonte: elaborado pela autora no DionisosFlow® (2021).

Vale observar que os resultados obtidos para *Mixed Model* do *Dionisos Flow*, tanto quanto a validação como para análise de comportamento da FO para ambos os parâmetros, apresentam excelentes resultados. Uma vez que os resultados da FO identificam quando os poços observados e poços simulados são idênticos, como também quando são dissimilares ou estão muito semelhantes. Isso pode ser comprovado tanto nos valores da FO resultantes, como também nas figuras que ilustram as sequências das simulações nas posições dos poços obtidas com diferentes valores para os parâmetros avaliados. Além disso, para ambos os parâmetros selecionados pode comprovar o potencial da FO, a qual apresenta um excelente comportamento, que indica que ao aplicar métodos de otimização poderemos ter resultados surpreendentes positivos.

## 5.2 ANÁLISE DO FLUXO DE TRABALHO DA CALIBRAÇÃO

Buscando analisar o desempenho do fluxo de trabalho da calibração, como também o desempenho dos métodos de otimização AG e PSO aplicados para obter os melhores parâmetros que resultam no modelo calibrado, foram realizados diferentes testes.

Em um primeiro momento, todos os outros parâmetros são mantidos fixos enquanto um parâmetro incerto é calibrado, ou seja, apenas um parâmetro foi alterado a cada execução do algoritmo de calibração. Sendo o coeficiente de difusão de areia em uma execução do workflow e a altura para o cálculo do volume de sedimento da fonte 1 em outra execução, parâmetros para os quais foram analisados o comportamento da FO na seção anterior. Depois, foram considerados quatro parâmetros incertos a serem calibrados, os quais são variados simultaneamente, sendo eles a altura para o cálculo da vazão fluvial em duas fontes diferentes (S1 e S2), na primeira fonte para as idades 70 e 28 milhões de anos e na segunda fonte para as idades 70 e 65 milhões de anos. Para isso, também foram considerados os três poços de hidrocarbonetos de referência citados anteriormente e o cálculo será realizado pela ponderação destes, ou seja, a FO total definida na Equação (12).

### 5.2.1 Estudo de caso 1: Calibração de um parâmetro inversível - *Mixed*

Primeiramente, apenas um parâmetro foi alterado a cada execução do algoritmo de calibração e os valores testados foram definidos pelos métodos de otimização PSO e AG. Para o parâmetro ‘coeficiente de difusão de areia’, foram realizadas 15 simulações totais (3 iterações com população de 5 indivíduos) com um valor de referência igual a 130,55m<sup>2</sup>/ano em um intervalo de 65,255m<sup>2</sup>/ano a 195,755m<sup>2</sup>/ano. Enquanto que para o parâmetro ‘altura para o cálculo do volume de sedimento da fonte 1’, foram realizadas 20 simulações totais (4 iterações com população de 5 indivíduos) com um valor de referência igual a 2240km em um intervalo de 1120km a 3360km.

Os resultados obtidos para os melhores parâmetros com os algoritmos PSO e AG são mostrados na Tabela 5.4. É importante ressaltar sobre o tempo computacional para a realização destes testes do fluxo de trabalho de calibração. Para executá-lo com um parâmetro incerto utilizando os algoritmos AG e PSO, os tempos foram na ordem de 14 a 21 min.

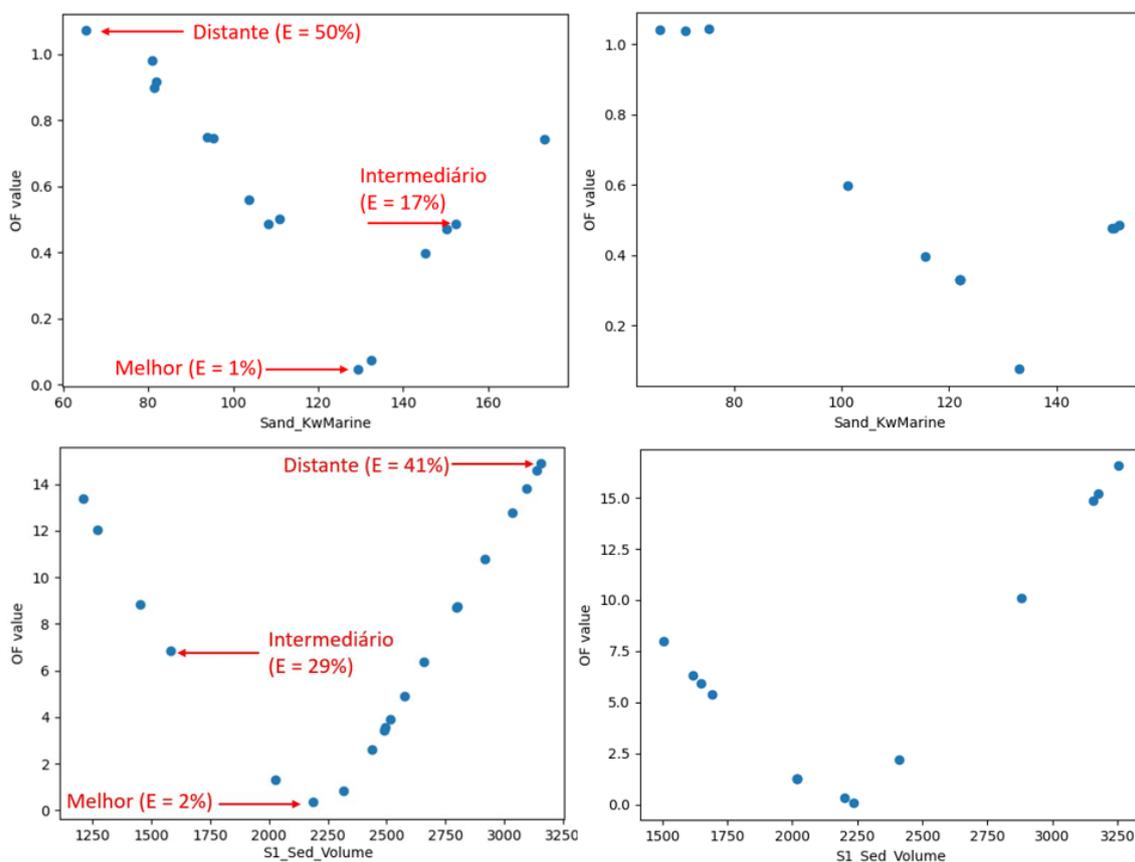
Tabela 5.4 - Comparação entre resultados da calibração de um parâmetro inversível pelos algoritmos AG e PSO.

Estudo de caso	Referência	AG	PSO	Erro relativo AG	Erro relativo PSO
<b>Coeficiente de difusão de areia (m<sup>2</sup>/ano)</b>	Valor: 130,55	Valor: 132,98 FO: 0,076	Valor: 129,315 FO: 0,046	1.9%	0.9%
<b>Altura para o cálculo do volume de sedimento da fonte 1 (km)</b>	Valor: 2240	Valor: 2236,12 FO: 0,056	Valor: 2187,12 FO: 0,349	0.2%	2.4%

Fonte: elaborado pela autora (2022).

A Figura 5.8 mostra os gráficos do comportamento para o ‘coeficiente de difusão de areia’ pelo ‘OF value’ (topo) e o comportamento para a ‘altura para o cálculo do volume de sedimento da fonte 1’ (base) pelo ‘OF value’ obtidos pelos algoritmos PSO (direita) e AG (esquerda).

Figura 5.8 - Gráfico do parâmetro incerto 'coeficiente de difusão de areia' no topo para o PSO (esquerda- com pontos destacados para avaliação das sequências dos poços) e o AG (direita) e do parâmetro incerto 'altura para o cálculo do volume de sedimento da fonte 1' na base para o PSO (esquerda- com pontos destacados para avaliação das sequências dos poços) e o AG (direita).



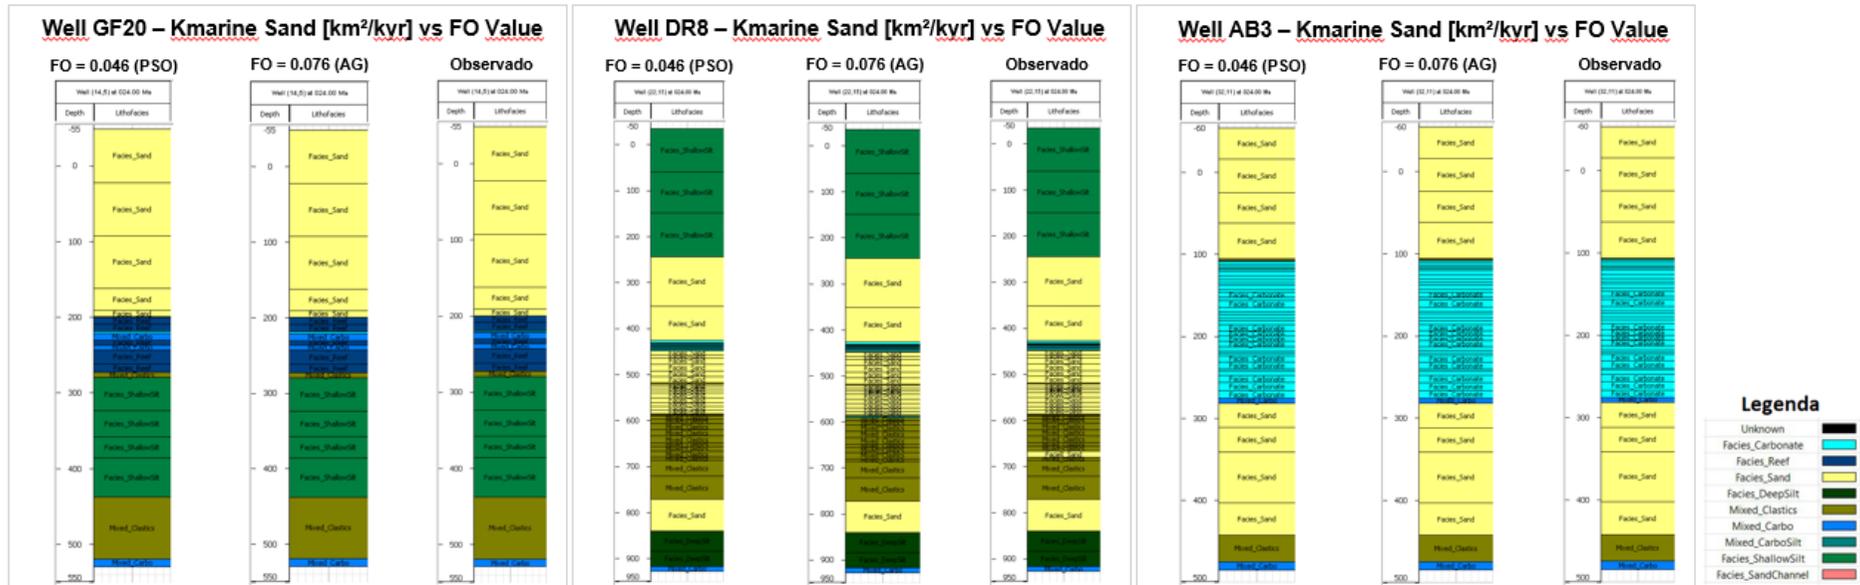
Fonte: elaborado pela autora (2021).

Como era de se esperar, estes gráficos validam as análises realizadas nos testes de análise de comportamento da FO, no qual os parâmetros variaram em intervalos regulares predeterminados, mostrando que ao aplicar os algoritmos de otimização é possível obter valores ótimos para os parâmetros estudados com um número bem reduzido de simulações. Nota-se que a altura para o cálculo do volume de sedimento da fonte 1 apresenta um gráfico de função convexa, enquanto o gráfico do coeficiente de difusão de areia possui alguns mínimos locais. Ainda assim, ambos apresentam um comportamento geral interessante para a calibração, em que ambos direcionam para o valor

ótimo no vértice da parábola. Além disso, o AG possui herança de pais e cruzamento entre os indivíduos durante a aplicação do método, como consequência alguns valores são repetidos entre as gerações, fazendo com que o gráfico tenha menos pontos do que o número de iterações, já que alguns estão sobrepostos.

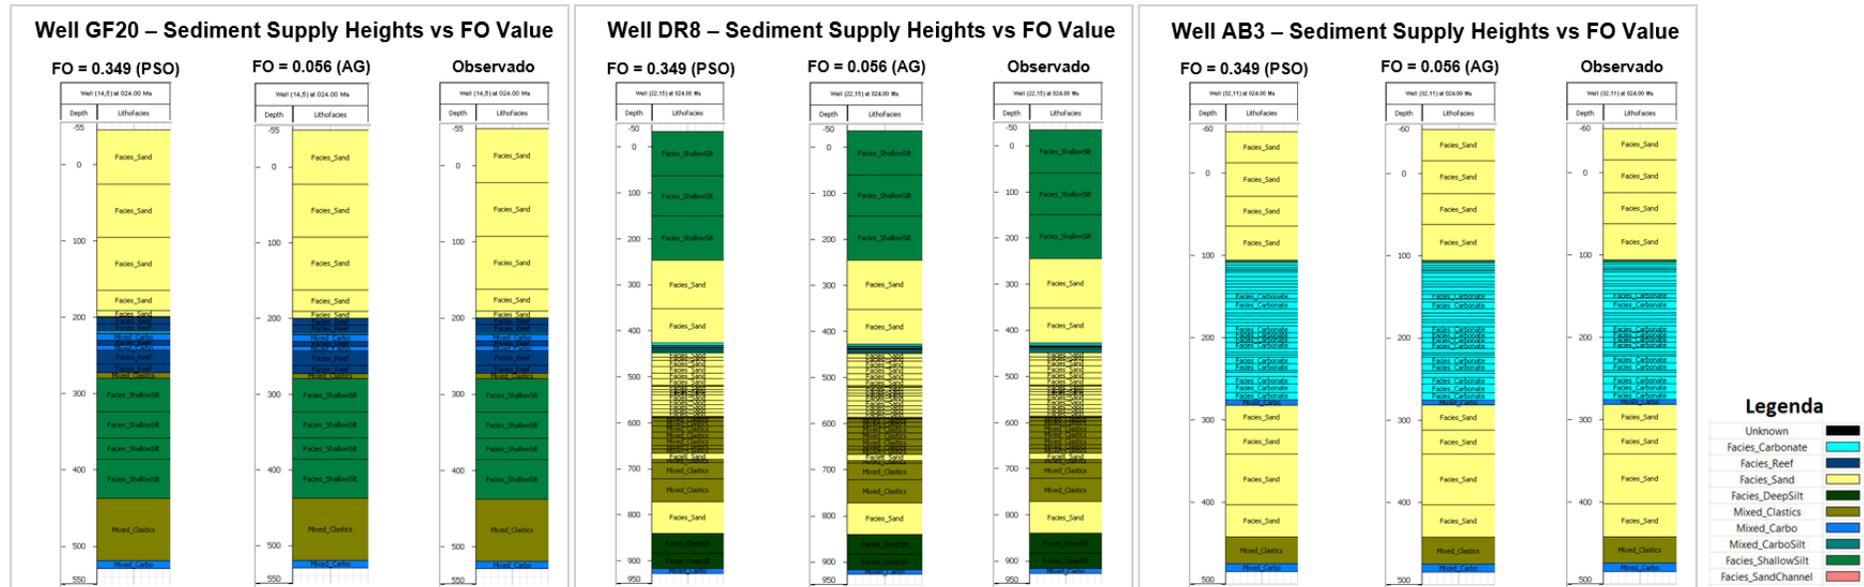
A Figura 5.9 e a Figura 5.10 abaixo mostram as sequências para os três poços, ilustrando o melhor valor encontrado com os algoritmos PSO e AG na calibração, nos testes do 'coeficiente de difusão de areia' e 'altura para o cálculo do volume de sedimento da fonte 1', respectivamente. O objetivo destas figuras é comparar o desempenho de ambos os algoritmos. Note que os resultados obtidos por ambos foram muito similares, tanto as sequências das fácies como também nas espessuras destas.

Figura 5.9 - Sequências do poço GF20, DR8 e AB3, correspondentes aos valores ótimos obtidos pelos algoritmos PSO e AG para o parâmetro incerto 'coeficiente de difusão de areia'. Da esquerda para a direita: melhor valor calibrado pelo PSO, melhor valor calibrado pelo AG e poço observado.



Fonte: elaborado pela autora no DionisosFlow® (2021).

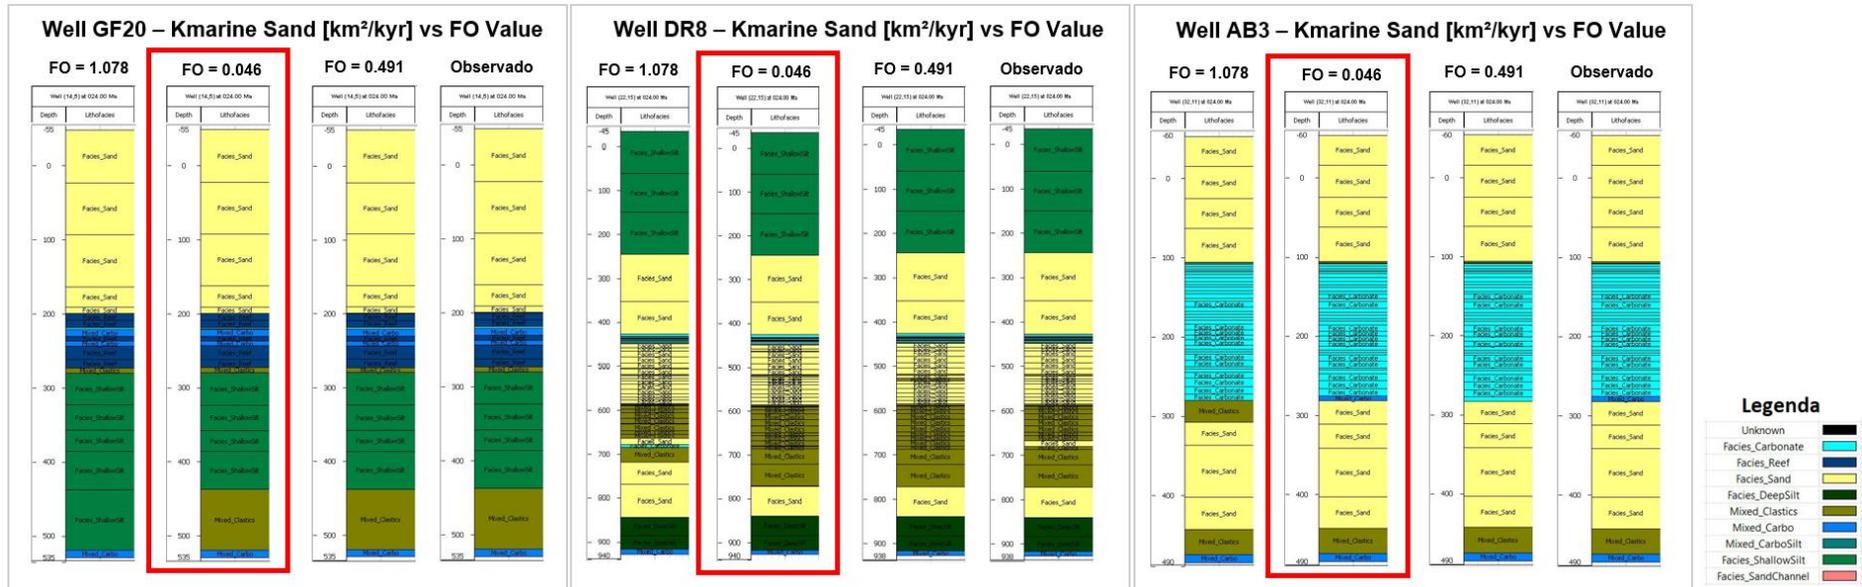
Figura 5.10 - Sequências do poço GF20, DR8 e AB3, correspondentes aos valores ótimos obtidos pelos algoritmos PSO e AG para o parâmetro incerto 'altura para o cálculo do volume de sedimento da fonte 1'. Da esquerda para a direita: melhor valor calibrado pelo PSO, melhor valor calibrado pelo AG e poço observado.



Fonte: elaborado pela autora no DionisosFlow® (2021).

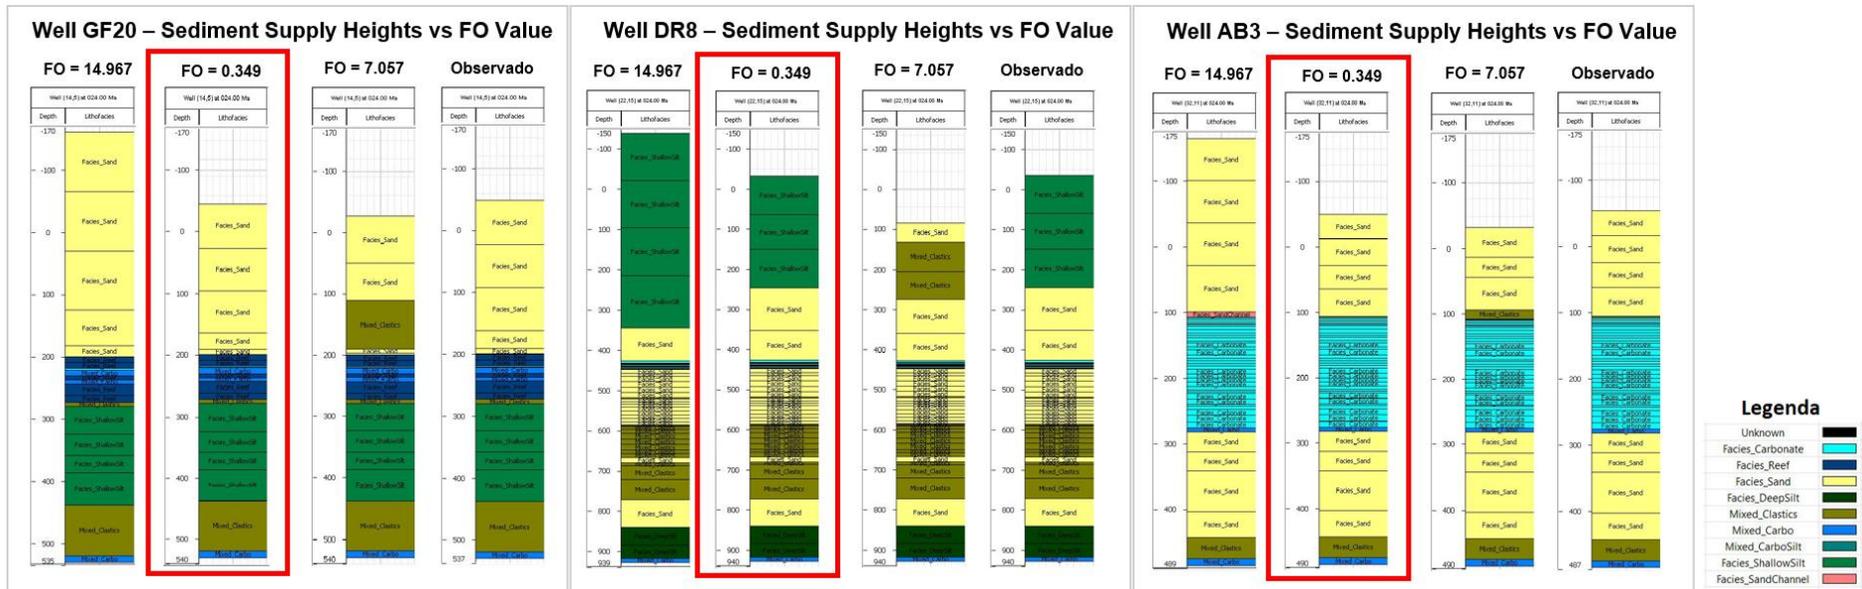
A Figura 5.11 e a Figura 5.12 mostram as sequências para os mesmos poços para os dois parâmetros incertos novamente. Entretanto, neste caso ilustrando a comparação do poço observado com: o melhor valor (meio), um valor intermediário (direita) e o valor mais distante (esquerda). Os valores foram obtidos pelo algoritmo PSO, nos pontos destacados no gráfico do comportamento. Note que para o 'coeficiente de difusão de areia', os resultados das simulações nos poços não apresentem diferenças geológicas significativas, ou seja, todas poderiam ser aceitas como bons resultados. No entanto, a FO identifica numericamente as que diferem mais, quanto a fácies como também quanto as espessuras. No caso do parâmetro 'altura para o cálculo do volume de sedimento da fonte 1', essa identificação é ainda mais clara, pois a diferença entre as sequências é mais significativa e reflete no valor numérico da FO. Resultados semelhantes podem ser obtidos pelo AG, como já foi apresentado nas figuras anteriores, quando comparado o valor ótimo por ambos os algoritmos, levando à mesma interpretação e conclusão.

Figura 5.11 - Sequências dos poços GF20, DR8 e AB3 correspondentes a diferentes valores para o parâmetro incerto ‘coeficiente de difusão de areia’. Da esquerda para a direita para cada poço: distante da referência, melhor valor (destacado com um contorno em vermelho), intermediário e poço observado.



Fonte: elaborado pela autora no DionisosFlow® (2021).

Figura 5.12 - Sequências dos poços GF20, DR8 e AB3 correspondentes a diferentes valores para o parâmetro incerto ‘altura para o cálculo do volume de sedimento da fonte 1’. Da esquerda para a direita para cada poço: distante da referência, melhor valor (destacado com um contorno em vermelho), intermediário e poço observado.



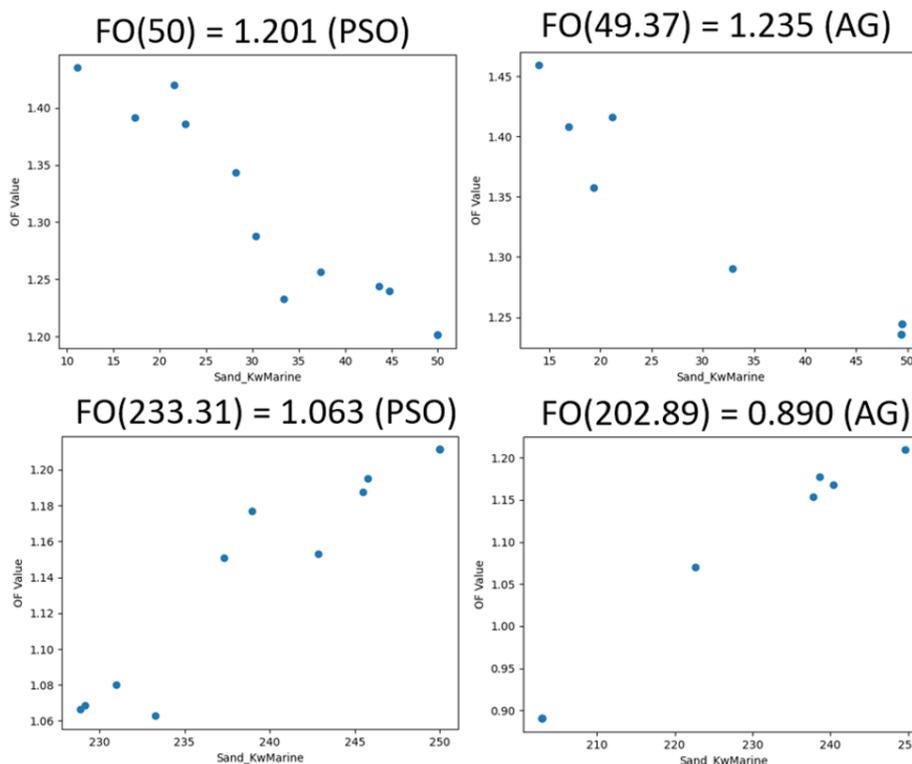
Fonte: elaborado pela autora no DionisosFlow® (2021).

### 5.2.1.1 Testes sobre o comportamento da FO quanto aos Intervalos de Incerteza

Buscando avaliar como a FO se comporta quando se erra a definição do intervalo, definiu-se intervalos de incerteza do parâmetro a ser calibrado que não contém o valor ótimo, ou seja, o valor de referência.

Assim, para o parâmetro ‘coeficiente de difusão de areia’, foram realizadas 12 simulações totais (4 iterações com população de 3 indivíduos), considerando o mesmo valor de referência igual a  $130,5\text{m}^2/\text{ano}$  e definiu-se um intervalo inferior de  $10\text{m}^2/\text{ano}$  a  $50\text{m}^2/\text{ano}$  e em um intervalo superior de  $200\text{m}^2/\text{ano}$  a  $250\text{m}^2/\text{ano}$ . Os resultados obtidos da pelo AG e PSO utilizando a FO são mostrados na Figura 5.13.

Figura 5.13 - Gráfico do comportamento da FO para o parâmetro incerto ‘coeficiente de difusão de areia’ obtidos pelo PSO (esquerda) e AG (direita) com intervalo inferior (topo) e superior (base).

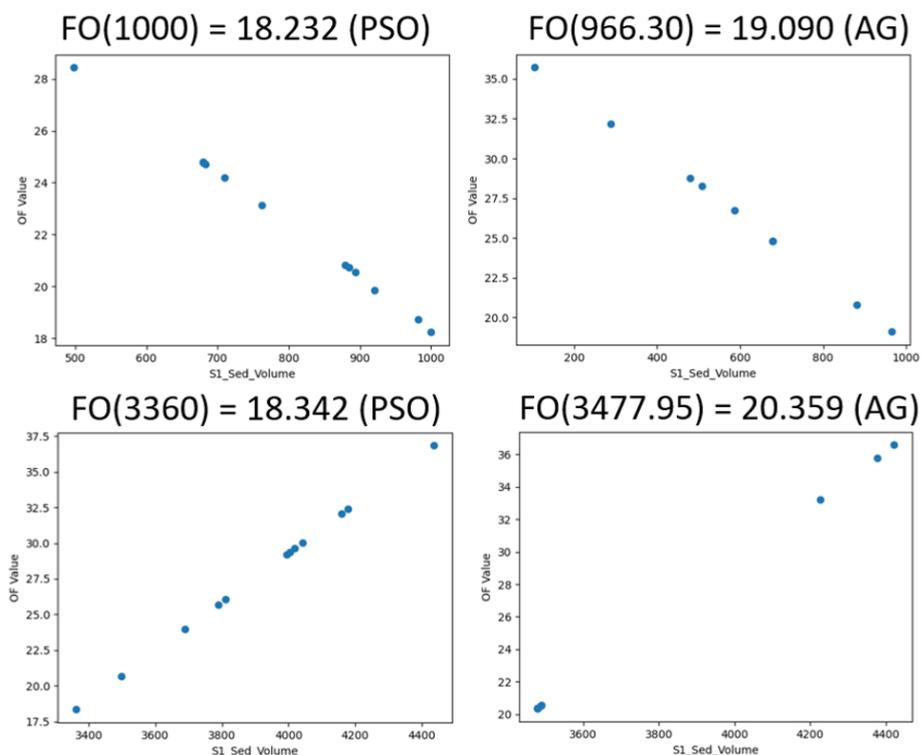


Fonte: elaborado pelos autores (2022).

Para o parâmetro ‘altura para o cálculo do volume de sedimento da fonte 1’, foram realizadas 12 simulações totais (4 iterações com população de 3

indivíduos), com o valor de referência igual a 2240km e definiu-se um intervalo inferior de 100km a 1000km e em um intervalo superior de 3360km a 4480km. A Figura 5.14 mostra os resultados obtidos.

Figura 5.14 - Gráfico do comportamento da FO para o parâmetro incerto 'altura para o cálculo do volume de sedimento da fonte 1' obtidos pelo PSO (esquerda) e AG (direita) com intervalo inferior (topo) e superior (base).



Fonte: elaborado pelos autores (2022).

É possível notar que, em todos os casos, o valor obtido para o parâmetro estudado foi em torno do extremo do intervalo, o mais próximo do valor de referência, o que é um ótimo resultado para o comportamento da FO, mostrando que ela consegue identificar o valor 'ótimo possível' no intervalo de incerteza dado, ou seja, que ela faz o melhor possível, identificando o valor mais próximo do valor de referência. Note também que, o parâmetro incerto 'coeficiente de difusão de areia' apresentou um gráfico mais disperso enquanto o parâmetro incerto 'altura para o cálculo do volume de sedimento da fonte 1' obteve um comportamento mais linear.

### 5.2.2 Estudo de caso 3: Calibração de quatro parâmetros inversíveis - *Mixed*

Em um segundo momento, foram realizados testes com variação de 4 parâmetros a serem calibrados por execução do algoritmo, os quais variam simultaneamente dentro da calibração (nenhum é fixado). Esses parâmetros definem o volume de água em duas fontes diferentes (S1 e S2), na primeira fonte para as idades 70 (S1\_70) e 28 milhões de anos (S1\_28) e na segunda fonte para as idades 70 (S2\_70) e 65 milhões de anos (S2\_65). Este teste é similar ao que será realizado para um campo real da indústria. Além disso, vale lembrar que o valor da FO é calculado sobre a média aritmética de 3 poços, considerando toda a espessura de cada poço.

Utilizando-se o PSO e AG como métodos de otimização e variando quatro valores de altura para o cálculo de vazão fluvial para duas fontes, foram realizadas 100 simulações totais (10 iterações com população de 10 indivíduos) com valores de referência iguais a [12; 50; 10; 20]km em um intervalo de 5km a 70km para cada parâmetro.

Os melhores valores para os parâmetros obtidos pelos algoritmos AG e PSO com seus respectivos valores para a FO e erros relativos correspondentes estão apresentados na Tabela 5.5. É importante observar quanto ao tempo computacional, a execução de todo fluxo de trabalho de calibração pelo PSO levou 7344s, em torno de 2h. Enquanto para o AG levou 4884s, em torno de 1h20min. O que mostra que é um tempo computacional praticável.

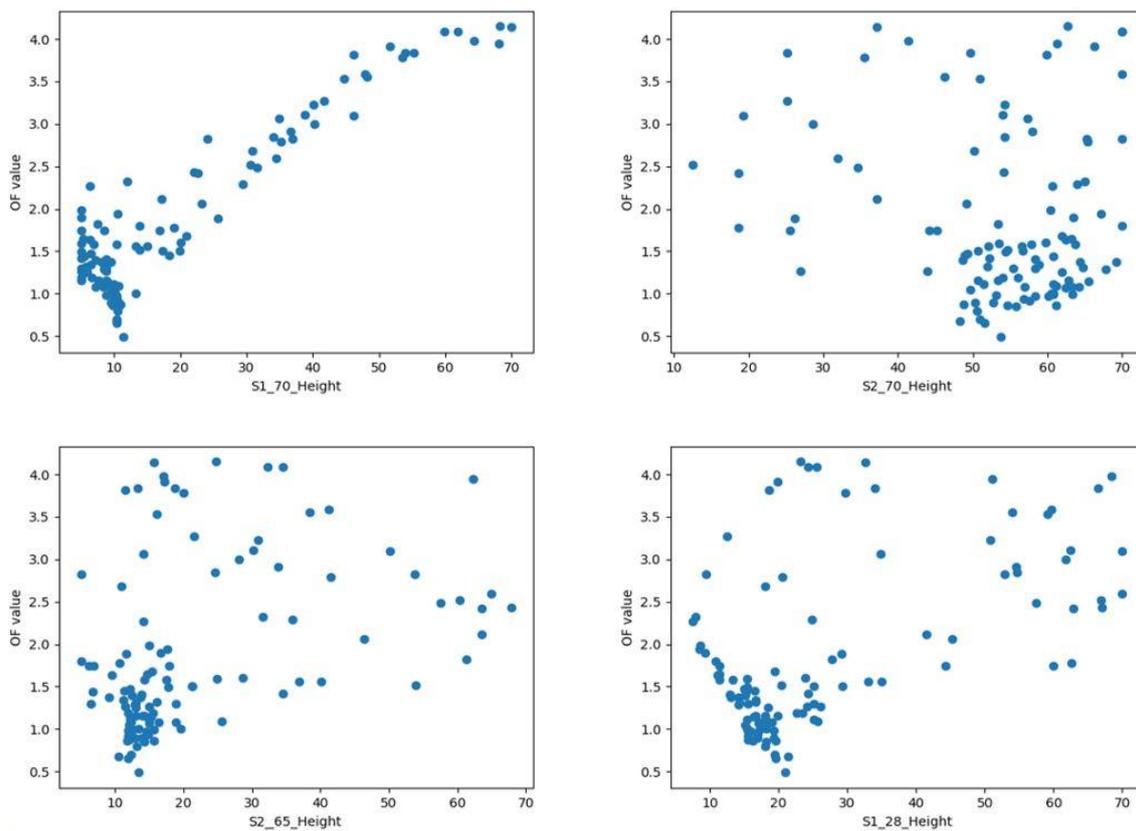
Tabela 5.5 - Comparação entre resultados da calibração de quatro parâmetros inversíveis pelos algoritmos AG e PSO.

Parâmetro	Método	Valor	Erro relativo
Altura para o cálculo de vazão fluvial (km)	Referência	Valor: [12; 50; 10; 20]	-
	AG	Valor: [12,31; 48,47; 19,19; 35,15] FO: 1,118	[2,6%; 3,1%; 91,9%; 75,8%]
	PSO	Valor: [11,43; 53,79; 13,43; 20,95] FO: 0,487	[4,8%; 7,6%; 34,3%; 4,8%]

Fonte: elaborado pela autora (2022).

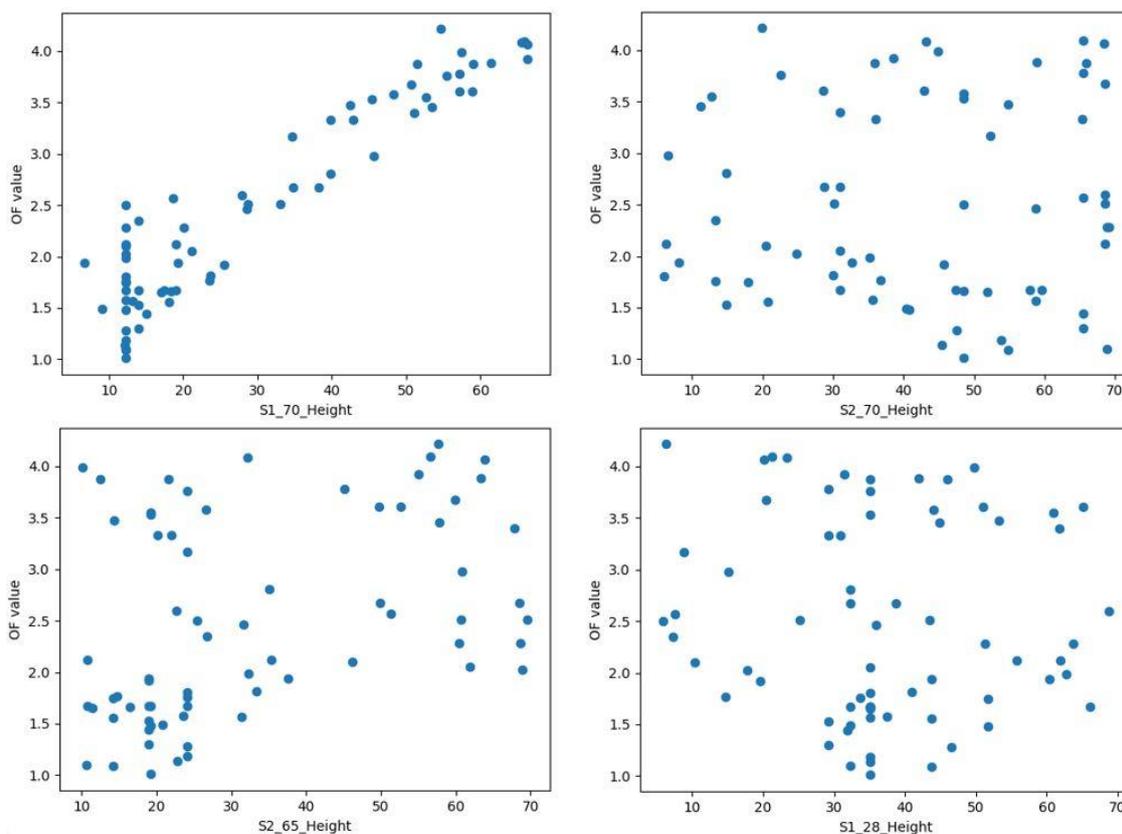
Os melhores valores encontrados para os parâmetros pelo PSO foram [11,43; 53,79; 13,43; 20,95]km com um valor para função objetivo igual a 0,487, conforme mostrado na Figura 5.15. A execução de todo fluxo de trabalho de calibração levou 7344s, em torno de 2h e os erros percentuais foram respectivamente de [4,8%; 7,6%; 34,3%; 4,8%]. Além disso, avaliando os gráficos da percebe-se que a altura para o cálculo de vazão fluvial da fonte 1 (S1\_70) para 70 milhões de anos está muito mais correlacionado ao valor da FO do que os outros parâmetros, pois é possível ver uma tendência mais clara do efeito deste parâmetro sobre o valor da FO. Percebe-se a influência de todos os parâmetros, entretanto o parâmetro S1\_70 possui um comportamento linear com o valor da FO enquanto os demais apresentam uma correspondência mais complexa. Também é possível notar que os valores testados pelo AG são um pouco mais dispersos se comparados ao método PSO, pois não há uma grande concentração de pontos em torno do valor ótimo.

Figura 5.15 - Gráficos dos quatro parâmetros incertos de altura para o cálculo de vazão fluvial para duas fontes diferentes pelo valor de suas respectivas FO, utilizando PSO como método de otimização da calibração.



Fonte: elaborado pela autora (2021).

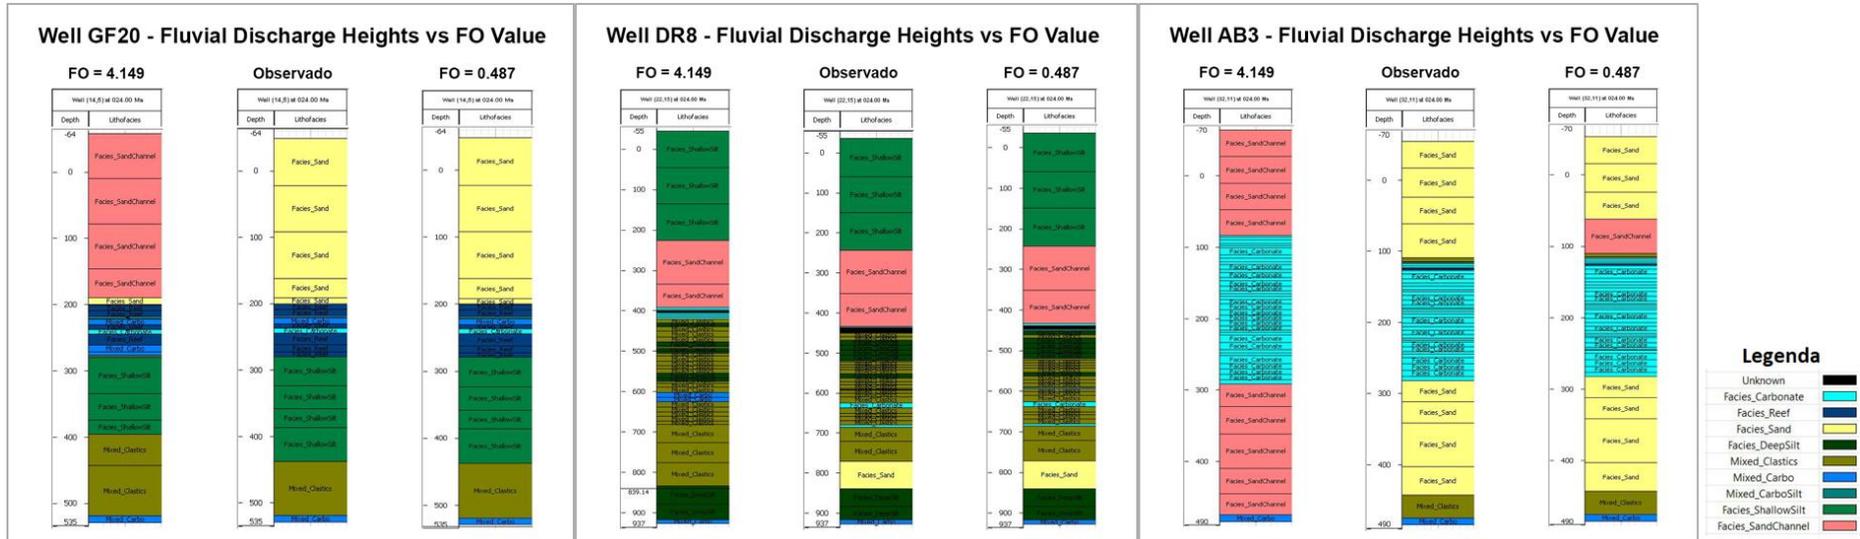
Figura 5.16 - Gráficos dos quatro parâmetros incertos de altura para o cálculo de vazão fluvial para duas fontes diferentes pelo valor de suas respectivas FO, utilizando AG como método de otimização da calibração.



Fonte: elaborado pela autora (2022).

A Figura 5.17 e a Figura 5.18 mostram as sequências de fácies para os três poços, comparando os poços de hidrocarbonetos observados com as simulações correspondentes aos valores mais distantes (esquerda) e os mais próximos (direita) obtidos pelos algoritmos PSO e AG, respectivamente. Também é possível notar claramente que para os valores distantes da referência (maior valor da FO calculado na execução da calibração), existem muitas fácies e espessuras diferentes do poço observado quando comparados. E para os valores mais próximos da referência (resultado da calibração), melhor é a correlação com o poço observado.

Figura 5.17 - Sequências dos poços GF20, DR8 e AB3 obtidas com diferentes valores para os quatro parâmetros incertos de 'altura para o cálculo de vazão fluvial'. Da esquerda para a direita para cada poço: distante da referência, poço observado e melhor valor encontrado pelo PSO.



Fonte: elaborado pela autora no DionisosFlow® (2022).



Diante dos resultados obtidos, pode-se concluir que ambos os métodos de otimização (AG e PSO) apresentam resultados muito similares, tanto ao tempo computacional quanto os valores ótimos; mas, no geral, o PSO apresenta melhores resultados. Alguns parâmetros foram obtidos com um erro relativo maior, mas a maioria ainda obteve erros relativamente baixos para um tempo computacional praticável. As sequências referente aos valores dos parâmetros incertos determinados pelos algoritmos estão totalmente coerentes quando comparadas com os poços observados, em que existem fácies e espessuras que diferem para os valores distantes da referência (maiores valores calculados pela FO) e, para valores mais próximos da referência, foram verificadas melhores correlações com os poços observados. Além disso, esses primeiros testes sugerem um bom comportamento da FO, porém ainda é preciso avaliar seu comportamento de maneira mais sistemática e em situações mais complexas. E os métodos de otimização aplicados até o momento são meta-heurísticas (AG e PSO), que empregam um certo grau de aleatoriedade. Desta forma, toda vez que é executado o fluxo de trabalho da calibração, são obtidos resultados distintos, sendo na maioria das vezes muito similares.

#### 5.2.2.1 Testes sobre os pesos das fácies e espessuras ( $\alpha$ e $\beta$ ) - ponderação

Buscando analisar a influência para as contribuições das fácies e espessuras no cálculo da FO foram realizadas análises dos pesos das fácies e espessuras ( $\alpha$ ) e ( $\beta$ ), nos quais estes foram ponderados da seguinte maneira, através das equações

$$\alpha = \frac{1}{\sqrt{n}} \quad (22)$$

e

$$\beta = \frac{1}{l_{p_i}}, \quad (23)$$

em que  $n_p$  é o número total de parâmetros que definem as fácies e  $l_{p_i}$  é a espessura total de interesse de cada poço.

Utilizando-se o PSO como método de otimização, foram variados os quatro valores de altura para o cálculo de vazão fluvial para duas fontes com os mesmos valores de referência, intervalo e número de simulações do teste anterior.

Os melhores valores para os parâmetros obtidos pelos algoritmos AG e PSO com seus respectivos valores para a FO e erros relativos correspondentes estão apresentados na Tabela 5.6. É importante observar quanto ao tempo computacional, a execução de todo fluxo de trabalho de calibração pelo PSO levou 6214s, em torno de 1h41min. Enquanto para o AG levou 6391s, em torno de 1h46min. O que mostra que é um tempo computacional praticável.

Tabela 5.6 - Comparação entre resultados da calibração de quatro parâmetros inversíveis pelos algoritmos AG e PSO com  $\alpha$  e  $\beta$  iguais a 1 e ponderados pelas equações.

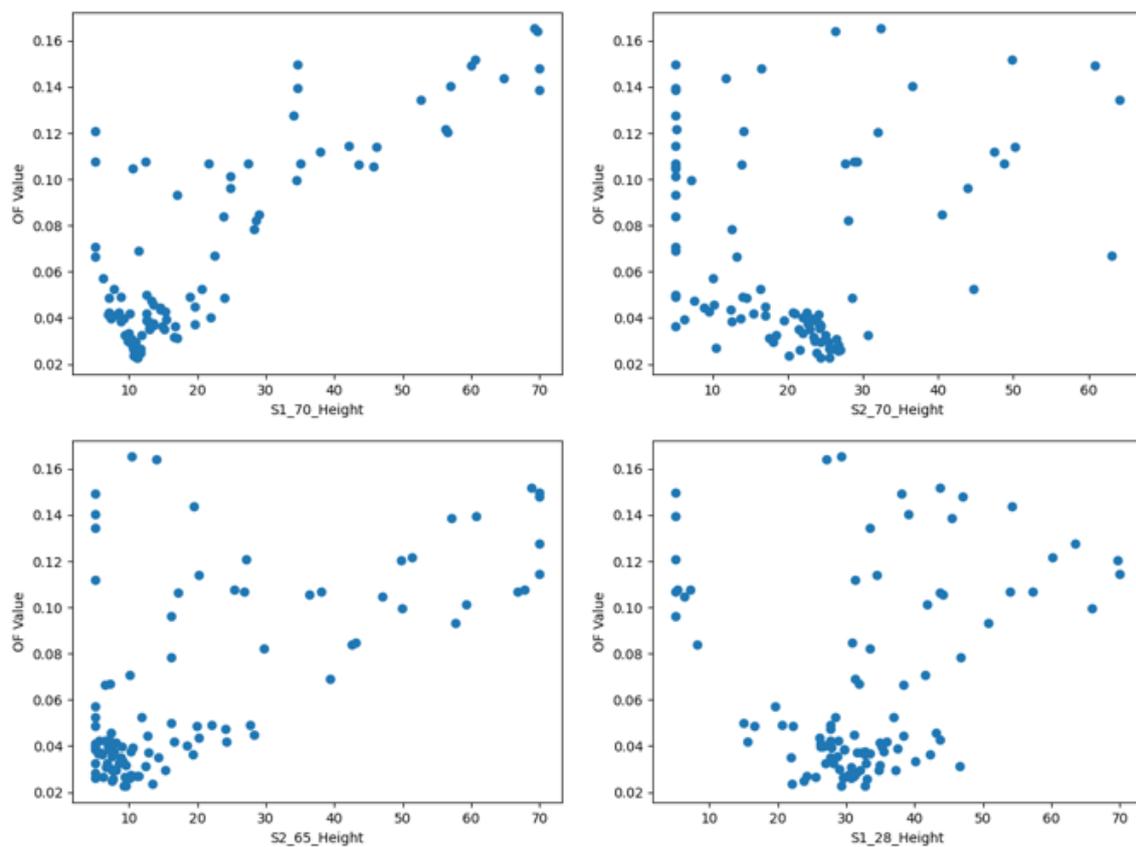
Parâmetro	Método		Valor	Erro relativo
Altura para o cálculo de vazão fluvial (km)	Referência	$\alpha$ e $\beta$	Valor: [12; 50; 10; 20]	-
	AG	1	Valor: [12,31; 48,47; 19,19; 35,15] FO: 1,118	[2,6%; 3,1%; 91,9%; 75,8%]
	PSO	1	Valor: [11,43; 53,79; 13,43; 20,95] FO: 0,487	[4,8%; 7,6%; 34,3%; 4,8%]
	AG	Ponderados	Valor: [9,56; 68,04; 12,19; 26,21] FO: 0,014	[20,3%; 36,1%; 21,9%; 31,1%]
	PSO	Ponderados	Valor: [11,09; 25,51; 9,47; 29,26] FO: 0,023	[7,6%; 49,0%; 5,3%; 46,3%]

Fonte: elaborado pela autora (2022).

Os melhores valores encontrados para os parâmetros pelo PSO foram [11,09; 25,51; 9,47; 29,26]km com um valor para função objetivo igual a 0,023, conforme mostrado na Figura 5.19. Os erros percentuais foram respectivamente de [7,6%; 49,0%; 5,3%; 46,3%]. Utilizando-se agora o AG como método de otimização, os melhores valores encontrados para os parâmetros foram [9,56; 68,04; 12,19; 26,21]km com um valor para função objetivo igual a 0,014, conforme mostrado na Figura 5.20, com erros percentuais de [20,3%; 36,1%; 21,9%; 31,1%]. Além disso, avaliando os gráficos da percebe-se também para

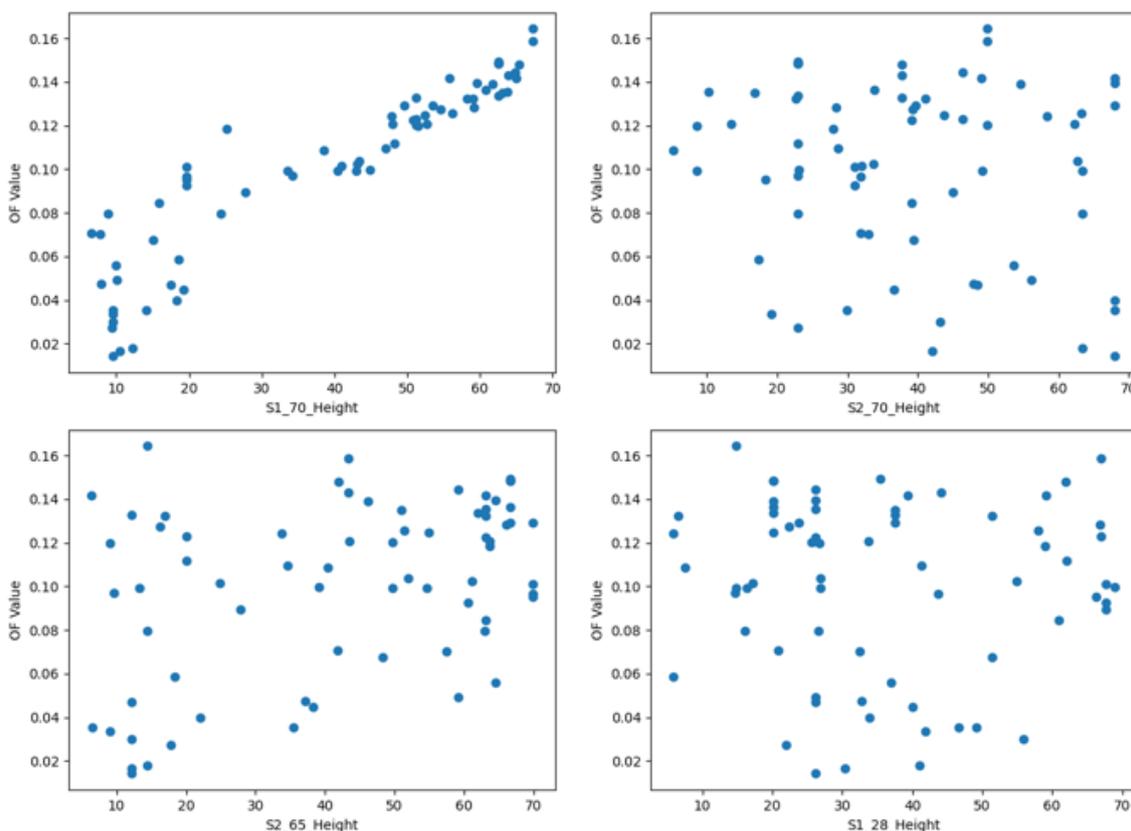
esse teste que a altura para o cálculo de vazão fluvial da fonte 1 (S1\_70) para 70 milhões de anos está muito mais correlacionado ao valor da FO do que os outros parâmetros, pois possui um comportamento linear enquanto os demais apresentam uma correspondência mais complexa. Os valores testados pelo AG continuam mais dispersos se comparados ao método PSO, não havendo uma grande concentração de pontos em torno do valor ótimo.

Figura 5.19 - Gráficos de quatro parâmetros incertos de altura para o cálculo de vazão fluvial para duas fontes diferentes pelo valor de suas respectivas FO, utilizando PSO como método de otimização da calibração.



Fonte: elaborado pela autora (2022).

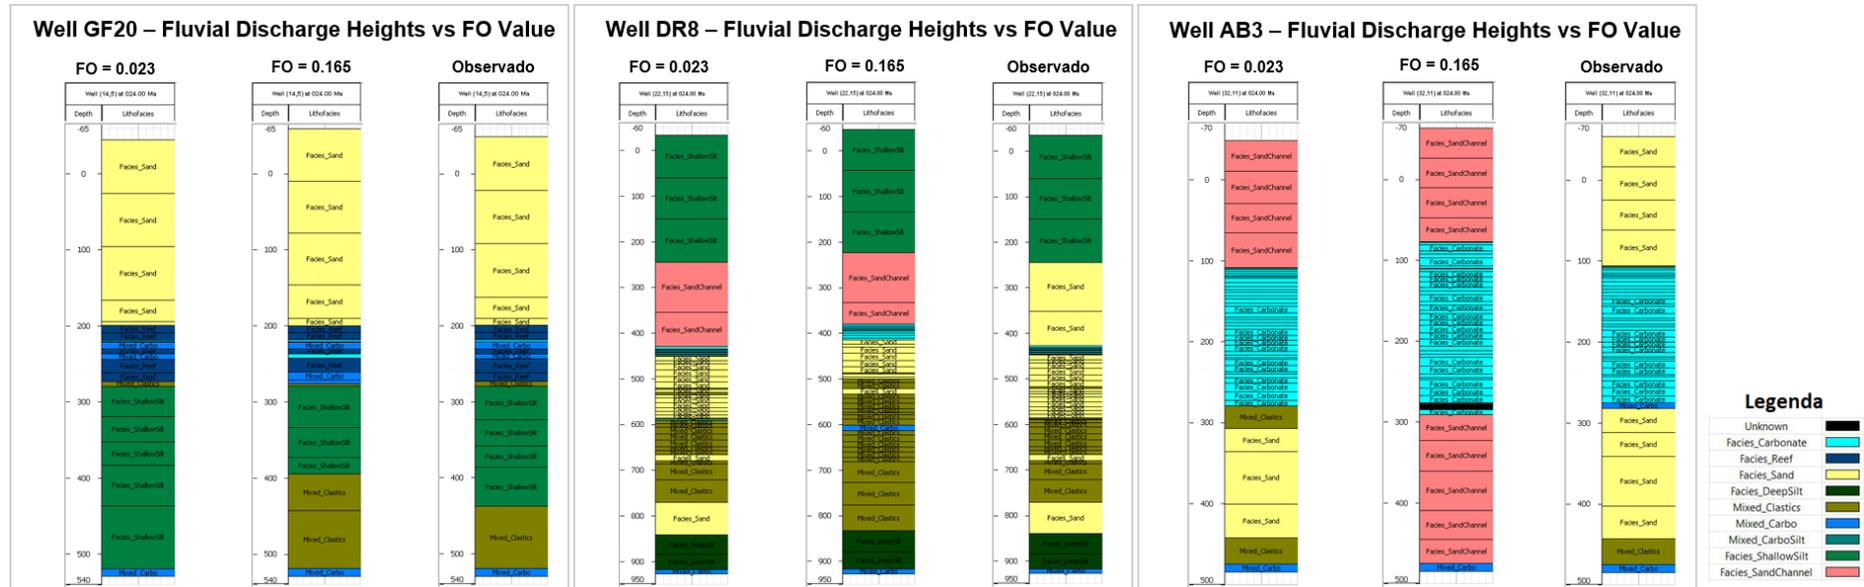
Figura 5.20 - Gráficos dos quatro parâmetros incertos de altura para o cálculo de vazão fluvial para duas fontes diferentes pelo valor de suas respectivas FO, utilizando AG como método de otimização da calibração.



Fonte: elaborado pela autora (2022).

A Figura 5.21 e a Figura 5.22 mostram as sequências para os três poços, comparando os poços de hidrocarbonetos observados com as simulações correspondentes aos valores mais distantes (esquerda) e os mais próximos (direita) obtidos pelos algoritmos PSO e AG, respectivamente. Também é possível notar claramente que para os valores distantes da referência (maior valor da FO calculado na execução da calibração), existem muitas fácies e espessuras diferentes do poço observado quando comparados. E para os valores mais próximos da referência (resultado da calibração), melhor é a correlação com o poço observado.

Figura 5.21 - Sequências dos poços GF20, DR8 e AB3 correspondentes a diferentes valores para quatro parâmetros incertos de ‘altura para o cálculo de vazão fluvial’. Da esquerda para a direita para cada poço: melhor valor, mais distante da referência encontrados pelo PSO e poço observado.



Fonte: elaborado pela autora no DionisosFlow® (2022).



É possível notar através dos gráficos que ambos os métodos de otimização também tendem a ter uma concentração de pontos testados em torno dos valores de referência. No entanto, os gráficos da calibração realizada utilizando AG possuem pontos mais dispersos. O parâmetro 'altura para o cálculo de vazão fluvial da fonte 1 (S1\_70) para 70 milhões de anos' continua apresentando uma tendência linear, o que mostra que o mesmo está muito mais correlacionado ao valor da FO do que os outros parâmetros. Através das figuras de sequências, nota-se que todos os resultados foram satisfatórios, pois as fácies e espessuras obtidas se assemelham aos poços observados. Além disso, os poços correspondentes ao menor valor obtido pela FO são quase idênticos aos poços observados, salvo algumas fácies que não são iguais, mas são geologicamente parecidas, como *Sand Channel* e *Sand*. Houveram mudanças nas sequências nos poços referentes ao menor valor da FO ao se comparar  $\alpha$  e  $\beta$  iguais a 1 com os resultados para  $\alpha$  e  $\beta$  ponderados pela equação. Ambos resultados são aceitáveis, mas para as execuções específicas aqui apresentadas, alguns poços para  $\alpha$  e  $\beta$  iguais a 1 exibem menos divergências de fácies ao relacioná-los aos poços observados. No entanto, não é possível firmar uma avaliação baseada apenas nessas execuções, pois os algoritmos de otimização possuem certa aleatoriedade em suas metodologias que levam a melhores ou piores resultados em cada execução realizada. Uma forma de reduzir a influência dessa aleatoriedade, é realizar diversas execuções, por exemplo 100 vezes, para um mesmo caso e analisar a média e variância desses resultados. Logo, sugere-se esse ensaio para estudos posteriores.

## 6 CONCLUSÕES E PERSPECTIVAS FUTURAS

A função objetivo proposta permite comparar de forma automática e buscar uma coerência geológica entre dados de poços de alta resolução com resultados de simulação de resolução menor, com diferentes espessuras totais. Para tornar essa metodologia mais rápida, foram incorporados métodos de otimização, como AG e PSO.

Os resultados obtidos pela aplicação dos algoritmos de otimização para o cálculo da FO nos casos sintéticos, a qual busca a melhor correlação entre os dados observados no poço e os resultados da simulação permitindo uma comparação coerente entre eles, são muito satisfatórios, uma vez que o tempo de execução do cálculo foi diminuído drasticamente e muitos resultados obtidos foram iguais ou muito próximos aos valores do mínimo global (resultante da Força Bruta ou Dijkstra). No entanto, para casos mais complexos envolvendo um grande número de camadas simuladas e dados de poços, alguns valores obtidos ultrapassam 100% de erro relativo. Uma vez que se deseja realizar a calibração de SFM utilizando o resultado da FO, esses valores muito divergentes do ótimo global podem causar ruídos e levar a um ajuste dos dados mais ineficaz. Portanto, é possível utilizar AG e PSO como métodos de otimização para o cálculo da FO, principalmente pelo baixo tempo de execução, mas em alguns casos pode não ser a melhor escolha pelo fato de os métodos não garantirem o mínimo global.

O fluxo de trabalho de calibração desenvolvido é um processo iterativo de otimização de forma assistida, pois em uma situação real haverá várias simulações e um número considerável de poços. Uma vez implementado todo o fluxo de calibração, o mesmo foi aplicado para o estudo de caso disponibilizado no *DionisosFlow*<sup>®</sup>, mais especificamente o tutorial *Mixed Model* (BEICIP-FRANLAB, 2017). Primeiramente, realizou-se um teste com os mesmos dados para o poço de hidrocarbonetos e o poço simulado e a FO foi avaliada e validada com sucesso. Analisando-se os parâmetros escolhidos individualmente para a calibração, foi possível verificar que os mesmos apresentam um comportamento regular, suave e convexo, inferindo-se que existe um mínimo global. Essa análise

é importante para uma boa execução da calibração, permitindo que os valores ótimos sejam encontrados e um bom ajuste de dados seja obtido.

Os resultados das calibrações para os parâmetros individualmente apresentaram excelente desempenho, chegando próximo aos valores de referência, em que o maior erro relativo foi de apenas 2,9% e o melhor resultado teve um erro relativo de somente 0,2%. Os resultados das calibrações para os quatro parâmetros inversíveis foram na maioria dos casos excelentes, nos quais os algoritmos de otimização encontraram resultados dentro de um tempo computacional praticável. Em particular, o PSO chegou a valores muito próximos dos parâmetros ótimos, com erros relativos de 4,8% a 34,3% para o teste realizado. O AG obteve os parâmetros com erros relativos de 2,6% a 91,9 %. Através da análise visual da estratigrafia dos poços de referência e resultante da calibração, é possível notar que ambos são similares e, apesar do resultado ser satisfatório para ambos os métodos, o PSO obteve erros relativos menores e estratigrafias mais próximas do poço de referência. Além disso, as sequências referentes os valores dos parâmetros incertos determinados pelos algoritmos estão totalmente coerentes quando comparadas com os poços observados, onde para os valores distantes da referência (maiores valores da FO calculados na execução da calibração) existem fácies e espessuras que diferem e para os valores mais próximos da referência melhores correlações com os poços observados.

As principais contribuições realizadas neste trabalho foram: o desenvolvimento de uma nova FO específica para calibração de modelagem geológica para a indústria de petróleo, a elaboração de uma ferramenta de calibração aplicando de métodos de otimização e publicação de artigo no Congresso Ibero-Latino Americano de Métodos Computacionais em Engenharia (CILAMCE).

Os próximos passos consistem na aplicação da calibração para estudos de casos mais reais e realmente práticos, para avaliar o custo computacional, a robustez da otimização e o comportamento quanto à representatividade geológica. Também será possível investigar novos métodos de otimização para o cálculo da FO e para a calibração dos modelos, usando a experiência já adquirida até aqui.

As perspectivas futuras para o desenvolvimento desta pesquisa são: o aprimoramento da FO através de ajustes no cálculo da mesma, novos estudos e propostas sobre a ponderação dos pesos  $\alpha$  e  $\beta$  e novos meios de ponderação do cálculo da FO total, em que são considerados todos os poços do modelo.

## REFERÊNCIAS

ALVES, M. K. Notas de Otimização e Aplicações. Florianópolis, 9 setembro 2019.

BEICIP-FRANLAB. **DionisosFlow**. 2007. Disponível em: <<https://www.beicip.com/stratigraphic-modeling-0>>. Acesso em: 20 de fev. de 2020.

BEICIP-FRANLAB. **Mixed Model**: Discovering DionisosFlow Mixed Solution. França: Beicip Franlab, 2017.

BERTSEKAS, D. P. Projected Newton methods for optimization problems with simple constraints. **SIAM Journal on control and Optimization**, v. 20, n. 2, p. 221-246, 1982.

BORNHOLDT, S.; WESTPHAL, H. Automation of stratigraphic simulations: Quasi-backward modelling using genetic algorithms. **Geological Society, London, Special Publications**, v. 134, n. 1, p. 371-379, 1998.

BRUGOGNOLLE, J. S. et al. **Development of an objective function to measure the dissimilarity between data observed in wells and results of Stratigraphic Forward Models-SFM**. Proceedings of the XLI Ibero-Latin-American Congress on Computational Methods in Engineering, CILAMCE, 2020.

CANT, D. J.; WALKER, R. G. **Development of a braided-fluvial facies model for the Devonian Battery Point Sandstone, Quebec**. Canadian Journal of Earth Sciences, v. 13, n. 1, p. 102-119, 1976.

CAUCHY, A. et al. Méthode générale pour la résolution des systemes d'équations simultanées. **Comp. Rend. Sci. Paris**, v. 25, n. 1847, p. 536-538, 1847.

CAUMON, G. et al. Surface-based 3D modeling of geological structures. **Mathematical Geosciences**, v. 41, n. 8, p. 927-945, 2009.

CHARVIN, K. et al. A Bayesian approach to inverse modelling of stratigraphy, part 1: Method. **Basin Research**, v. 21, n. 1, p. 5-25, 2009.

CHARVIN, K. et al. A Bayesian approach to inverse modelling of stratigraphy, part 2: Validation tests. **Basin Research**, v. 21, n. 1, p. 27-45, 2009.

CONN, A. R.; GOULD, N.; TOINT, P. L. Testing a class of methods for solving minimization problems with simple bounds on the variables. **Mathematics of computation**, v. 50, n. 182, p. 399-430, 1988.

CROSS, T. A.; LESSENGER, M. A. **Construction and application of a stratigraphic inverse model**. 1999.

DAVIDON, W. C. **Variable metric method for minimization**. 1959.

DEB, Kalyanmoy. An efficient constraint handling method for genetic algorithms. **Computer methods in applied mechanics and engineering**, v. 186, n. 2-4, p. 311-338, 2000.

DIJKSTRA, E. W. A note on two problems in connexion with graphs. **Numerische mathematik**, v. 1, n. 1, p. 269-271, 1959.

DUAN, T. **Similarity measure of sedimentary successions and its application in inverse stratigraphic modeling**. *Petroleum Science*, 14, p. 484–492, 2017.

DUAN, T.; GRIFFITHS, C. M.; JOHNSON, S. O. **Conditional simulation of 2-D parasequences in shallow marine depositional systems by using attributed controlled grammar**. *Comput Geosci*, v. 25, n. 6, p. 667-681, 1999.

DUAN, T.; GRIFFITHS, C. M.; JOHNSON, S. O. **High-frequency sequence stratigraphy using syntactic methods and clustering applied to the upper Limestone Coal Group (Pendleian, E1) of the Kincardine basin**. *UK, Math Geol.*, Ed. 7, 33, p. 825–44, 2001.

FALIVENE, O. et al. Automatic calibration of stratigraphic forward models for predicting reservoir presence in exploration. **AAPG Bulletin**, v. 98, n. 9, p. 1811-1835, 2014.

FARIA, D. L. P.; REIS, A. T.; SOUZA, O. G. Three-dimensional stratigraphic-sedimentological forward modeling of an Aptian carbonate reservoir deposited during the sag stage in the Santos basin, Brazil. **Marine and Petroleum Geology**, v. 88, p. 676-695, 2017.

FORD, L. R.; FULKERSON, D. R. Maximal Flow through a Network. The RAND Corporation. **Research Memorandum**, v. 1400, p. 19, 1954.

GOLDBARG, M. C.; GOLDBARG, E. G.; LUNA, H. P.L. **Otimização Combinatória e Meta-heurísticas: Algoritmos e Aplicações**. Rio de Janeiro: Elsevier Editora Ltda., 2016. 9788595154667. Disponível em: <<https://app.minhabiblioteca.com.br/#/books/9788595154667>>. Acesso em: 28 dez. 2020

GRANJEON, D.; JOSEPH, P. **Concepts and applications of a 3-D multiple lithology, diffusive model in stratigraphic modeling**. 1999.

HANCOCK, H. **Theory of maxima and minima**. 1917.

HOLLAND, J. H. **Genetic algorithms and the optimal allocation of trials**. *SIAM Journal on Computing*, 1973; 2:88-105.

INTRODUCTION To Optimization: Gradient Based Algorithms. Produtor: AlphaOpt. [S. l.: s. n.], 2017. Disponível em: <https://www.youtube.com/watch?v=n-Y0SDSOUI>. Acesso em: 15 janeiro 2022.

INTRODUCTION To Optimization: Gradients, Constraints, Continuous and Discrete Variables. Produtor: AlphaOpt. [S. l.: s. n.], 2017. Disponível em: <https://www.youtube.com/watch?v=URkmNZuFzKg>. Acesso em: 15 janeiro 2022.

INTRODUCTION to Optimization: What Is Optimization? Produtor: AlphaOpt. [S. l.: s. n.], 2017. Disponível em: <https://www.youtube.com/watch?v=Q2dewZweAtU>. Acesso em: 15 janeiro 2022.

KARSSENBERG, D.; TÖRNQVIST, T. E.; BRIDGE, J. S. Conditioning a process-based model of sedimentary architecture to well data. **Journal of Sedimentary Research**, v. 71, n. 6, p. 868-879, 2001.

KENNEDY, J.; EBERHART, R. **Particle swarm optimization**. Proceedings of ICNN'95-International Conference on Neural Networks. IEEE, 1995.

KRIGE, D. G. A statistical approach to some basic mine valuation problems on the Witwatersrand. **Journal of the Southern African Institute of Mining and Metallurgy**, v. 52, n. 6, p. 119-139, 1951.

LEE, A. **pyswarm**. Versão 0.6. [S. l.], 22 out. 2014. Disponível em: <<https://pypi.org/project/pyswarm>>. Acesso em: 18 nov. 2020.

LEMARÉCHAL, C. Cauchy and the gradient method. **Doc Math Extra**, v. 251, n. 254, p. 10, 2012.

LEVITIN, E. S.; POLYAK, B. T. Constrained minimization methods. **USSR Computational mathematics and mathematical physics**, v. 6, n. 5, p. 1-50, 1966.

LUZIA, L. F.; RODRIGUES, M. C. **Estudo sobre as Metaheurísticas**. Monografia – Instituto de Matemática e Estatística, Universidade de São Paulo. São Paulo, p. 38. 2009.

MACLAURIN, C. A treatise of fluxions (1742). In: **Landmark Writings in Western Mathematics 1640-1940**.

MARFISI, E. A. et al. Forward Stratigraphic Modelling of Deep-Sea Sedimentary Environments: Predicting Facies Distribution in Salt Tectonics Context. In: **AAPG/SEG International Conference & Exhibition**. 2016.

MENGER, K. et al. **Ergebnisse eines mathematischen Kolloquiums**. 1998.

MORÉ, J. J.; THUENTE, D. J. Line search algorithms with guaranteed sufficient decrease. **ACM Transactions on Mathematical Software (TOMS)**, v. 20, n. 3, p. 286-307, 1994.

MORÉ, J. J.; TORALDO, G. Algorithms for bound constrained quadratic programming problems. **Numerische Mathematik**, v. 55, n. 4, p. 377-400, 1989.

NASH, S. G. A survey of truncated-Newton methods. **Journal of computational and applied mathematics**, v. 124, n. 1-2, p. 45-59, 2000.

POWELL, D.; SKOLNICK, M. Using genetic algorithms in engineering design optimization with non-linear constraints. In: **Proceedings of the 5th International conference on Genetic Algorithms**. 1993. p. 424-431.

RUNARSSON, T. P.; YAO, X. Stochastic ranking for constrained evolutionary optimization. **IEEE Transactions on evolutionary computation**, v. 4, n. 3, p. 284-294, 2000.

SACCHI, Q.; WELTJE, G. J.; VERGA, F. Towards process-based geological reservoir modelling: Obtaining basin-scale constraints from seismic and well data. **Marine and Petroleum Geology**, v. 61, p. 56-68, 2015.

SELLEY, R. **Série Engenharia de Petróleo - Geologia do Petróleo**. Grupo GEN, 2016. Disponível em: <https://app.minhabiblioteca.com.br/#/books/9788595156289/>. Acesso em: 05 Mai 2021

SOLGI, R. **geneticalgorithm**. Versão 1.0.1. [S. l.], 4 mai. 2020. Disponível em: <<https://pypi.org/project/geneticalgorithm>>. Acesso em: 1 nov. 2020.

THOMAS, J. E. **Fundamentos de engenharia de petróleo**. Interciência, 2001.

WIJNS, C. et al. Interactive inverse methodology applied to stratigraphic forward modelling. **Geological Society, London, Special Publications**, v. 239, n. 1, p. 147-156, 2004.