



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

EDUARDA DE FRANÇA ANDRADE

**OTIMIZAÇÃO DA LOCAÇÃO E VAZÃO DE POÇOS EM RESERVATÓRIOS DE
PETRÓLEO UTILIZANDO ALGORITMOS GENÉTICOS E MODELOS
SUBSTITUTOS ADAPTATIVOS**

Recife

2022

EDUARDA DE FRANÇA ANDRADE

**OTIMIZAÇÃO DA LOCAÇÃO E VAZÃO DE POÇOS EM RESERVATÓRIOS DE
PETRÓLEO UTILIZANDO ALGORITMOS GENÉTICOS E MODELOS
SUBSTITUTOS ADAPTATIVOS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de Mestre em Engenharia Civil.

Área de concentração: Simulação e Gerenciamento de Reservatórios de Petróleo.

Orientadora: Profa. Dra. Silvana Maria Bastos Afonso da Silva.

Recife

2022

Catálogo na fonte:
Bibliotecária Sandra Maria Neri Santiago, CRB-4 / 1267

- A554o Andrade, Eduarda de França.
 Otimização da locação e vazão de poços em reservatórios de petróleo utilizando algoritmos genéticos e modelos substitutos adaptativos / Eduarda de França Andrade. – 2022.
 133 f.: il., figs., tabs.
- Orientadora: Profa. Dra. Silvana Maria Bastos Afonso da Silva.
 Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Civil. Recife, 2022.
 Inclui referências e apêndice.
1. Engenharia civil. 2. Simulação de reservatórios. 3. Locação de poços. 4. Gerenciamento de vazões. 5. Modelos substitutos. 6. Algoritmo genético. 7. Otimização sequencial aproximada. I. Silva, Silvana Maria Bastos Afonso da (Orientadora). II. Título.

UFPE

624 CDD (22. ed.)

BCTG/2022-393

EDUARDA DE FRANÇA ANDRADE

**OTIMIZAÇÃO DA LOCAÇÃO E VAZÃO DE POÇOS EM RESERVATÓRIOS DE
PETRÓLEO UTILIZANDO ALGORITMOS GENÉTICOS E MODELOS
SUBSTITUTOS ADAPTATIVOS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para obtenção do título de Mestre em Engenharia Civil. Área de Concentração: Simulação e Gerenciamento de Reservatórios de Petróleo.

Aprovada em: 26/08/2022.

BANCA EXAMINADORA

Participação por videoconferência
Prof. Dr. Bernardo Horowitz (Examinador Interno)
Universidade Federal de Pernambuco

Participação por videoconferência
Prof. Dr. Denis José Schiozer (Examinador Externo)
Universidade Estadual de Campinas

Participação por videoconferência
Prof. Dr. Jefferson Wellano Oliveira Pinto (Examinador Externo)
Universidade Federal de Pernambuco

Dedico este trabalho aos meus queridos pais, Dilma e Janival.

AGRADECIMENTOS

Agradeço imensamente aos meus amados pais, Dilma e Janival, que sempre me apoiaram e me incentivaram em tudo que me propus a fazer na vida, sem nenhum julgamento. Meus alicerces, meus exemplos, com quem sempre posso contar. A eles a minha gratidão por absolutamente tudo.

À minha companheira, Jessica, que também é minha melhor amiga. Por todo o companheirismo, incentivo, cuidado, paciência, confiança e amor demonstrados e construídos. Por ter segurado a minha mão nos momentos mais difíceis que passei nos últimos anos e por sempre acreditar em mim, me guiando para as melhores decisões.

Aos meus queridos orientadores, Profa. Silvana Bastos e Prof. Leonardo Oliveira, com quem demorei a me abrir e me sentir confortável, mas que sempre estiveram ali, disponíveis, me incentivando e me orientando (para assuntos de dentro e fora da academia). Por toda a compreensão e lucidez diante dos momentos que relatei passar (problemas durante a pandemia, transição de carreira). Por todos os puxões de orelha que foram necessários para que eu me tornasse alguém melhor e pudesse seguir firme com esse trabalho.

Agradeço também todos que contribuíram diretamente com a minha adaptação, meu desenvolvimento e crescimento durante o mestrado. Entre eles, meus professores e colegas. Destaco os queridos Matheus Garrido e Jefferson Wellano que me auxiliaram sempre que precisei.

Meu agradecimento a Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE) pelo apoio financeiro que permitiu o desenvolvimento desta pesquisa.

RESUMO

O desenvolvimento de novos campos para produção de petróleo está cada vez mais complexo e oneroso. Por sua vez, ter uma produção lucrativa em campos maduros, onde as taxas de produção de água geralmente são altas, também representa um desafio para a área de Engenharia de Reservatórios. Para ambas as situações pode ser difícil obter retornos sobre os investimentos usando apenas técnicas tradicionais de gerenciamento de produção. Portanto, há um interesse crescente da Indústria de Petróleo e Gás no desenvolvimento de procedimentos de otimização baseados em simulações numéricas que sejam eficientes de modo a guiar o planejamento de operação dos poços. Levando isso em consideração, o presente trabalho se concentra em maximizar o valor presente líquido (VPL) do reservatório, otimizando operações de gerenciamento de campo tais como o posicionamento dos poços e o gerenciamento de vazões através de ciclos de controle. Neste trabalho foi resolvido o problema de otimização de um reservatório conhecido da literatura através de três diferentes abordagens onde foram empregados o algoritmo genético (AG) do *Toolbox Optimization* do MATLAB e a técnica de otimização por aproximação sequencial (SAO). A primeira abordagem otimizou, em duas etapas sequenciais, a locação de poços (AG) e suas vazões (SAO). A segunda abordagem utilizou o AG para definir, simultaneamente, a melhor posição para os poços e as melhores taxas de vazões para cada poço nos ciclos de controle definidos. Na terceira, combinou-se a segunda metodologia (AG integrado) com uma etapa adicional que otimizava as vazões por meio do SAO. Durante o processo de otimização foi realizada uma série de avaliações de funções utilizando um simulador de reservatórios. Devido ao alto custo desse processo, e visando reduzi-lo, foi empregada uma metodologia com modelos substitutos adaptativos. Como o problema de otimização estudado é restrito, foram utilizadas técnicas como reparação de cromossomos e um método de penalização adaptativa que permitiu que o AG funcionasse respeitando as restrições impostas ao problema. Para todos os estudos foram executadas 20 otimizações. A solução associada ao melhor VPL, entre todos os casos e abordagens estudados, trouxe um aumento de 50,44% em relação ao caso base. A redução significativa da produção de água foi o parâmetro mais decisivo para esse aumento. As metodologias aqui sugeridas trouxeram resultados consistentes com melhorias significativas no VPL, objetivo principal deste trabalho.

Palavras-chave: simulação de reservatórios; locação de poços; gerenciamento de vazões; modelos substitutos; algoritmo genético; otimização sequencial aproximada.

ABSTRACT

The development of new fields for oil production is increasingly complex and expensive. Moreover, having profitable production in mature fields, where water production rates are generally high, also represents a challenge for the Reservoir Engineering area. In both situations, it cannot be easy to obtain investment returns using only traditional production management techniques. Therefore, there is a growing interest in the Oil and Gas Industry in developing optimization procedures based on numerical simulations that efficiently guide well operation planning. Thus, the present work focuses on maximizing the reservoir's net present value (NPV) through optimizing field management operations such as well placement and flow management with control cycles. The optimization problem of a known reservoir in the literature was solved through three different approaches using the genetic algorithm (AG) of the MATLAB Toolbox Optimization and the technique of sequential approximation optimization (SAO). In two sequential steps, the first approach optimized the location of wells (AG) and their flow rates (SAO). The second approach used AG to simultaneously define the best position for the wells and the best flow rates for each well in the defined control cycles. In the third, the second methodology (integrated AG) was combined with an additional step that optimized the flows through the SAO. During the optimization process, a series of function evaluations were performed using a reservoir simulator. Due to the high cost of this process and aiming to reduce it, a methodology with adaptive substitute models was used. As the optimization problem studied is constrained, techniques such as chromosome repair and an adaptive penalty method were used that allowed the GA to work respecting the constraints imposed on the problem. For all studies, 20 optimization runs were performed. Among all cases and approaches studied, the solution associated with the best NPV had a 50.44% increase concerning the base case. The significant reduction in water production was the most decisive parameter for this increase, reaching about 87.70% in the best result obtained in this work. The methodologies suggested here brought results consistent with significant improvements in NPV, the main objective of this work.

Keywords: reservoir simulation; well placement; production optimization; surrogate models; genetic algorithm; sequential approximate optimization.

LISTA DE FIGURAS

Figura 1 –	Histórico da mudança anual na demanda de óleo.....	17
Figura 2 –	Previsão do crescimento anual da demanda global de petróleo.....	19
Figura 3 –	Consumo de energia por combustível (em quatrilhão de unidades térmicas britânicas)	19
Figura 4 –	Mudança na energia primária por combustível.....	20
Figura 5 –	Exemplos dos tipos de aproximação: (a) espaço de projeto, (b) aproximação global e (c) aproximação local.....	34
Figura 6 –	Exemplos de amostragem: (a) randômica, (b) estratificada e (c) LHS.....	37
Figura 7 –	Procedimento básico do AG.....	44
Figura 8 –	Aplicação do método da penalidade adaptativa com a função f_x	51
Figura 9 –	Esquema usado para a adaptação do modelo substituto.....	54
Figura 10 –	Evolução das regiões de confiança a cada iteração da estratégia.....	59
Figura 11 –	Disposição inicial dos poços e campo de permeabilidade do reservatório Egg Model.....	61
Figura 12 –	Intervalos de tempo de ciclos de controle com tempos fixos.....	68
Figura 13 –	Definição prévia do intervalo dos 3 ciclos de controle para o reservatório Egg Model.....	68
Figura 14 –	Disposição dos poços da melhor solução para o problema 1: produtores (à esquerda) e injetores (à direita)	70
Figura 15 –	Distribuição dos poços produtores e injetores da melhor solução do problema 1.....	71
Figura 16 –	Permeabilidade dos cortes verticais das camadas do reservatório onde estão locados os poços produtores pós otimização de locação: (a) PROD1, (b) PROD3, (c) PROD2 e (d) PROD4.....	71
Figura 17 –	Permeabilidade dos cortes verticais das camadas do reservatório onde estão locados os poços injetores pós otimização de locação: (a) INJECT1 e INJECT5, (b) INJECT2, (c) INJECT3, (d) INJECT4, (e) INJECT6 e (f) INJECT7 e INJECT8.....	72
Figura 18 –	Permeabilidade dos cortes verticais das camadas do reservatório onde foram locados os poços produtores no caso base: (a) PROD1, (b) PROD2, (c) PROD3 e (d) PROD4.....	73

Figura 19 –	Produção de líquidos (m3/dia) no caso base do problema 1.....	74
Figura 20 –	Injeção de água (m3/dia) no caso base do problema 1.....	74
Figura 21 –	Produtores pós otimização da locação (etapa 1) com AG para o problema 1.....	76
Figura 22 –	Injetores pós otimização da locação (etapa 1) com AG para o problema 1..	76
Figura 23 –	Produtores pós otimização da locação com definição dos ciclos de controle para entrada no SAO (início da etapa final) do problema 1.....	77
Figura 24 –	Injetores pós otimização da locação com definição dos ciclos de controle para entrada no SAO (início da etapa final) do problema 1.....	77
Figura 25 –	Histograma do VPL após etapas de otimização do problema 1.....	81
Figura 26 –	Comparativo de óleo e água acumulados (m3) para o reservatório Egg Model no problema 1.....	83
Figura 27 –	Comparativo do corte de água (%) para o reservatório Egg Model no problema 1.....	83
Figura 28 –	Saturação de água para o reservatório Egg Model para o problema 1.....	84
Figura 29 –	Produção acumulada de água para o reservatório Egg Model na melhor solução para o problema 1.....	85
Figura 30 –	Corte de água do reservatório Egg Model (GA+SAO – problema 1)	85
Figura 31 –	Produção de líquidos dos poços produtores no reservatório Egg Model (GA+SAO – problema 1)	86
Figura 32 –	Pressão de fundo de poço (BHP) dos poços produtores do reservatório Egg Model (GA+SAO – problema 1)	87
Figura 33 –	Produção acumulada de óleo para o reservatório Egg Model (GA+SAO – problema 1)	87
Figura 34 –	Saturação de óleo: (a) caso base, (b) pós otimização da locação e (c) pós otimização de vazões.....	88
Figura 35 –	Injeção de água no reservatório Egg Model (GA+SAO – problema 1)	88
Figura 36 –	Pressão de fundo de poço (BHP) dos poços injetores do reservatório Egg Model (GA+SAO – problema 1)	89
Figura 37 –	Disposição dos poços da melhor solução para o problema 2: produtores (à esquerda) e injetores (à direita)	92
Figura 38 –	Distribuição dos poços produtores e injetores da melhor solução para o problema 2.....	93

Figura 39 –	Permeabilidade dos cortes verticais das camadas do reservatório onde estão locados os poços produtores pós otimização simultânea de locação e vazão: (a) PROD1, (b) PROD2, (c) PROD3 e (d) PROD4.....	93
Figura 40 –	Permeabilidade dos cortes verticais das camadas do reservatório onde estão locados os poços injetores pós otimização simultânea de locação e vazão: (a) INJECT1, (b) INJECT2, (c) INJECT3, (d) INJECT4 e INJECT8, (e) INJECT5 e (f) INJECT6 e INJECT7.....	94
Figura 41 –	Produção de líquidos (m3/dia) no caso base do problema 2.....	95
Figura 42 –	Injeção de água (m3/dia) no caso base do problema 2.....	95
Figura 43 –	Comparativo de óleo e água acumulados (m3) para o reservatório Egg Model no problema 2.....	97
Figura 44 –	Saturação de água para o reservatório Egg Model para o problema 2.....	97
Figura 45 –	Comparativo da produção acumulada de água (m3) entre o caso base e a melhor solução para o problema 2.....	98
Figura 46 –	Comparativo do corte de água dos poços produtores do caso base e da melhor solução para o problema 2.....	99
Figura 47 –	Produção de líquidos da melhor solução para o problema 2.....	100
Figura 48 –	Pressão de fundo de poço (BHP) dos poços produtores na melhor solução para o problema 2.....	100
Figura 49 –	Injeção de água dos poços injetores na melhor solução para o problema 2..	101
Figura 50 –	Pressão de fundo de poço (BHP) dos poços injetores na melhor solução para o problema 2.....	101
Figura 51 –	Disposição dos poços da melhor solução para o problema 3: produtores (à esquerda) e injetores (à direita)	104
Figura 52 –	Distribuição dos poços produtores e injetores da melhor solução para o problema 3.....	104
Figura 53 –	Produção de líquidos (m3/dia) no caso base do problema 3.....	106
Figura 54 –	Injeção de água (m3/dia) no caso base do problema 3.....	106
Figura 55 –	Histograma com evolução do VPL após otimizações dos problemas 2 e 3..	108
Figura 56 –	Comparativo de óleo e água acumulados (m3) para o reservatório Egg Model no problema 3.....	109
Figura 57 –	Saturação de água para o reservatório Egg Model para o problema 3.....	110
Figura 58 –	Comparativo da produção acumulada de água (m3/dia) entre os casos base	

	e a melhor solução encontrada para o problema 3.....	110
Figura 59 –	Comparativo do corte de água dos produtores para o caso base e para a melhor solução encontrada para o problema 3.....	111
Figura 60 –	Produção de líquidos (m3/dia) da melhor solução para o problema 3.....	112
Figura 61 –	Injeção de água (m3/dia) da melhor solução para o problema 3.....	112
Figura 62 –	Pressão de fundo de poço (BHP) dos poços produtores na melhor solução para o problema 3.....	113
Figura 63 –	Pressão de fundo de poço (BHP) dos poços injetores na melhor solução para o problema 3.....	113
Figura 64 –	Saturação de óleo: (a) caso base, (b) solução da locação e vazões através de abordagem integrada com o AG e (c) solução final com acréscimo de etapa com o SAO.....	114
Figura 65 –	Locação base e posicionamento otimizado dos poços para as 20 soluções do problema 1.....	127
Figura 66 –	Locação base e posicionamento otimizado dos poços para as 20 soluções dos problemas 2 e 3.....	130

LISTA DE TABELAS

Tabela 1 -	Propriedades petrofísicas do reservatório Egg Model.....	62
Tabela 2 -	Condições operacionais dos poços do reservatório Egg Model.....	63
Tabela 3 -	Parâmetros econômicos do reservatório Egg Model.....	63
Tabela 4 -	Parâmetros adotados para o modelo substituto (problema 1)	64
Tabela 5 -	Parâmetros adotados para o modelo substituto (problemas 2 e 3)	65
Tabela 6 -	Resumo de resultados para escolha dos tamanhos de amostras.....	66
Tabela 7 -	Resultados estatísticos obtidos na primeira etapa do problema 1 (locação de poços)	69
Tabela 8 -	Coordenadas do caso base do problema 1.....	78
Tabela 9 -	Valores de vazões em m ³ /dia, adotadas para entrada na segunda etapa, e coordenadas após etapa 1 do problema 1.....	79
Tabela 10 -	Valores de finais de vazões em m ³ /dia para o caso otimizado pós SAO.....	80
Tabela 11 -	Resultados estatísticos obtidos para o problema 1.....	81
Tabela 12 -	Resultados estatísticos obtidos para o problema 1 em relação ao caso base.	81
Tabela 13 -	Resultados estatísticos obtidos para o problema 2.....	91
Tabela 14 -	Resultados estatísticos obtidos para o problema 2 em relação ao caso base.....	92
Tabela 15 -	Valores de vazões em m ³ /dia e coordenadas do caso base para o problema 2.....	96
Tabela 16 -	Valores de vazões em m ³ /dia e coordenadas da melhor solução para o problema 2.....	96
Tabela 17 -	Resultados estatísticos obtidos para o problema 3.....	103
Tabela 18 -	Resultados estatísticos obtidos para o problema 3 em relação ao caso base.....	103
Tabela 19 -	Valores de vazões em m ³ /dia e as coordenadas do caso base para o problema 3.....	105
Tabela 20 -	Valores de vazões em m ³ /dia da melhor solução para o problema 3.....	107
Tabela 21 -	Comparativo entre os resultados estatísticos obtidos para os problemas 2 (AGint) e 3 (AGint + SAO)	107
Tabela 22 -	Comparativo entre os resultados estatísticos, em percentual, obtidos para	

	os problemas 2 (AGint) e 3 (AGint + SAO)	108
Tabela 23 -	Resumo dos resultados estatísticos obtidos todos os problemas estudados.....	114
Tabela 24 -	Coordenadas dos poços produtores obtidas na primeira parte do problema 1 (locação de poços)	125
Tabela 25 -	Coordenadas dos poços injetores obtidas na primeira parte do problema 1 (locação de poços)	126
Tabela 26 -	Coordenadas dos poços produtores obtidas nos problemas 2 e 3.....	128
Tabela 27 -	Coordenadas dos poços injetores obtidas nos problemas 2 e 3.....	129
Tabela 28 -	Resultados de VPL obtidos para o problema 1.....	131
Tabela 29 -	Resultados de VPL obtidos para o problema 2.....	132
Tabela 30 -	Resultados de VPL obtidos para o problema 3.....	133

SUMÁRIO

1	INTRODUÇÃO.....	17
1.1	MOTIVAÇÃO.....	17
1.2	OBJETIVOS.....	21
1.3	METODOLOGIA.....	21
1.4	ORGANIZAÇÃO DO TEXTO.....	22
2	FORMULAÇÃO MATEMÁTICA PARA OS PROBLEMAS DE LOCAÇÃO E GERENCIAMENTO ÓTIMO DE RESERVATÓRIOS.....	24
2.1	LOCAÇÃO DE POÇOS DE PETRÓLEO.....	24
2.2	GERENCIAMENTO DE VAZÕES NOS POÇOS DE PETRÓLEO.....	26
2.3	LOCAÇÃO E GERENCIAMENTO DE VAZÕES DE POÇOS DE PETRÓLEO.....	28
3	MODELOS SUBSTITUTOS.....	32
3.1	TERMINOLOGIA E CLASSIFICAÇÃO.....	32
3.2	PLANO DE AMOSTRAGEM.....	34
3.2.1	Hipercubo latino (LHS).....	36
3.3	CRIAÇÃO DO MODELO SUBSTITUTO GLOBAL.....	37
3.3.1	Funções de base radial (RBF).....	38
3.3.2	Tratamento das amostras.....	40
3.3.2.1	Problema de locação.....	40
3.3.2.2	Problema integrado de locação e vazão.....	41
3.4	PRECISÃO DO MODELO SUBSTITUTO.....	42
4	ESTRATÉGIAS PARA OTIMIZAÇÃO.....	43
4.1	ALGORITMO GENÉTICO.....	43
4.1.1	Representação e estrutura de dados.....	44
4.1.2	Parâmetros do algoritmo genético.....	44
4.1.2.1	Opções de população.....	45
4.1.2.2	Seleção de indivíduos.....	45
4.1.2.3	Cruzamento.....	46
4.1.2.4	Mutação.....	46
4.1.2.5	Escalonamento de aptidão.....	47

4.1.3	Manipulação das restrições.....	48
4.1.3.1	Reparação de cromossomos.....	48
4.1.3.2	Penalização adaptativa.....	50
4.1.4	Crítérios de parada.....	51
4.1.5	Modelo substituto adaptativo.....	52
4.1.5.1	Adaptação do MS para o problema de locação.....	54
4.1.5.2	Adaptação do MS para o problema integrado de locação e vazão.....	56
4.2	OTIMIZAÇÃO POR APROXIMAÇÃO SEQUENCIAL.....	57
4.2.1	Formulação matemática.....	57
4.2.2	Atualização da região de confiança.....	58
4.2.3	Algoritmo.....	59
4.2.4	Crítérios de convergência.....	60
5	CASOS ESTUDADOS E RESULTADOS OBTIDOS.....	61
5.1	RESERVATÓRIO EGG MODEL.....	61
5.2	PARÂMETROS DO AG.....	63
5.3	PROBLEMAS ESTUDADOS.....	66
5.3.1	Problema 1 - Otimização em dois estágios: locação dos poços (AG) e gerenciamento de vazões (SAO).....	66
5.3.2	Problema 2 - Otimização simultânea da locação dos poços e do gerenciamento de vazões (AG).....	90
5.3.3	Problema 3 - Otimização da locação dos poços e gerenciamento de vazões integradas (AG) + gerenciamento de vazões (SAO).....	102
5.4	RESUMO DOS RESULTADOS.....	114
6	OBSERVAÇÕES FINAIS.....	115
6.1	CONCLUSÕES.....	115
6.2	SUGESTÕES PARA TRABALHOS FUTUROS	116
	REFERÊNCIAS.....	118
	APÊNDICE A – PROBLEMAS 1, 2 E 3.....	125

1 INTRODUÇÃO

Este trabalho está concentrado na área de Engenharia de Reservatórios de Petróleo, mais especificamente no desenvolvimento e utilização de ferramentas e técnicas computacionais que otimizam o posicionamento de poços e as vazões associadas a esses poços. Essa otimização tem como objetivo maximizar a estimativa do lucro do reservatório a ser explorado.


Essa seção traz uma discussão do cenário que motivou o desenvolvimento deste trabalho e os objetivos associados a esta pesquisa. Além disso, é apresentada uma breve descrição da metodologia adotada e como este texto está organizado.

1.1 MOTIVAÇÃO

O cenário energético traz múltiplos desafios e incertezas e é influenciado diretamente pela demanda, oferta e por eventos históricos mundiais. O consumo de energia funciona como um indicador do desenvolvimento econômico mundial e do avanço do acesso da população a bens de consumo e serviços.

Acontecimentos recentes como a pandemia do COVID-19 que atingiu o mundo inteiro a partir de 2020 trouxe consequências na economia, afetando a produção e o consumo energético. Estima-se que a demanda global de energia tenha caído 4,5%. Esta é a maior recessão desde o final da segunda guerra mundial, impulsionada por um colapso sem precedentes na demanda de petróleo, já que a restrição de mobilidade devido ao isolamento imposto em todo o mundo dizimou a demanda relacionada ao transporte. Estima-se também que a demanda de petróleo tenha caído 9,3% nesse mesmo ano (Figura 1), o que representa o maior declínio em consumo na história recente (PETROLEUM, 2021).

Figura 1 – Histórico da mudança anual na demanda de óleo.



Fonte: Petroleum (2021).

Dados apresentados pela *British Petroleum Statistical Review of World Energy* de 2021 (PETROLEUM, 2021) demonstram que o preço do óleo atingiu a média de US \$ 41,84/barril em 2020, o menor desde 2004. O consumo de petróleo caiu em nível recorde e atingiu o seu nível mais baixo desde 2011. A produção global também encolheu. Tudo isso foi reflexo da pandemia.

Por outro lado, a participação das energias renováveis, excluindo hidrelétricas, na geração global de energia continuou sua tendência de crescimento, impulsionada pela forte expansão da energia solar e eólica (PETROLEUM, 2022).


A demanda e as emissões de energia voltaram aos níveis de antes da pandemia em 2021, revertendo a redução temporária de 2020 resultante da pandemia de COVID-19 (PETROLEUM, 2022). Sendo importante destacar, por exemplo, que:

- O preço médio do barril de óleo cru atingiu o valor de US \$ 70,91 em 2021, o que representa o segundo nível mais alto desde 2015.
- O consumo de petróleo aumentou em 5,3 milhões de barris por dia (b/d) em 2021. Esse dado ainda é 3,7 milhões b/d abaixo dos níveis de 2019 (antes da pandemia).
- A maior parte do crescimento desse consumo veio da gasolina (1,8 milhão b/d) e diesel (1,3 milhão b/d). Trazendo uma análise regional, a maior parte do crescimento veio dos EUA (1,5 milhão b/d), China (1,3 milhão b/d) e União Europeia (570.000 b/d).
- A produção global de petróleo também aumentou em 1,4 milhão de b/d no ano de 2021.

O cenário pontuado acima demonstra que a demanda vem crescendo novamente, revertendo a queda acentuada no consumo de energia que ocorreu em 2020 em grande parte do mundo. A partir de 2021, o sistema de energia vem se recuperando à medida que a economia global se recupera da pandemia.

Segundo a Agência Internacional de Energia (IEA), mesmo com essa recuperação, o choque da demanda induzido pela pandemia e o direcionamento de investimento em energia limpa devem desacelerar a expansão da capacidade mundial de produção de petróleo ao longo dos próximos anos, Figura 2, (IEA, 2021).

Figura 2 – Previsão do crescimento anual da demanda global de petróleo.




Fonte: IEA (2021).

Mesmo durante uma provável transição energética, é crucial continuar a investir no setor de petróleo, pois as mudanças dessa transição poderão levar anos até que sejam estabelecidas. Setores como aviação, navegação e petroquímica continuarão a depender do petróleo por algum tempo.

Segundo a Administração de Informações de Energia dos Estados Unidos (U.S. EIA, 2022), o consumo de energias renováveis nos EUA (maior consumidor do mundo) cresce mais rápido, mas a previsão é de permanecer muito abaixo do consumo de petróleo e outros líquidos em 2050, conforme projeção apresentada na Figura 3.

Figura 3 – Consumo de energia por combustível (em quatrilhão de unidades térmicas britânicas).




Fonte: U.S. EIA (2022).

As previsões para os anos seguintes indicavam uma tendência de retomada no consumo de energia, o que foi confirmado pela *British Petroleum Statistical Review of World*

Energy de 2022 (PETROLEUM, 2022). A Figura 4 mostra essa retomada que foi impulsionada, especialmente, por fontes de energias renováveis. O nível de consumo de energia de combustíveis fósseis permaneceu inalterado entre 2019 e 2021, com menor demanda de petróleo compensada pelo maior consumo de gás natural e carvão.

Figura 4 – Mudança na energia primária por combustível.



Fonte: Petroleum (2022).

Após essas considerações, fica claro que a indústria de petróleo e gás ainda tem um papel relevante a desempenhar nos próximos anos.

Diante disso, um aspecto importante dentro da Engenharia de Reservatórios envolve a preocupação em maximizar as estimativas de lucro obtido a partir da exploração de um reservatório. Isso é uma tarefa complexa que exige uma equipe multidisciplinar altamente capacitada, pois a elaboração de planos de desenvolvimento e exploração de campos de petróleo requer a tomada de decisões estratégicas e operacionais diante de várias opções disponíveis (LIMA; ABREU; PACHECO, 2015). Tais decisões visam otimizar o valor presente líquido do projeto.

Projetos que envolvem o desenvolvimento, gerenciamento e operação de reservatórios de petróleo necessitam de grandes investimentos. Há um grande risco, visto que mesmo pequenos erros podem resultar em prejuízos financeiros significativos. A complexidade desses projetos que podem envolver muitas variáveis, restrições e incertezas, tornam mais necessária a tomada das melhores decisões. Assim, a aplicação de uma ferramenta computacional que dê suporte nesse processo é um grande diferencial.

Este trabalho também foi desenvolvido visando dar continuidade aos estudos da área de otimização de reservatórios de petróleo realizados pelo grupo de Simulação e

Gerenciamento de Reservatórios (SIGER) do Laboratório Integrado de Tecnologia em Petróleo, Gás e Biocombustíveis (LITPEG) da Universidade Federal de Pernambuco (UFPE).

1.2 OBJETIVOS

Esta dissertação tem como objetivo apresentar ferramenta desenvolvida e os estudos que foram realizados a partir de diferentes formulações e metodologias aplicadas para a otimização de problemas de locação de poços e gerenciamento ótimo de vazões de um reservatório de petróleo. O foco aqui é também demonstrar a eficácia da combinação de métodos de otimização com modelos substitutos adaptativos para solucionar os problemas tratados neste trabalho.

Este trabalho possui os seguintes objetivos específicos:

- Estudar diferentes abordagens para otimização da locação de poços e vazões.
- Analisar o impacto de cada abordagem aplicada ao reservatório estudado.
- Utilizar técnicas de otimização para maximizar o VPL do reservatório estudado.
- Aplicação de metamodelos visando reduzir o custo computacional do processo de otimização.

Além disso, discute-se acerca de uma proposta de metodologia que é aplicada ao processo de adaptabilidade dos modelos substitutos que torna o processo de otimização mais eficiente e, computacionalmente, menos custoso.

1.3 METODOLOGIA

Os problemas apresentados nesta dissertação envolvem a otimização da locação de poços e o gerenciamento de vazões e utilizaram do simulador comercial IMEX (COMPUTER MODELLING GROUP LTD, 2016). Este é responsável por definir as vazões dos poços a partir das características petrofísicas do reservatório. A partir das simulações numéricas feitas é possível definir o VPL e analisar a viabilidade econômica de exploração do reservatório.

Configurações de localização e controle de poços são decisões críticas que precisam ser tomadas durante o desenvolvimento do campo e estudos de otimização da produção para maximizar o lucro econômico da produção de petróleo e gás (SALEHIAN; SEFAT; MURADOV, 2021). Portanto, para cada problema, foi definida uma metodologia específica para a busca de solução com o emprego de algoritmos genéticos (AG) (GOLDBERG, 1988) e da estratégia de otimização sequencial aproximada (SAO) (GIUNTA; ELDRED, 2000) que utiliza o otimizador SQP do MATLAB (MATHWORKS, INC., 2018).

O primeiro problema teve o emprego de uma abordagem de otimização realizada em duas etapas (em sequência) que utilizaram o AG e o SAO. O AG definiu a melhor locação para os poços do reservatório e o SAO otimizou os controles de produção e injeção desses poços. No segundo problema foi utilizado o AG através de uma abordagem integrada que solucionava o problema de posicionamento de poços e das suas vazões simultaneamente. Para o terceiro, foi aplicada a metodologia do segundo problema (AG integrado) combinada com o SAO caracterizando uma estratégia híbrida para encontrar a melhor configuração dos poços (melhores locações e vazões).

Há um elevado custo computacional associado às sucessivas avaliações da função objetivo no simulador. Para contornar essa situação, foram utilizados modelos substitutos construídos a partir da técnica de Funções de Base Radial (RBF) (GUTMANN, 2001). Esses modelos permitem a construção de uma superfície de resposta que se aproxima da resposta da função real.

Os modelos substitutos criados foram enriquecidos de maneira adaptativa durante o processo de otimização e seguiram uma metodologia de criação e inserção de pontos que foi baseada em Redouane, Zeraibi e Nait Amar (2019).

A função objetivo deste trabalho é o valor presente líquido (VPL) do reservatório aqui estudado.

1.4 ORGANIZAÇÃO DO TEXTO

O capítulo 2 apresenta uma contextualização dos problemas estudados nesta dissertação e as formulações matemáticas desses problemas.

O capítulo 3 trata de tópicos gerais relacionados a modelos substitutos como terminologia e classificação. Com destaque para pontos que foram aplicados neste trabalho, tais como: plano de amostragem, Hipercubo Latino, Funções de Base Radial e os métodos de criação dos modelos substitutos utilizados para cada problema.

No capítulo 4 são abordadas as estratégias de otimização utilizadas neste trabalho para solucionar os problemas aqui estudados. São apresentados o Algoritmo Genético (AG) e seus principais parâmetros, as técnicas de manipulação das restrições e critérios de parada empregados para o AG. Ainda são explicados os processos de adaptação dos modelos substitutos empregados para os diferentes problemas estudados aqui. Também é apresentada a definição de Otimização Sequencial por Aproximação (SAO), sua formulação matemática e os critérios de convergência adotados para o SAO.

O capítulo 5 traz uma apresentação do reservatório analisado e todos os resultados referentes aos casos estudados.

No capítulo 6 é onde podem ser encontradas as conclusões acerca do que foi observado nos resultados apresentados no capítulo anterior. Também são feitas sugestões para trabalhos futuros que possam dar continuidade à temática discutida aqui. As referências bibliográficas utilizadas para a construção desse trabalho são listadas na sequência.

2 FORMULAÇÃO MATEMÁTICA PARA OS PROBLEMAS DE LOCAÇÃO E GERENCIAMENTO ÓTIMO DE RESERVATÓRIOS

Todos os problemas deste trabalho visam maximizar o valor presente líquido (VPL) do reservatório estudado. Para cada um deles são descritas suas restrições e particularidades. A função que avalia a metodologia empregada aqui considera o fluxo de caixa de entradas e saídas ao longo do tempo de exploração do reservatório.

Aqui são apresentadas três diferentes formulações que foram utilizadas nos problemas analisados.

2.1 LOCAÇÃO DE POÇOS DE PETRÓLEO

Um dos desafios que envolvem o problema de locação de poços é desenvolver uma formulação que represente esse problema de maneira adequada. Para isso, são definidos inicialmente os parâmetros que descrevem o problema, entre eles a localização dos poços dentro da malha do reservatório estudado (REDOUANE; ZERAIBI; NAIT AMAR, 2019). Tal como anteriormente apresentado, o valor presente líquido (VPL) é a função objetivo considerada neste trabalho. Portanto, os poços são posicionados em locais ótimos do reservatório baseados nos resultados de produção e injeção do modelo numérico que é utilizado para avaliar, com alta fidelidade, a resposta do reservatório. Ou seja, para o cálculo do VPL é necessária uma previsão da produção que está associada a um cenário de posicionamento dos poços (SATTER; IQBAL, 2015).

Restrições distintas são impostas aos problemas. Estas podem abranger o comprimento de poços, a quantidade de poços, os tipos (injetores e produtores), os limites de reservatório, a orientação dos poços, a distância entre poços, entre outras restrições (FOROUZANFAR; POQUIOMA; REYNOLDS, 2016). Muitos estudos de locação de poços utilizaram reservatórios sintéticos ou modelos de *benchmark* que usam restrições simplificadas que podem gerar diferenças para situações reais de projetos (BANGERTH et al., 2006). Levando isso em consideração, neste trabalho foram definidas duas restrições para o problema de locação: atividade dos blocos que está associada aos limites do reservatório e distância entre poços.

A restrição de atividade dos blocos pode ser colocada como uma restrição de limite do reservatório onde os poços só podem ser posicionados dentro de um domínio determinado. Essa situação se aproxima de reservatórios reais, pois estes normalmente possuem formatos mais complexos e irregulares. A restrição de distância mínima entre os poços foi definida

visando diminuir os efeitos de interferência entre poços. Assim, para essa restrição, todos os poços devem respeitar uma distância em relação aos outros.

Nos problemas de otimização de locação de poços para campo de petróleo, as variáveis de decisão, usadas para definir o espaço de busca, são normalmente tratadas como discretas, inteiras e positivas (REDOUANE; ZERAIBI; NAIT AMAR, 2019). Desse modo, através de um esquema centrado de blocos, os poços são identificados a partir dos seus índices (i, j, k) que são referenciados na malha do reservatório.

Para a locação de poços, o número total de variáveis de projeto varia de acordo com o que é definido para cada problema. Nesta etapa foi realizada a locação topográfica dos poços onde foram utilizadas as coordenadas $x_{i,w}$ e $x_{j,w}$ para representar a posição de cada poço dentro do domínio de trabalho. Desse modo, cada poço a ser locado no reservatório possui duas variáveis (n_c) associadas a ele. A partir disso, o número total de variáveis para locação (ndv_{loc}) pode ser definido como indica a Eq.(1):

$$ndv_{loc} = (n_p + n_l) \cdot n_c \quad (1)$$

Onde n_p e n_l representam o número de poços produtores e injetores, respectivamente.

A formulação para o problema de locação foi desenvolvida por Andrade et al. (2021a) e é apresentada a seguir pela Eq.(2):

$$\begin{aligned} \text{Maximize VPL} = f(\mathbf{x}) &= \frac{1}{(1 + d)^{\tau_t}} F(\mathbf{x}) \\ \text{Sujeito a: } \mathbf{x} &= [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_w, \dots, \mathbf{X}_{n_w}], \quad \mathbf{X}_w = [x_{i,w}, x_{j,w}], \quad w = 1 \dots n_w \\ x_{i,w} &\leq n_{cl}, \quad w = 1 \dots n_w, \quad x_{i,w} \in \mathbb{N}^* \\ x_{j,w} &\leq n_{cj}, \quad w = 1 \dots n_w, \quad x_{j,w} \in \mathbb{N}^* \\ \prod_{w=1}^{n_w} \left(\prod_{k=1}^{n_{ck}} id_w(x_{k,w}) \right) &= 1 \\ \|\mathbf{X}_a, \mathbf{X}_b\| &\geq dist_{min}, \quad a, b = 1 \dots n_w \quad \text{com } a \neq b \\ id_w(x_{k,w}) &= \begin{cases} 0, & \text{para blocos inativos} \\ 1, & \text{caso contrário} \end{cases} \end{aligned} \quad (2)$$

Onde $f(\mathbf{x})$ é a função objetivo (VPL); $\mathbf{x} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_w, \dots, \mathbf{X}_{n_w}]$ é o vetor de variáveis, onde $\mathbf{X}_w = [x_{i,w}, x_{j,w}]$, ou seja, $x_{i,w}$ e $x_{j,w}$ são as variáveis representadas pelas coordenadas dos poços e definem a posição do bloco na malha com $\mathbf{X}_w \in \mathbb{N}^*$ (pertencente aos naturais, excluindo zero); além das coordenadas que compõem o vetor $\mathbf{X}_w$, há também $x_{k,w}$ com $k = 1 \dots n_{cK}$; n_{cl} , n_{cj} e n_{cK} são, nesta ordem, o máximo número de blocos nas direções

i, j e k da malha do reservatório; n_w é o número total de poços; $dist_{min}$ é uma constante que estabelece a distância euclidiana mínima entre o poço a e qualquer poço b ; $x_{i,w}$ e $x_{j,w}$ são inteiros e reais. $id_w(x_{k,w})$ é um índice que define se um bloco está localizado em uma célula ativa ou inativa. Aqui, para $x_{k,w}$ é considerado que o poço é perfurado até o limite n_{cK} , mantendo a locação topográfica como o problema a ser otimizado. Assim, n_{cK} é utilizado apenas para verificar se um poço está locado em um ponto onde todas as camadas estão ativas. Na função objetivo, d é a taxa de desconto aplicada ao capital e τ_t é o tempo ao final do t -ésimo passo de tempo. O fluxo de caixa F no passo de tempo t , que representa a receita do petróleo produzido retirando os custos de injeção e produção de água, é dado por Horowitz, Afonso e De Mendonça (2013) e está descrito pela Eq.(3):

$$F(\mathbf{x}_t) = \Delta\tau_t \left[\sum_{w \in P} (r_o q_{t,w}^o - c_w q_{t,w}^{wt}) - \sum_{w \in I} c_{wi} q_{t,w} \right] \quad (3)$$

Onde, numa formulação geral, $\Delta\tau_t$ é o intervalo de tempo no t -ésimo passo de tempo. P e I fazem referência aos poços produtores e injetores, respectivamente; $q_{t,w}^o$ e $q_{t,w}^{wt}$ são as taxas médias de produção de óleo e água no w -ésimo poço produtor no t -ésimo passo de tempo; r_o é o preço do óleo; c_w e c_{wi} são os custos de produção e injeção de água, nesta ordem; $q_{t,w}$ é o fluxo de água injetada no w -ésimo poço injetor durante o tempo de concessão.

2.2 GERENCIAMENTO DE VAZÕES NOS POÇOS DE PETRÓLEO

A otimização dos parâmetros de controle de poços em cada etapa de controle durante a produção é um dos procedimentos mais importantes para obter melhores resultados econômicos e eficiência de recuperação (ZHAO et al., 2020). Na otimização tradicional de controle de poços, muitos pesquisadores consideram o valor presente líquido (VPL) como o único objetivo para otimizar esquemas de controle de poços (ZHANG et al., 2020). No entanto, na área de desenvolvimento petrolífero, os engenheiros se deparam com mais de um objetivo, como maximizar o lucro enquanto minimizam riscos ou maximizar a produção enquanto minimizam o custo.

Determinar as taxas de produção e de injeção do poço é de suma importância no desenvolvimento de reservatórios modernos e é uma decisão difícil, pois as taxas ótimas dependem da heterogeneidade das rochas e dos líquidos, do posicionamento dos poços e de outros parâmetros. Essas propriedades e parâmetros de entrada são acoplados de maneira altamente não linear. Além disso, as taxas ótimas de produção e injeção geralmente não são constantes ao longo do ciclo de vida do reservatório, pois a distribuição da saturação do óleo

muda durante os processos de injeção e produção dos poços. Isso afetará então as taxas ideais de produção e de injeção para cada poço (CHEN et al., 2020).

O planejamento de controle de poços pode ser formulado como um problema de otimização, usando a produção econômica ou cumulativa de petróleo como função objetivo (WANG et al., 2019). Nesta situação, assim como no problema de locação, o VPL é a função objetivo considerada. Neste trabalho, para o problema de gerenciamento de vazões, as restrições impostas se referem tanto aos poços de modo individual como em relação ao reservatório como um todo. Cada poço tem, por questões operacionais, suas vazões e pressões máximas e/ou mínimas. Todos os poços, injetores ou produtores, levando em consideração as suas finalidades, estão ligados a unidades de injeção ou produção do campo. Essas unidades possuem capacidades limitadas, não sendo permitido que as vazões de produção e injeção violem tais limitações.

Para o problema de locação ou gerenciamento de vazões, a simulação numérica é a técnica mais comum usada para obter o desempenho do reservatório e calcular os valores das funções objetivo (ZHANG et al., 2019).

São definidos os melhores controles de produção e injeção para os poços utilizando a seguinte formulação matemática representada pela Eq.(4):

$$\begin{aligned}
 \text{Maximize VPL} = f(\mathbf{q}) &= \sum_{t=1}^T \left[\frac{1}{(1+d)^{\tau_t}} F(\mathbf{q}_t) \right] \\
 \text{Sujeito a: } \sum_{w \in P} q_{t,w} &\leq Q_{l,max}, \quad t = 1 \dots T \\
 \sum_{w \in I} q_{t,w} &\leq Q_{inj,max}, \quad t = 1 \dots T \\
 q_{t,w}^{lb} &\leq q_{t,w} \leq q_{t,w}^{ub}, \quad w = 1 \dots n_w, \quad t = 1 \dots T
 \end{aligned} \tag{4}$$

Onde $\mathbf{q} = [\mathbf{q}_1^T \ \mathbf{q}_2^T \dots \mathbf{q}_{n_t}^T]^T$ é o vetor com as taxas de vazão para todo o tempo de concessão do reservatório; $\mathbf{q}_t = [q_{t,1} \dots q_{t,n_w}]^T$ é o vetor com os valores de vazão no passo de tempo t ; $q_{t,w}$ é a taxa de líquido do poço w no passo de tempo t ; T é o tempo de concessão do reservatório; n_w é o número total de poços e n_t é o número de ciclos de tempo (ciclos de controle). Na Eq.(4), d é a taxa de desconto e τ_t é o tempo ao final do t -ésimo passo de tempo. O fluxo de caixa F segue o que foi apresentado na Eq.(3). Ainda na Eq.(5), $Q_{l,max}$ é a vazão máxima permitida para a produção de líquidos na plataforma e $Q_{inj,max}$ é a vazão máxima

permitida para a injeção de água na plataforma. Os limites superior e inferior para os valores de vazões no vetor de variáveis são dados por $q_{t,w}^{ub}$ e $q_{t,w}^{lb}$, respectivamente.

Comumente, as taxas de poços são normalizadas a partir das taxas máximas permitidas para as plataformas, como mostrado na Eq.(5).

$$x_{t,w} = \frac{q_{t,w}}{Q_{l,max}}, w \in P \quad \text{e} \quad x_{t,w} = \frac{q_{t,w}}{Q_{inj,max}}, w \in I \quad (5)$$

Há dois tipos de operação para o controle de vazões: operação em capacidade topada (OCT), onde a soma das vazões de injeção e produção trabalham em suas capacidades máximas e operação em capacidade não-topada (OCNT), situação onde não há necessidade de atendimento dessa restrição (HOROWITZ; AFONSO; DE MENDONÇA, 2013). Neste trabalho, esta última foi a configuração adotada. Diante das considerações apresentadas, a formulação matemática para a operação em capacidade não-topada (OCNT) com tempo fixo é dada na Eq.(6) a seguir.

$$\begin{aligned} \text{Maximize VPL} = f(\mathbf{x}) &= \sum_{t=1}^T \left[\frac{1}{(1+d)^{\tau_t}} F(\mathbf{x}_t) \right] \\ \text{Sujeito a: } \sum_{w \in P} x_{t,w} &\leq 1, \quad t = 1 \dots T \\ \sum_{w \in I} x_{t,w} &\leq 1, \quad t = 1 \dots T \\ x_{t,w}^{lb} &\leq x_{t,w} \leq x_{t,w}^{ub}, \quad w = 1 \dots n_w, \quad t = 1 \dots T \end{aligned} \quad (6)$$

O período concessão T é dividido em um número de ciclos de controle n_t com tempos fixos para a troca de ciclo. Portanto, o número total de variáveis para OCNT é dado pela Eq.(7).

$$ndv_{vaz} = (n_p + n_i) \cdot n_t \quad (7)$$

Onde ndv_{vaz} é o número total de variáveis, n_p é o número de poços produtores, n_i é a quantidade de poços injetores e n_t é a quantidade total de ciclos de controle.

2.3 LOCAÇÃO E GERENCIAMENTO DE VAZÕES DE POÇOS DE PETRÓLEO

Técnicas de otimização vêm sendo desenvolvidas para vários tipos de campos e diferentes decisões operacionais, incluindo a determinação da localização ótima de poços e os controles ideais de operação. Tradicionalmente, a otimização da localização de poços tem sido estudada de maneira separada da otimização dos controles de operação de poços. No entanto, trabalhos desenvolvidos nos últimos anos demonstraram que a localização ideal de

um poço depende diretamente de como o poço será operado (ISEBOR; DURLOFSKY; ECHEVERRÍA CIAURRI, 2014).

Um ineficiente posicionamento de poços pode levar ao desenvolvimento de um campo pouco produtivo e, por consequência, a um desempenho inadequado do reservatório. Já um posicionamento ideal de poços pode melhorar significativamente o desempenho dos reservatórios e reduzir o custo geral do desenvolvimento de um campo. Ao otimizar o desempenho geral do ciclo de vida do reservatório, além de identificar as localizações ideais dos poços, é necessário especificar a melhor configuração operacional para cada poço. Quando esses problemas são resolvidos separadamente, cada um deles pode fornecer uma solução abaixo do ideal para a otimização geral do desempenho de campo (LI; JAFARPOUR; MOHAMMAD-KHANINEZHAD, 2013).

Uma abordagem mais estratégica é resolver o problema de otimização de posicionamento de poço e de controles de maneira acoplada e simultânea ao invés de tratá-los como dois problemas de otimização separados, ou seja, que são solucionados de maneira sequencial. Uma das limitações das abordagens sequenciais é que ao ser realizada a primeira etapa de otimização da locação de poços, a solução encontrada pelo algoritmo pode parecer impraticável ou mesmo difícil de perfurar.

Adicionalmente, Zandvliet, Handels e Van Essen (2008) e Bellout et al. (2012) demonstraram que as localizações de poços otimizadas dependem da estratégia de controle utilizada durante a otimização de posicionamento de poços. Assim, espera-se que qualquer abordagem que não tenha como objetivo otimizar simultaneamente a localização dos poços e os controles forneça resultados, teoricamente, abaixo do ideal. Alguns estudos fizeram um comparativo entre abordagens conjuntas e sequenciais. Bellout et al. (2012) e Li e Jafarpour (2012) descobriram que as suas investigações com abordagens simultâneas superaram os procedimentos sequenciais. Por outro lado, Humphries, Haynes e James (2014) não encontraram indícios que uma abordagem conjunta possa fornecer resultados superiores em relação ao procedimento sequencial.

A abordagem integrada otimiza, em um único vetor, todas as variáveis de posicionamento de poços e as configurações de controle de cada poço. No entanto, quando se trabalha com um número muito grande de variáveis, a utilização dessa abordagem pode resultar em falhas do algoritmo de otimização devido à sua incapacidade de lidar com problemas tão complexos (LU; FOROUZANFAR; REYNOLDS, 2017).

O problema integrado de locação e gerenciamento de vazões de poços de petróleo segue a formulação matemática dada por Andrade et al. (2021b) e que está descrita na Eq.(8) para o seu processo de otimização.

$$\begin{aligned}
 \text{Maximize VPL} = f(\mathbf{x}) &= \sum_{t=1}^T \left[\frac{1}{(1+d)^{\tau_t}} F(\mathbf{x}) \right] \\
 \text{Sujeito a: } \mathbf{x} &= [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_w, \dots, \mathbf{X}_{n_w}], \quad \mathbf{X}_w = [x_{i,w}, x_{j,w}], \quad w = 1 \dots n_w \\
 x_{i,w} &\leq n_{cl}, \quad w = 1 \dots n_w, \quad x_{i,w} \in \mathbb{N}^* \\
 x_{j,w} &\leq n_{cj}, \quad w = 1 \dots n_w, \quad x_{j,w} \in \mathbb{N}^* \\
 \prod_{w=1}^{n_w} \left(\prod_{k=1}^{n_{cK}} id_w(x_{k,w}) \right) &= 1 \\
 \|(\mathbf{X}_a, \mathbf{X}_b)\| &\geq dist_{min}, \quad a, b = 1 \dots n_w \quad \text{com } a \neq b \\
 id_w(x_{k,w}) &= \begin{cases} 0, & \text{para blocos inativos} \\ 1, & \text{caso contrário} \end{cases} \\
 \sum_{w \in P} x_{t,w} &\leq 1, \quad t = 1 \dots T \\
 \sum_{w \in I} x_{t,w} &\leq 1, \quad t = 1 \dots T \\
 x_{t,w}^{lb} &\leq x_{t,w} \leq x_{t,w}^{ub}, \quad w = 1 \dots n_w, \quad t = 1 \dots T \\
 \text{com } x_{t,w} &= \frac{q_{t,w}}{Q_{l,max}}, w \in P \quad \text{e} \quad x_{t,w} = \frac{q_{t,w}}{Q_{inj,max}}, w \in I
 \end{aligned} \tag{8}$$

Onde $f(\mathbf{x})$ é a função objetivo a ser maximizada (valor presente líquido); o vetor de variáveis é representado por $\mathbf{x} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_w, \dots, \mathbf{X}_{n_w}, x_{t,1}, x_{t,2}, \dots, x_{t,w}, \dots, x_{t,n_w}]$, onde $\mathbf{X}_w = [x_{i,w}, x_{j,w}]$, $x_{i,w}$ e $x_{j,w}$ são as variáveis representadas pelas coordenadas dos poços e definem a posição do bloco na malha com $\mathbf{X}_w \in \mathbb{N}^*$. O fluxo de caixa F no passo de tempo t é dado na Eq.(3), o desconto aplicado ao capital é dado por d , τ_t é o tempo ao final do t -ésimo passo de tempo. Além das coordenadas que compõem o vetor $\mathbf{X}_w$, há também $x_{k,w}$ com $k = 1 \dots n_{cK}$; as variáveis n_{cl} , n_{cl} e n_{cK} são, nesta ordem, o máximo número de blocos nas direções i , j e k da malha do reservatório; n_w é o número total de poços; $dist_{min}$ é uma constante que estabelece a distância euclidiana mínima entre o poço a e qualquer poço b ; $id_w(x_{k,w})$ é um índice que define se um bloco está localizado em uma célula ativa ou inativa; $x_{i,w}$, $x_{j,w}$, e $x_{k,w}$ são inteiros e reais. Aqui, para $x_{k,w}$ é considerado que o poço é perfurado até o limite de camadas n_{cK} , mantendo a locação topográfica como o problema a ser otimizado.

Assim, n_{cK} é utilizado apenas para verificar se todas as células ao longo do poço estão ativas. As restrições referentes ao problema de gerenciamento de vazões são definidas pelos limites inferior e superior da vazão para cada poço e são descritas como $x_{t,w}^{lb}$ e $x_{t,w}^{ub}$, respectivamente. $q_{t,w}$ é a vazão do poço w (produtor P ou injetor I), $Q_{l,max}$ e $Q_{inj,max}$ são a vazão máxima total de produção de líquidos (óleo e água) e a vazão máxima total de injeção de água permitida para a plataforma, respectivamente.

Para este problema integrado, o número total de variáveis é dado a partir de uma combinação das equações (2) e (6), como é demonstrado na Eq.(9).

$$ndv_{int} = ndv_{loc} + ndv_{vaz} = (n_P + n_I) \cdot n_c + (n_P + n_I) \cdot n_t \quad (9)$$

3 MODELOS SUBSTITUTOS

Em muitos problemas de ciência e engenharia, os pesquisadores fazem uso intenso de códigos de simulação de computador para substituir experimentos físicos caros e melhorar a qualidade e o desempenho de produtos e dispositivos projetados. Essas atividades de simulação são chamadas de engenharia computacional. Infelizmente, embora permita aos cientistas uma maior flexibilidade para estudar fenômenos sob condições controladas, as simulações exigem um investimento substancial de tempo computacional. Uma única simulação pode levar muitos minutos, horas, dias ou até semanas, tornando rapidamente os estudos de parâmetros impraticáveis ((FORRESTER; SÓBESTER; KEANE, 2008);(SIMPSON et al., 2008)). Das diferentes maneiras de lidar com este problema, a construção de modelos de aproximação para prever, com precisão, o desempenho de um sistema está entre as mais populares, pois são computacionalmente mais baratos no processo de avaliação (GORISSEN et al., 2010).

3.1 TERMINOLOGIA E CLASSIFICAÇÃO

Na indústria de petróleo são frequentemente utilizadas simulações numéricas para prever como um reservatório vai se comportar durante o seu período de exploração. De modo geral, os problemas de engenharia de petróleo são complexos e podem envolver muitas variáveis, gerando um alto custo computacional que dificulta a obtenção de um projeto que seja economicamente viável. A otimização de problemas na Engenharia de Reservatórios em conjunto com simulações numéricas também vem sendo usada como uma maneira de planejar e obter projetos mais vantajosos para exploração de um campo, seja no ponto de vista financeiro quanto no quesito eficiência (SEIXAS, 2010).

A otimização com simulação é uma metodologia que envolve o projeto, análise e controle dos complexos sistemas físicos na qual formulações de otimização estão inseridas, obtendo resultados otimizados a partir de avaliações de funções provenientes de simulações numéricas. Nesse processo, as simulações são realizadas repetidas vezes até que sejam obtidos os resultados a partir do algoritmo de otimização. Tal combinação exige um considerável custo computacional, pois o próprio processo de simulação traz uma complexidade diante das funções utilizadas que podem ser altamente não-lineares e, dependendo do algoritmo utilizado, a quantidade de avaliações de função objetivo pode ser tão alta que se pode inviabilizar esse processo (OLIVEIRA, 2006). Para contornar isso, é indicado o uso de técnicas de aproximação que se baseiam em modelos substitutos, ou

metamodelos, pois estes garantem uma otimização eficiente e com um menor tempo de consumo de CPU, sendo assim uma excelente ferramenta para transpor problemas de otimização de engenharia (FORRESTER; SÓBESTER; KEANE, 2008).

O uso de funções aproximadas traz uma resposta computacional mais rápida do que a utilização de modelos de alta fidelidade, pois substituem as funções de alta fidelidade por funções mais simples de serem obtidas que são utilizadas durante o processo de otimização (OLIVEIRA, 2013). Os modelos de engenharia estão agrupados em três categorias (PIETROBOM, 2002):

1. Modelos funcionais: a aproximação da função real é encontrada através da interpolação de valores conhecidos da função objetivo e abrange diferentes abordagens tais como métodos baseados em ajustes de dados e séries polinomiais. Exemplos conhecidos do tipo funcional: redes neurais (DUARTE et al., 2000), interpoladores do tipo polinomiais (BOOR; RON, 1992), funções de base radial (FORRESTER; SÓBESTER; KEANE, 2008; GUTMANN, 2001), krigagem (AFONSO; HOROWITZ; WILLMERSDORF, 2008), splines (WATSON, 1984), mínimos quadrados (CHUNG; ALONSO, 2000);
2. Modelos físicos: envolvem modelos simplificados com base na física do problema estudado envolvendo a solução numérica de equações diferenciais ou integrais. Exemplos conhecidos do tipo físico: modelos de ordem reduzida, funções calculadas considerando modelos linearizados, análise de sistemas dinâmicos utilizando funções descritivas;
3. Modelos híbridos: combinam características dos modelos funcional e físico.


Neste trabalho foi utilizado um modelo da categoria funcional com uma abordagem de ajuste de dados do tipo funções de base radial cúbica (*Radial Basis Function* - RBF) devido a sua maior precisão na criação de modelos substitutos como demonstrou Pinto (2014) em seu trabalho.

Barthelemy e Haftka (1993) identificaram três grupos gerais de aproximação de acordo com os seus intervalos de aplicabilidade no espaço de projeto:

1. Aproximações globais (Figura 5b): seu conceito é válido para todo o espaço de projeto ou, ao menos, para grande parte dele;
2. Aproximações locais (Figura 5c): são válidas nas proximidades do ponto em que foram geradas, ou seja, estimam uma resposta em uma zona limitada do espaço de projeto. Esse tipo de aproximação tem ligação com métodos que usam o conceito de região de confiança (ALEXANDROV et al., 1998);

3. Aproximações de médio alcance: enquadra os dois tipos de aproximação citados anteriormente numa tentativa de dar um aspecto global para as aproximações locais, fazendo uma combinação entre os tipos.

Figura 5 - Exemplos dos tipos de aproximação: (a) espaço de projeto; (b) aproximação global; (c) aproximação local.



Fonte: Silva (2019).

Levando em consideração as classificações acima, para a otimização dos casos de estudo deste trabalho foram empregadas as abordagens de aproximação global e local a serem mais detalhadas posteriormente.

3.2 PLANO DE AMOSTRAGEM

A criação de uma amostra de pontos que sejam únicos e respeitem os limites do espaço de projeto é o primeiro passo para a construção de um modelo substituto baseado em ajuste de dados. Essa metodologia é chamada de plano de amostragem (*Design of Experiments* – DoE) (FORRESTER; SÓBESTER; KEANE, 2008). Essa definição da amostra é importante, pois os pontos que a ela pertencem são os locais nos quais os valores de resposta dos modelos de alta fidelidade são calculados para construir o modelo substituto. Portanto, é

essencial que se trabalhe com um plano de amostragem eficaz com um número mínimo e suficiente de pontos visando reduzir o custo computacional e garantir uma boa precisão para o modelo que será usado (AFONSO; HOROWITZ; WILLMERSDORF, 2008).

Entre as diversas técnicas de amostragem disponíveis, para este trabalho foi usado o Hipercubo Latino (*Latin Hypercube Sampling* – LHS). Sua escolha se deve a sua fácil implementação computacional e seu comportamento na criação de pontos com uma distribuição mais uniforme. Esta última característica é garantida devido a uma maior regularidade na geração das amostras individuais em cada dimensão dos parâmetros da função, fase que acontece antes dos parâmetros serem aleatoriamente combinados para gerar o grupo final de pontos (ROMERO et al., 2006). Porém, é importante destacar que quando se trabalha com problemas de otimização restritos, uma parcela significativa do espaço de projeto criado pode ser inviável. Logo, por esse motivo, deve-se garantir que as amostras criadas, ou pelo menos uma parte representativa delas, estejam dentro do espaço viável, especialmente quando se utiliza algoritmos meta-heurísticos (SILVA, 2019).

Em problemas de otimização como o de posicionamento de poços, onde pode haver um elevado número de variáveis e onde o espaço de projeto viável é bastante limitado devido às suas restrições, faz-se necessário assegurar que uma parte das amostras estejam dentro do domínio viável. Levando isso em consideração, Oliveira (2013) recomenda um percentual de 60% da população sendo inicializada da maneira acima indicada para um melhor desempenho do modelo substituto. Esta também foi a estratégia adotada no desenvolvimento deste trabalho.

Outro ponto significativo a ser citado é o tamanho da amostra, pois isso está diretamente ligado à precisão do modelo. De modo geral, amostras maiores representam modelos substitutos de maior qualidade, porém esse aumento também provoca mais custos. Na literatura foi discutido que quando se trabalha com funções de base radial, o aumento de pontos não necessariamente traz melhorias, pois pode esbarrar no problema de sobreajuste, também chamado de *overfitting*, onde há um excesso de pontos numa mesma região (AMOUZGAR; STRÖMBERG, 2016). Isso faz com que pontos próximos de um outro desconhecido afetem a previsão de resposta nesse ponto, ou seja, os pontos de amostragem influenciarão apenas em uma vizinhança muito próxima, não capturando a função verdadeira com precisão. Assim, a aproximação pode ser muito boa em alguns pontos, mas muito ruim em outros lugares. Isso pode ser evitado minimizando o tamanho da amostra de modo a se obter um modelo mais parcimonioso. Dessa forma, as previsões geralmente são melhores para todo o domínio estudado (ROUSSOULY; PETITJEAN; SALAUN, 2013). Portanto é de suma

importância que se estabeleça um tamanho ideal de amostra que alinhe qualidade e acurácia ao modelo substituto.

Os modelos substitutos aqui utilizados serão enriquecidos ao longo do processo de otimização. Em função disso foi necessário definir qual a melhor combinação de tamanhos de amostra inicial e de enriquecimento dos modelos, esse processo será explicado no capítulo 6 de casos estudados e resultados obtidos.


Para os problemas citados, apenas locação e locação e vazão integrados, são utilizados modelos substitutos para uma operação de busca do tipo global. Quando os problemas passam para uma segunda etapa onde somente vazão é otimizada, através da otimização sequencial por aproximação (SAO), modelos substitutos de aproximação local são usados. A diferença em relação a etapa com um algoritmo de busca global é que agora o algoritmo opera sobre um modelo substituto numa pequena região do domínio de projeto, denominada região de confiança, característica do SAO. Mais detalhes sobre esse processo são apresentados no item 4.2 deste trabalho.

3.2.1 Hipercubo latino (LHS)

O hipercubo latino (*Latin Hypercube Sampling* – LHS) é um tipo de amostragem estratificada podendo ser vista como uma extensão da amostragem do quadrado latino (RAJ, 1968). Publicado inicialmente por McKay, Beckman e Conover (1979) como uma alternativa às técnicas de Monte Carlo, o LHS é indicado para que cada uma das variáveis de entrada tenha todas as porções de sua distribuição representadas por valores de entrada, deve-se dividir o intervalo, ou espaço de projeto, em N estratos de probabilidade marginal igual a $1/N$ e criar apenas uma amostra em cada estrato. Este método garante que cada um desses componentes seja representado de uma maneira totalmente estratificada e não requer mais amostras para mais dimensões, sendo esta independência uma das principais vantagens do esquema LHS (DIMITROV; DIMOV; TODOROV, 2017).

A Figura 6 abaixo mostra uma comparação entre exemplos de amostragens num espaço de projeto bidimensional.

Figura 6 – Exemplos de amostragem: (a) randômica, (b) estratificada e (c) LHS



Fonte: Jarosz (2008)

As características de preenchimento de espaço de projeto usando o LHS não têm garantia de serem eficientes o tempo todo, o que é notado na Figura 6(c) onde o arranjo dos pontos pode ser diagonal. Por conta disso, estudos foram realizados com objetivo de desenvolver projetos de LHS ideais que forneçam, de fato, cobertura mais uniformes do espaço de projeto. Uma das principais abordagens foi proposta por Audze e Eglais (1977), onde uma grade foi gerada pela primeira vez, ponto de partida para diversos aprimoramentos da técnica. Posteriormente, os pontos são alocados de forma que não haja dois pontos na mesma linha de grade e a métrica descrita pela Eq.(10) seja minimizada (KEANE; NAIR, 2005). Onde d_{ij} é a distância Euclidiana entre dois pontos i e j , implicando assim numa maior distância entre os pontos amostrais.

$$G = \sum_{i=1}^N \sum_{j=i+1}^N \frac{1}{d_{ij}^2} \quad (10)$$

A função G acima é baseada na analogia física da minimização de forças entre partículas carregadas que é dada pela soma das normas das forças repulsivas, caso as amostras sejam consideradas como partículas eletricamente carregadas (STOCKI, 2005). Desse modo, num comparativo de N amostras, a que possui melhor distribuição no espaço de projeto é a de menor valor de G entre todas.

3.3 CRIAÇÃO DO MODELO SUBSTITUTO GLOBAL

A aproximação de função de aptidão, utilizada no algoritmo genético, com algum modelo de regressão é uma opção comum quando a função objetivo substituta tem que ser usada. Esses modelos substitutos simulam o comportamento da função original, e são mais baratos e mais rápidos de serem construídos. O primeiro passo para uma otimização usando

modelo substituto é a criação de uma amostra a partir de uma técnica de amostragem. Neste trabalho, foi empregado o Hipercubo Latino (*Latin Hypercube Sampling – LHS*) (MCKAY; BECKMAN; CONOVER, 1979). Para a criação dos modelos substitutos foi empregada a técnica de interpolação de dados chamada de funções de base radial (RBF) (HARDY, 1971). Os modelos criados são otimizados utilizando o Algoritmo Genético (AG).

Os principais passos para o processo de criação dos modelos substitutos com amostra viável são indicados abaixo.

Passo 1. Criação da amostra com LHS.

Passo 2. Verificação da viabilidade da amostra para a seleção de 60% viáveis em relação a restrição de distância entre poços.

Passo 2.1 Se o percentual requerido for atingido, o processo segue para o passo 3.

Passo 2.2 Caso contrário, a amostra é tratada aplicando o reparo de cromossomos até que se obtenha o percentual desejado.

Passo 3. Aplicação de reparo de cromossomos no conjunto de viáveis em relação a distância para que esses indivíduos respeitem, simultaneamente, todas as restrições impostas ao problema.

Passo 4. Consolidação do conjunto com 60% de viáveis e 40% de inviáveis.

Passo 5. Criação do modelo substituto usando funções de base radial (RBF).

3.3.1 Funções de base radial (RBF)

A interpolação de função de base radial (RBF) desenvolvida por Hardy (1971), para fins cartográficos, foi concebida para ser uma técnica de interpolação adequada para modelar colinas e vales com uma precisão, local e global, razoavelmente alta.

Posteriormente, Powell (1989) apresentou a interpolação RBF para aproximar uma função F ajustando uma combinação linear ponderada de funções de base radial, onde é introduzido um conjunto de N funções base, uma para cada observação amostral, e que tem a seguinte forma:

$$F(\mathbf{x}) = \hat{f}(\mathbf{x}) = \sum_{i=1}^N w_i \varphi(\|\mathbf{x} - \mathbf{x}_i\|), \quad (11)$$

onde $\{\varphi(\|\mathbf{x} - \mathbf{x}_i\|) \mid i = 1, \dots, N\}$ é um grupo de N funções arbitrárias, normalmente não-lineares, e $\|\cdot\|$ denota, geralmente, a norma Euclidiana. É comum que todos os pontos conhecidos $\mathbf{x}_i \in \mathbb{R}^m, i = 1, \dots, N$ sejam considerados como centros das funções de base radial.

A partir da Eq.(11), é possível obter o seguinte conjunto de equações lineares para os coeficientes desconhecidos da expansão $\{w_i\}$:

$$\begin{bmatrix} \varphi_{11} & \varphi_{12} & \cdots & \varphi_{1N} \\ \varphi_{21} & \varphi_{22} & \cdots & \varphi_{2N} \\ \vdots & \vdots & \vdots & \vdots \\ \varphi_{N1} & \varphi_{N1} & \cdots & \varphi_{NN} \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_N \end{bmatrix} = \begin{bmatrix} F_1 \\ F_2 \\ \vdots \\ F_N \end{bmatrix} \quad (12)$$

onde $\varphi_{ji} = \varphi(\|\mathbf{x}_j - \mathbf{x}_i\|)$, $(j, i) = 1, \dots, N$, $\mathbf{F} = [F_1, F_2, \dots, F_N]^T$ e $\mathbf{w} = [w_1, w_2, \dots, w_N]^T$.

Os vetores $\mathbf{F}$ e $\mathbf{w}$ de tamanhos $N \times 1$ representam o vetor de resposta desejado e o vetor de peso linear, respectivamente, onde N é o tamanho da amostra de treinamento. Define-se Φ para uma matriz $N \times N$ com elementos φ_{ji} :

$$\Phi = \{\varphi_{ji} | (j, i) = 1, \dots, N\}. \quad (13)$$

É a chamada matriz de interpolação. A Eq.(12) pode ser escrita de forma compacta como:

$$\Phi \mathbf{w} = \mathbf{x}. \quad (14)$$

O Teorema de Micchelli (MICCHELLI, 1986) garante que é possível assumir que Φ não é singular e, portanto, que a matriz inversa Φ^{-1} existe. Desse modo, a Eq.(14) pode ser resolvida para o vetor de peso $\mathbf{w}$ como mostrado abaixo na Eq.(15).

$$\mathbf{w} = \Phi^{-1} \mathbf{x}. \quad (3.6)$$

Nesta dissertação foi utilizado o método de Gutmann (2001) onde ele apresentou uma forma mais geral para a RBF. A diferença aqui é a adição de um termo polinomial p de grau máximo g , normalmente linear, e conhecido também como polinômio caudal. Levando isso em consideração, a Eq.(11) pode ser reescrita da forma que é demonstrada a seguir:

$$F(\mathbf{x}) = \hat{f}(\mathbf{x}) = \sum_{i=1}^N w_i \varphi(\|\mathbf{x} - \mathbf{x}_i\|) + p(\mathbf{x}), \quad \mathbf{x} \in \mathbb{R}^m. \quad (16)$$

(GUTMANN, 2001) também apresentou os exemplos mais difundidos de funções de base radial que são resumidos na Eq.(17) abaixo:

$$\begin{aligned} \varphi(r) &= r & (\text{Linear}), \\ \varphi(r) &= r^3 & (\text{Cúbica}), \\ \varphi(r) &= r^2 \log(r) & (\text{Thin plate spline – TPS}), \\ \varphi(r) &= \sqrt{r^2 + \gamma^2} & (\text{Multi-quadrática}), \\ \varphi(r) &= e^{-\gamma r^2} & (\text{Gaussiana}), \end{aligned} \quad (17)$$

onde γ é uma constante positiva prescrita e $r \geq 0$.

A partir das classificações apresentadas para φ , neste trabalho foi empregada a função do tipo cúbica.

3.3.2 Tratamento das amostras

Os problemas de otimização de engenharia raramente são irrestritos, ou seja, a grande maioria dos problemas práticos possuem restrições e estas são funções das variáveis nas quais se busca restringir de alguma forma. É a chamada otimização restrita. Além disso, as restrições que aparecem nesses problemas são normalmente não lineares (NING; HICKEN, 2017). Todos os problemas aqui apresentados são de natureza restrita e não lineares.

Na etapa de criação de amostras utilizando o LHS, primeiro passo para a criação do modelo substituto, é realizada uma verificação de atendimento de restrições para todos os pontos escolhidos. Isso se deve a imposição inicial citada no item 3.2 onde 60% das amostras devem estar dentro do espaço viável. Com essa verificação é possível indicar quantos pontos da amostra criada deverão passar por um processo de tratamento para que se atinja o percentual viável definido. O tratamento adotado aqui neste trabalho é descrito a seguir.

3.3.2.1 Problema de locação

O procedimento de tratamento das amostras para o problema de locação é descrito a seguir.

O primeiro passo é a criação da amostra usando LHS que gera um conjunto (St) formado por uma matriz de tamanho $5n \times n$, onde n é o número de variáveis. Em seguida é realizada a verificação da restrição de distância mínima entre poços ($dist_w$) para cada indivíduo da amostra. Então, o conjunto St é dividido em dois conjuntos: St_{feas} com os indivíduos viáveis e St_{nfeas} com os indivíduos inviáveis. Considerando o conjunto St_{feas} , é calculado o número de indivíduos N_{ind} que precisam ser tratados para que o percentual de 60% de amostras viáveis em relação à restrição de distância seja atingido. Então, N_{ind} indivíduos de St_{nfeas} são escolhidos aleatoriamente e passarão pelo processo de tratamento em relação à restrição $dist_w$. Para isso, cada um dos indivíduos escolhidos é analisado através do cálculo da distância Euclidiana entre poços e são identificados quais poços (poço a e poço b) estão provocando o não atendimento da restrição. A correção ocorre alterando randomicamente as coordenadas dos poços a e b , levando em conta os limites atribuídos ao espaço de projeto. Para o indivíduo que está em análise, é calculada novamente a distância entre todos os poços, já considerando as novas coordenadas definidas aleatoriamente, e é

realizada uma nova verificação de atendimento da restrição $dist_w$. Caso seja indicado que o indivíduo é inviável, modifica-se suas coordenadas de maneira randômica, conforme indicado anteriormente, até que ele se torne viável. O tratamento segue para o próximo indivíduo, repetindo o processo descrito até que todos os N_{ind} indivíduos escolhidos sejam atingidos pelo tratamento. Esses indivíduos tratados são incluídos no conjunto St_{feas} e excluídos do conjunto St_{nfeas} , que agora possuem 60% de indivíduos viáveis e 40% complementares de inviáveis, respectivamente. Até essa etapa do processo, $dist_w$ é a única restrição que determina viabilidade.

O tratamento em relação a restrição de atividade de célula é iniciado com um estudo individual de todos os componentes do conjunto St_{feas} atualizado. Para cada indivíduo é verificada a atividade de célula para todos os blocos que compõem um poço, camada a camada, a partir das suas coordenadas. Nesse estágio há um índice associado que identifica se um bloco está localizado numa zona inativa ($id_{bloco} = 0$) ou ativa ($id_{bloco} = 1$). Assim, se for encontrada algum bloco inativo nessa verificação, são definidas novas coordenadas de forma randômica para o poço que não respeita a restrição. Se o poço possui todos os seus blocos ativos, as coordenadas atribuídas a ele permanecem sem alterações. Esse procedimento é repetido até que o indivíduo do conjunto St_{feas} seja totalmente analisado em relação a atividade de célula. Na sequência, é verificada a viabilidade desse indivíduo para todas as restrições, já considerando as possíveis alterações provocadas pelo tratamento. Caso ele ainda não seja completamente viável, o processo de correção é repetido até que haja o atendimento de todas as restrições impostas. Caso seja viável, o tratamento segue até que todos os outros indivíduos do conjunto sejam corrigidos.

A finalização do tratamento de St_{feas} gera um conjunto de indivíduos tratados St_{trat} que agora atende a todas as restrições exigidas. Os conjuntos St_{nfeas} atualizado e St_{trat} são unificadas formando o conjunto Stf . Por fim, é realizado um teste de repetição em Stf para verificar se há indivíduos iguais no conjunto. Se não houver, é feita a consolidação da amostra seguindo os percentuais estabelecidos 40% para inviáveis e 60% para viáveis. Caso contrário, o processo é reiniciado seguindo o que é indicado a partir do passo 2 da metodologia geral presente no item 3.3.

3.3.2.2 Problema integrado de locação e vazão

A amostra que antes continha apenas dados referentes a locação no problema anterior, agora possui também dados de vazão, o que caracteriza o problema de locação e vazão

integrados. O processo de tratamento adotado aqui é semelhante ao que foi indicado no item 3.3.2.1. A diferença ocorre apenas no início quando a amostra é criada. Novamente, um conjunto (St) formado por uma matriz de tamanho $5n \times n$ é gerado de modo aleatório, obedecendo os limites inferiores e superiores impostos ao problema. Na sequência, St é dividida em dois conjuntos: Stf_{loc} que possui os dados de posicionamento dos poços e Stf_{vaz} com os rateios de vazão. A partir disso, o procedimento de correção é realizado em duas etapas: Stf_{loc} passa por todo o processo descrito no item 3.3.2.1 e Stf_{vaz} é submetida ao tratamento indicado por (OLIVEIRA, 2013), onde é proposta uma metodologia para adequação de população no domínio viável em problemas de simulação de reservatório. Ao final dessas duas etapas, os conjuntos são unificados e geram o conjunto final Stf que segue o percentual requerido de pontos viáveis.

3.4 PRECISÃO DO MODELO SUBSTITUTO

Quando se trabalha com modelos substitutos, é necessário utilizar estratégias que avaliem a acurácia desses modelos. Essa avaliação é feita por meio do cálculo de medidas de erro. Nesta dissertação é considerada a soma dos quadrados dos erros preditos (*Predicted Error Sum of Squares* - PRESS) (AFONSO; HOROWITZ; OLIVEIRA, 2010).

A medida de erro PRESS é apresentada na Eq.(18) e considera uma validação cruzada onde um ponto do modelo é omitido do grupo inicial para criar o modelo aproximado.

$$PRESS = \sum_{i=1}^m (f_i - \hat{f}_{i,-1})^2 \quad (18)$$

Para o cálculo do PRESS foram considerados os valores normalizados da função objetivo deste trabalho em relação ao caso base estudado.

4 ESTRATÉGIAS PARA OTIMIZAÇÃO


Neste capítulo são tratados dos tópicos referentes a estratégias de otimização que se relacionem a este trabalho.

4.1 ALGORITMO GENÉTICO

O algoritmo genético (AG) é um algoritmo de busca estocástica eficiente e uma poderosa técnica de otimização heurística desenvolvida por Holland (1984). Baseado na mecânica da seleção natural e na genética natural, o AG pertence a classe maior de algoritmos evolutivos (EA). Em alguns métodos de otimização, a busca da melhor solução segue uma movimentação ponto a ponto no espaço de trabalho. Essa metodologia pode não ser eficiente em espaços de busca multimodais que possuem muitos picos, podendo assim identificar um pico com um falso ótimo. Em contraste a isso, os algoritmos genéticos trabalham a partir de um rico banco de dados de pontos (uma população), escalando muitos picos no espaço de busca de maneira paralela, reduzindo a probabilidade de encontrar um falso ótimo. Embora aleatórios, os algoritmos genéticos exploram com eficiência as informações históricas para especular sobre novos pontos de pesquisa com excelente desempenho (GOLDBERG, 1988).

O procedimento do AG é inspirado na Teoria da Evolução de Darwin (ROMERO et al., 2000) onde prevalece a lei natural, o que significa que os melhores indivíduos em uma população continuarão a existir, com maiores chances de reprodução, ao passo que os indivíduos mais fracos serão extintos e substituídos por indivíduos melhores. A partir disso, normalmente as gerações futuras são melhores do que as anteriores. Entre as gerações, os cruzamentos entre indivíduos ocorrem e deles surgem os descendentes (novos indivíduos) que são melhores e farão parte da próxima geração. Para produzir uma melhor geração, existe um processo de seleção no qual os indivíduos que se destacam possuem uma tendência de cruzamento com indivíduos que também se destacam. Após a criação de novos indivíduos, os indivíduos menos aptos serão substituídos na próxima geração. Dentre as alterações de geração, provavelmente podem ocorrer mutações, ou seja, alterações na estrutura dos genes por motivos específicos. Essas mutações fazem com que as características dos indivíduos sejam diferentes dos seus estados anteriores (ARIADJI et al., 2014). O cenário descrito constitui o ciclo básico de seleção natural que ocorre também acontece no AG. O procedimento geral básico do algoritmo genético é descrito no fluxograma da Figura 7.

Figura 7 – Procedimento básico do AG.



Fonte: Adaptado de Ariadji et al. (2014).

O fluxograma da Figura 7 apresenta três operadores genéticos: seleção, cruzamento e mutação. Normalmente não é necessário aplicar todos esses operadores no AG, pois cada um deles funciona de maneira independente. A escolha dos operadores e seus parâmetros depende diretamente do problema e da representação do esquema empregado (PHAM; KARABOGA, 2000). Cada operador citado acima é detalhado a partir do item 4.1.2.1.

4.1.1 Representação e estrutura de dados

O AG foi desenvolvido para modelar processos de adaptação operando principalmente em cadeias binárias para representar os cromossomos, podendo também operar através de variáveis numéricas inteiras e/ou reais. O AG mantém uma população de cromossomos $P(t) = x_1^t, \dots, x_n^t$ para a geração t . Cada cromossomo representa uma solução potencial para o problema e cada solução é avaliada obtendo uma medida de sua aptidão. A aptidão de um cromossomo é atribuída proporcionalmente ao valor da função objetivo dos cromossomos. Então, uma nova população (geração $t + 1$) é formada selecionando os cromossomos que mais se adequaram, etapa de seleção. Alguns membros da nova população passam por transformações por meio de operadores genéticos para formar uma nova solução (ROEVA; FIDANOVA; PAPRZYCKI, 2013).

4.1.2 Parâmetros do algoritmo genético

Além do problema de entrada, o AG possui diversos parâmetros numéricos que são utilizados para controlar o comportamento do algoritmo durante o processo evolucionário. Entre eles, os mais populares são o tamanho da população, taxa de cruzamento, taxa de mutação e número de gerações. Este último, em geral, é bastante empregado como critério de

parada para o AG. A seguir, alguns dos parâmetros citados são apresentados de forma detalhada.

4.1.2.1 Opções de população

A definição do tipo de população indicará a forma como os operadores genéticos são empregados. Em alguns casos, os operadores funcionam apenas para variáveis inteiras e em outras, apenas para variáveis reais (OLIVEIRA, 2013). Para os problemas aqui estudados, a população adotada possui dois tipos de codificações dos cromossomos: a forma inteira para o problema de locação, onde as variáveis de projeto são discretas; e, inteira e real para o problema integrado de locação e vazão que envolve variáveis discretas e contínuas.

Diante das restrições impostas aos problemas de otimização aqui estudados e pela necessidade da presença de indivíduos viáveis na população inicial, foram adotadas técnicas de reparação de cromossomos visando criar uma população viável. Tais técnicas de reparo são detalhadas mais adiante.

4.1.2.2 Seleção de indivíduos

O objetivo do operador de seleção é escolher os elementos da população que serão inclusos no processo de reprodução, ou seja, selecionar os pais dos indivíduos que estarão na nova população. Esse processo acontece visando reproduzir cópias de indivíduos com os melhores valores de aptidão. O procedimento de seleção tem uma influência significativa no direcionamento da busca por uma área promissora e na busca de boas soluções em um curto espaço de tempo. No entanto, a diversidade da população deve ser mantida para evitar convergência prematura e para alcançar a solução ótima global (PHAM; KARABOGA, 2000).

Há esquemas de seleção comumente usados em algoritmos genéticos modernos. A reprodução proporcional descreve um grupo de esquemas de seleção que escolhem indivíduos para o nascimento de acordo com seus valores de função objetivo f . Vários métodos de seleção desse grupo foram estudados, incluindo Monte Carlo ou seleção roda de roleta (DE JONG, 1975), seleção por resto estocástico (BRINDLE, 1980) e seleção universal estocástica. Ainda podem ser citadas as seleções baseadas em classificação, por torneio (DEB; GOLDBERG, 1989) e genitor (WHITLEY, 1989).

O AG do módulo de otimização global do MATLAB apresenta algumas dessas opções de seleção, entre elas: por resto estocástico, uniforme, por torneio, roda de roleta e estocástica

uniforme. Esta última é a opção de seleção considerada neste trabalho. Essa função define uma linha em que cada pai corresponde a uma seção dessa mesma linha de comprimento proporcional ao seu valor escalonado. O algoritmo se move ao longo da linha em passos de tamanhos iguais, ou seja, é definido um tamanho de passo padrão. A cada passo dado, o algoritmo aloca um genitor. O primeiro passo é menor do que o tamanho de passo padrão e é definido por um número aleatório com distribuição uniforme (MATHWORKS, INC., 2018).

4.1.2.3 Cruzamento

Essa operação é considerada aquela que diferencia o AG de outros algoritmos. O cruzamento é usado para criar indivíduos (filhos) a partir de dois indivíduos existentes (pais), escolhidos da população atual pela operação de seleção. Existem várias maneiras de fazer isso. Algumas operações de cruzamento comuns são cruzamento de um ponto, cruzamento de dois pontos, cruzamento de ciclo e cruzamento uniforme (PHAM; KARABOGA, 2000). As opções disponíveis pelo AG do MATLAB para cruzamento englobam: cruzamento espalhado, cruzamento de um ponto, cruzamento de dois pontos, cruzamento intermediário, cruzamento por Laplace, cruzamento heurístico e cruzamento por média aritmética ponderada (MATHWORKS, INC., 2018).

Neste trabalho, o cruzamento por Laplace foi a opção adotada, pois ela é indicada quando se trabalha com problemas que possuem restrições envolvendo números inteiros. Essa função de cruzamento é descrita por Deep et al. (2009).

4.1.2.4 Mutação

No procedimento de mutação todos os indivíduos da população são verificados bit a bit e os valores dos bits são invertidos aleatoriamente de acordo com uma taxa especificada, alterando características dos indivíduos sobre o qual a mutação é aplicada. Essas mudanças são importantes, pois elas possibilitam a criação de novos valores atribuídos a características que não existiam anteriormente ou que simplesmente estavam presentes em uma pequena parcela da população em análise. Portanto, o operador de mutação é usado para criar diversidade na população de soluções e forçar o algoritmo a explorar novas áreas no espaço de solução durante o processo de otimização. A definição de uma taxa de mutação adequada é necessária, pois uma taxa muito alta converte o AG em um procedimento de busca aleatório e uma taxa muito baixa pode fazer com que o processo fique preso em ótimos locais (PHAM; KARABOGA, 2000).

Para o processo de mutação, o AG do MATLAB possui diversas opções, entre elas: mutação Gaussiana, mutação uniforme, mutação adaptativa, etc (MATHEWORKS, INC., 2018). Para os problemas estudados nesta dissertação, foi utilizada a mutação Gaussiana que é a opção indicada quando se trabalha com problemas restritos.

4.1.2.5 Escalonamento de aptidão

O controle do número de cópias é importante em algoritmos genéticos, especialmente quando se trabalha com populações pequenas. No início das execuções do AG, é comum ter alguns indivíduos considerados extraordinários (com valores altos de aptidão) em uma população de indivíduos não tão bons. A regra de seleção geral indique que a avaliação de um indivíduo i na população corrente é dada por f_i e a probabilidade p_i do indivíduo i ser selecionado é proporcional a

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad (19)$$

com N representando o número de indivíduos da população. Portanto, os indivíduos classificados como extraordinários, assumiriam uma proporção significativa da população finita em uma única geração. Este é um cenário indesejado e uma das principais causas de uma convergência prematura (GOLDBERG, 1989).

O escalonamento está relacionado a função de seleção, pois ela usa os valores de aptidão para selecionar os pais da próxima geração, atribuindo também uma maior probabilidade de seleção a indivíduos com valores de aptidão mais altos. O escalonamento de aptidão converte as pontuações de aptidão que são retornadas pela função de aptidão com valores em um intervalo que é adequado para a função de seleção. O intervalo de valores afeta diretamente o desempenho do algoritmo genético. Se esses valores variam muito, os indivíduos com os valores mais altos de aptidão se reproduzem de maneira acelerada, assumindo o *pool* de genes da população muito rapidamente e evitando que o algoritmo genético pesquise outras áreas do espaço de solução. Por outro lado, se os valores variam pouco, todos os indivíduos terão aproximadamente a mesma chance de reprodução e a busca irá progredir muito lentamente.

A opção de escalonamento de aptidão adotada neste trabalho é também a opção padrão do AG, disponível no MATLAB, que escalona as pontuações com base na classificação de cada indivíduo em vez de sua pontuação, pois, como visto anteriormente, é uma opção que gera equilíbrio na escolha dos pais, considerando também a aptidão dos indivíduos nesse processo.

A classificação de um indivíduo é sua posição nas pontuações classificadas. Um indivíduo com classificação r obteve uma pontuação proporcional a $1/\sqrt{r}$. Portanto, a pontuação escalonada do indivíduo mais apto é proporcional a 1, a pontuação escalonada do próximo indivíduo mais apto é proporcional a $1/\sqrt{2}$ e assim por diante.

A função de classificação atribui valores para que:

- a) O valor escalonado de um indivíduo com classificação r seja proporcional a $1/\sqrt{r}$, como já mencionado; e
- b) A soma dos valores escalonados de toda a população seja igual ao número de pais necessários para criar a próxima geração.

4.1.3 Manipulação das restrições

Os problemas de otimização restrita são comuns nas ciências, engenharia e economia. Devido à crescente complexidade dos problemas a serem solucionados, as metaheurísticas, inspiradas na natureza em geral, e os algoritmos evolutivos, em particular, estão se tornando cada vez mais populares. Operadores como cruzamento e mutação geralmente não tratam diretamente as restrições. Levando essa limitação em consideração, a maioria das metaheurísticas deve ser combinada com alguma técnica de manipulação de restrições (BARBOSA; LEMONGE; BERNARDINO, 2015). Para o uso do AG, método de busca empregado aqui, essa combinação também é necessária.

Seguindo o que foi indicado por Oliveira (2013), duas técnicas de manipulação foram empregadas aos problemas estudados neste trabalho: reparação de cromossomos e um método de penalização adaptativa. Ambos os métodos foram utilizados em etapas diferentes durante o processo de otimização. O primeiro foi usado na fase inicial de busca, onde é necessário obter indivíduos viáveis. O segundo, no restante do processo.

4.1.3.1 Reparação de cromossomos

Muitos mecanismos de tratamento de restrições possuem como objetivo transformar a função objetivo original, seja eliminando as restrições e, portanto, alterando o vetor de entrada, seja adicionando alguns termos à função que está sendo pesquisada. No entanto, é possível lidar com restrições por meio de mecanismos de reparo que modificam indivíduos de algoritmos evolucionários inviáveis para que se tornem viáveis. Tais mecanismos são amplamente dependentes do problema (SIMON, 2013). Para essas aplicações, que são bastante populares, são feitas até mesmo algumas analogias biológicas. É o caso do reparo de

cromossomos onde o cromossomo que codifica o ponto inviável é reparado. Obviamente, consertar um projeto pode ser uma opção difícil e cara, que envolve a busca por uma solução viável, se não ótima. Agora, o objetivo é a viabilidade da solução em vez de sua qualidade (KEANE; NAIR, 2005). Assim, diante da necessidade da presença de indivíduos viáveis na população inicial do AG, para os problemas estudados neste trabalho foram empregadas duas técnicas para reparação dos cromossomos que são explicadas a seguir.

A primeira técnica foi adaptada a partir do que foi apresentado por Garrido (2019) e foi usada nos estudos onde apenas a locação de poços é otimizada. O processo se inicia com a criação aleatória de indivíduos. Para cada geração, o número de indivíduos deve ser maior do que o tamanho da população (ps) do AG. Na sequência, tais indivíduos são analisados verificando se há violações em relação às restrições impostas ao problema. Os que não atendem as restrições são removidos da amostra, restando apenas os indivíduos viáveis (pop_{feas}). Se o tamanho de pop_{feas} for menor do que ps , uma nova amostra é gerada e sua viabilidade é analisada. Esse processo é repetido até que o tamanho de pop_{feas} seja maior ou igual a ps . A partir disso, ps indivíduos são escolhidos de maneira aleatória entre pop_{feas} para criar a população inicial (pop_i) de tamanho determinado para o AG. Para a primeira população inicial gerada, esse processo descrito acima se aplica e pop_i é composta integralmente pelos indivíduos selecionados a partir de pop_{feas} . Para as próximas gerações, uma amostra inicial para a população inicial é gerada seguindo o que foi indicado inicialmente. Após isso, os cinco últimos indivíduos de pop_i são removidos da amostra para que os pontos utilizados no enriquecimento do modelo substituto, processo explicado mais adiante, sejam inseridos na população inicial, formando a pop_i de tamanho ps em cada nova geração.

Para a análise do problema integrado foi utilizada uma combinação de técnicas que aqui foram aplicadas separadamente, pois cada indivíduo da pop_i deste problema é composto por dois tipos de variáveis: as de locação e as de vazão. Portanto, o processo de criação da população inicial é dividido em duas etapas. Na primeira é gerada um conjunto viável com os dados de posicionamento de poços de tamanho $5n \times ndv_{loc}$ ($feaspop_{loc}$), onde ndv_{loc} é o número de variáveis do problema de locação, a partir da adaptação baseada em Garrido (2019) e conforme detalhado anteriormente. Na última, para a criação de indivíduos viáveis referentes ao gerenciamento de vazões, a metodologia de reparo apresentada e descrita por Oliveira (2013) é utilizada, gerando um conjunto de tamanho $5n \times ndv_{vaz}$ ($feaspop_{vaz}$), ndv_{vaz} é o número de variáveis do problema de vazão.

Após a geração de $feaspop_{loc}$ e $feaspop_{vaz}$, os dois conjuntos são unificados, formando a pop_i com indivíduos viáveis e de tamanho $5n \times ndv_{int}$, ndv_{int} é o número de variáveis do problema integrado.

4.1.3.2 Penalização adaptativa

Existe uma grande classe de métodos indiretos em que um problema original restrito é transformado em um problema irrestrito equivalente que é então solucionado usando métodos para esses tipos de problemas específicos. Os métodos de penalidade pertencem a esta classe de métodos indiretos. A ideia básica de um método de penalidade é definir um problema irrestrito adicionando restrições, multiplicadas por um termo de penalidade, à função objetivo. Os termos são definidos de tal forma que, se as restrições forem satisfeitas, não haverá penalidade, mas se uma ou mais restrições forem violadas, um termo de penalidade é aplicado e forçará indiretamente as restrições a serem satisfeitas (BHATTI, 2000).

Barbosa e Lemonge (2002) indicaram que é possível e útil definir a quantidade de violação da j -ésima restrição pela solução $x \in \mathbb{R}^m$ como

$$v_j(x) = \begin{cases} |h_j(x)| & \text{restrições de igualdade} \\ \max\{0, g_j(x)\} & \text{demais restrições} \end{cases} \quad (20)$$

Embora conceitualmente simples, as técnicas de penalidade geralmente requerem parâmetros dependentes do problema definidos pelo usuário, que costumam impactar significativamente o desempenho de uma metaheurística, como é o caso do AG. Lemonge e Barbosa (2004) propuseram um método sem qualquer tipo de parâmetro de penalidade que seja definido pelo usuário. É um esquema adaptativo que define automaticamente os valores dos parâmetros envolvidos usando informações do processo de busca e utiliza apenas informações da população, como a média da função objetivo e o nível de violação de cada restrição durante a evolução.

A função aptidão proposta é dada por:

$$F(x) = \begin{cases} f(x) & \text{se } x \text{ é viável} \\ \bar{f}(x) + \sum_{j=1}^m k_j v_j(x) & \text{caso contrário} \end{cases} \quad (21)$$


onde

$$\bar{f}(x) = \begin{cases} f(x) & \text{se } f(x) > \langle f(x) \rangle \\ \langle f(x) \rangle & \text{caso contrário} \end{cases} \quad (22)$$

e $\langle f(x) \rangle$ é a média dos valores da função objetivo na população atual.

O comportamento da função aptidão pode ser visto na Figura 8, onde soluções viáveis e inviáveis são apresentadas.

Figura 8 – Aplicação do método da penalidade adaptativa com a função $\bar{f}(x)$.



Fonte: Silva (2019)

Entre as seis soluções inviáveis, os indivíduos 3, 4, 5 e 6 possuem seus valores de função objetivo menores do que a média das funções. Portanto, de acordo com o método proposto e conforme indicado na Eq.(22), $\bar{f}(x)$ assume o valor de $\langle f(x) \rangle$. Já as soluções 1 e 2 que possuem valores de função maiores que a média da população, $\bar{f}(x)$ é dada por $f(x)$.

O parâmetro de penalização das restrições é dado, em cada geração, pela Eq.(23) descrita abaixo:

$$k_j = |\langle f(x) \rangle| \frac{\langle v_j(x) \rangle}{\sum_{l=1}^m [\langle v_l(x) \rangle]^2} \quad (23)$$

$\langle v_l(x) \rangle$ é a violação da l -ésima restrição calculada pela média da população atual. Usando ps como o tamanho da população, a equação acima também pode ser escrita como demonstrado na Eq.(24).

$$k_j = \frac{|\sum_{i=1}^{ps} f(x^i)|}{\sum_{l=1}^m [\sum_{i=1}^{ps} v_l(x^i)]^2} \sum_{i=1}^{ps} v_j(x^i) \quad (24)$$

A ideia aqui é que os valores dos coeficientes de penalidade sejam distribuídos de maneira que aquelas restrições mais difíceis de serem satisfeitas tenham um coeficiente de penalidade relativamente maior. A metodologia de penalização descrita neste tópico foi adotada no presente trabalho.

4.1.4 Critérios de parada

O algoritmo genético considerado neste trabalho integra o *Toolbox* de otimização do MATLAB (MATHWORKS, INC., 2018). Alguns critérios próprios desta versão podem ser utilizados como opções de parada para o algoritmo, entre eles podem ser citados: o número máximo de iterações (gerações), o tempo máximo em segundos para o AG ser executado, limite de valor para a função de aptidão e observação da mudança relativa média do melhor valor da função de aptidão.

Dois dos critérios citados acima foram adotados aqui para a busca global com o AG. O primeiro envolve o número máximo de gerações onde é fixado um limite máximo de gerações no processo de busca da solução ótima. Para este critério, foi mantida a configuração padrão do AG do MATLAB que considera $gen_{max} = 100n$ com n igual ao número de variáveis, portanto o limite de iterações para este critério depende diretamente da dimensão do problema. O segundo critério é o monitoramento das mudanças associadas a melhora no valor da função de aptidão que avalia a qualidade dos indivíduos numa população qualquer. Este último critério estabelece um número de gerações consecutivas onde as alterações da melhor aptidão não ultrapassam o valor de tolerância definido. Nos estudos realizados nesta dissertação, foi determinado o valor de $1e^{-6}$ para a tolerância. O número de gerações sequenciais sem mudanças significativas foi limitado a 100 gerações.

4.1.5 Modelo substituto adaptativo

Um dos principais fatores em qualquer processo de otimização é o custo de avaliar a função objetivo e quaisquer restrições. Isso não é problema para trabalhos mais simples como quando se lida com expressões matemáticas sem maiores complexidades. No entanto, em problemas complexos, como é o caso de otimização de problemas de Engenharia de Reservatório, os custos para essas avaliações de função podem ser altos visto que podem levar horas ou mesmo dias. Isso pode impor uma restrição computacional severa para a resolução de um problema de otimização se o modelo subjacente exigir uma grande quantidade de tempo de CPU para ser executado (WANG et al., 2014). Portanto, idealmente, é necessário buscar alternativas que possibilitem a minimização do número de chamadas de função, tais opções de mitigação devem funcionar independentemente das dimensões do problema (KEANE; NAIR, 2005). Uma das maneiras já descritas aqui neste trabalho é por meio do conceito de superfície de resposta, modelos substitutos ou metamodelos. A partir deles, é possível reduzir o número de avaliações de função que são usadas para montar um banco de


dados ou um processo de ajuste de curva que serão os substitutos de uma função real para um processo de otimização, reduzindo então a carga computacional através da aproximação e substituição de um modelo de simulação caro por um modelo substituto de execução mais barata (WANG et al., 2014).

Uma forma de construir economicamente um modelo substituto para otimização é usar um processo adaptativo. Isso significa que um determinado número de pontos é criado no estágio inicial e, em seguida, pontos adicionais são gerados de maneira adaptativa, aumentando assim a precisão do modelo substituto. Para o propósito de encontrar um ponto de ótimo, não é necessário mapear toda a superfície em uma exploração de modelo substituto. Assim, uma estratégia de amostragem adaptativa pode mover rapidamente a busca para uma região que contém o ótimo das variáveis de entrada. Dentro desta região, uma exploração completa do modelo substituto é garantida para encontrar o ótimo (WU; HAMADA, 2009).

No presente trabalho foi aplicada uma abordagem para o processo adaptativo baseada em Redouane, Zeraibi e Nait Amar (2019) na qual é demonstrada uma nova maneira de adaptar o modelo substituto para otimização usando um orçamento restrito de simulações de reservatório (*i*). Esta técnica faz uso de uma proposta já existente que tem como objetivo encontrar regiões mais promissoras no entorno de um ponto. Para isso, foi utilizado um método adaptativo de amostragem: Minimizando uma Superfície de Interpolação (*Minimizing an Interpolating Surface – MIS*) (JONES, 2001). Essa escolha se justifica devido a funcionalidade do MIS que atua, neste caso, na região que contém o ótimo e não está concentrado em uma superfície de resposta completa. Com base nisso, foi desenvolvido um procedimento que cria perturbações na melhor solução encontrada pelo otimizador, tal interferência cria novos pontos em torno desse ótimo. Nesse procedimento, o modelo substituto é primeiro ajustado para pontos de amostra do banco de dados inicial. Em seguida, o ótimo desse substituto é encontrado e tratado como um novo ponto de amostra a ser adicionado ao conjunto de dados existente, juntamente com os novos pontos criados a partir das perturbações, após suas avaliações pelo modelo de simulação. Estes novos pontos de dados são usados para atualizar recursivamente o modelo substituto. Se o novo conjunto de amostras atender ao critério de convergência ou se o limite de simulações é atingido, a pesquisa é interrompida. Caso contrário, um novo laço é iniciado (BABAEI; PAN, 2016).

A estrutura adaptativa proposta e utilizada em todos os estudos aqui realizados usa o AG como otimizador e é ilustrada pelo fluxograma na Figura 9.

Figura 9 – Esquema usado para a adaptação do modelo substituto.



Fonte: Adaptado de Andrade et al. (2021a)

4.1.5.1 Adaptação do MS para o problema de locação

Os principais passos do procedimento, descrito no fluxograma acima e adotado para o problema de locação, são:

Passo 1. Otimizar o modelo substituto usando o AG e encontrar o melhor indivíduo ($xstr_{ga}$);

Passo 2. Avaliar $xstr_{ga}$ no simulador (MAX_{surg}) e verificar a convergência. Se houver convergência, $BEST_{max}$ e $BEST_{pnt}$ são atualizados;

Passo 3. Definir o domínio dinâmico (D) onde novos pontos baseados no melhor ponto são criados. Aqui, quatro diferentes pontos (n_p) são gerados no entorno de $xstr_{ga}$ através de perturbações randômicas em cinco poços aleatórios (n_{dw}) que alteram as suas coordenadas originais. Essa quantidade, nesse caso, representa cerca de 40% do número total de poços. Cada novo ponto é criado a partir do cálculo da distância Euclidiana entre o poço a ser perturbado e o centro do reservatório. Devido ao formato quadrado do reservatório estudado, levando em consideração a área que envolve as células ativas e inativas, foi definida uma região circular de influência com diâmetro d igual a metade do tamanho do reservatório. Essa definição foi adotada visando padronizar a configuração do movimento das coordenadas dos poços. Essa movimentação acontece de maneira suave, um ou dois blocos em relação ao

ponto original, e é definida aleatoriamente entre os dois tamanhos de movimento citados. Desse modo, se a distância Euclidiana calculada é maior do que o raio definido ($d/2$), o movimento da coordenada é feito em direção ao centro. Caso contrário, a movimentação acontece em direção as bordas. Ou seja, todo movimento advindo dessas perturbações intencionais depende de onde os poços foram inicialmente locados;

Passo 4. Computar os valores da função objetivo desse novo grupo de indivíduos, gerando o grupo L_2 ;

Passo 5. Enriquecer o modelo substituto adicionando os pontos: a melhor solução encontrada pelo algoritmo genético e os novos pontos criados no entorno dele. Em seguida, também adicionar esses mesmos pontos a população inicial para a próxima busca, conforme indicado no item 4.1.3.1;

Passo 6. Aplicar o laço (L_2) i vezes até que seja atingido o número máximo de iterações (i_{max}) ou obter a convergência determinada com $i = 1$ no início e $i = i + 1$ toda vez que passar pelo loop;

Passo 7. Continuar o processo do passo 6 até que um dos critérios de parada seja alcançado. Os critérios de parada são o número máximo de iterações ($i_{max} = 48$), representando o número total de avaliações de função máximas que é igual a 240 para um enriquecimento de modelo com tamanho $10n$ (onde n é o número de variáveis do problema), e a convergência indicada pela Eq.(25):

$$convergencia = \frac{MAX_{surg} - fit(GA)}{MAX_{surg}} < 1e^{-6} \quad (25)$$

Caso não haja convergência e a parada do processo aconteça pelo número máximo de iterações, uma análise é realizada para a obtenção da melhor solução. Para isso, MAX_{data} e $BEST_{data}$ são extraídos do modelo e representam, nessa ordem, o melhor valor da função objetivo e as suas respectivas variáveis contidas no modelo substituto enriquecido. Em seguida é realizada uma verificação de viabilidade em relação ao atendimento das restrições impostas ao problema.

Caso o ponto extraído seja viável, o processo segue para a última verificação: saber se o último resultado encontrado pelo otimizador (MAX_{surg}) é melhor do que esse ponto, ou seja, $MAX_{surg} > MAX_{data}$. Caso o ponto não seja viável, ele é “removido” do modelo para que sejam realizadas uma nova extração e uma nova verificação de viabilidade. Esse processo é repetido até que o ponto seja viável. Seguindo, enfim, o caminho que é indicado no

fluxograma da Figura 9. Assim, ao final do procedimento descrito, o melhor indivíduo encontrado é a solução otimizada.

4.1.5.2 Adaptação do MS para o problema integrado de locação e vazão

O processo de adaptação para o problema integrado também segue o que é indicado no fluxograma da Figura 9 e descrito no item 4.1.5.1. No entanto, por se tratar de um problema diferente, alguns passos sofreram adaptações e são descritos a seguir.

O passo 3 agora também contempla as variáveis relacionadas a vazão. Portanto, o domínio dinâmico (D) que antes, no problema de locação, era definido por novos pontos baseados em perturbações das coordenadas dos poços, agora inclui perturbações nas vazões. Novamente, quatro diferentes pontos (n_p) são gerados no entorno de $xstr_{ga}$. O processo para as coordenadas segue o que foi indicado anteriormente. A definição das vazões a serem alteradas é feita baseada nos mesmos poços previamente escolhidos, ou seja, todos os poços que tiverem suas coordenadas alteradas, também terão suas vazões modificadas para cada ciclo de controle definido. Na sequência, a perturbação atua através de acréscimos definidos aleatoriamente para cada um dos valores de rateio de vazão originais. Tais acréscimos variam entre dois limites pré-definidos: limite inferior (lim_{inf}) igual a $-0,05$ e limite superior (lim_{sup}) igual a $+0,05$, assim como demonstrado em Eq.(26):

$$\begin{aligned} x_{pert_{t,w}} &= \frac{q_{t,w}}{Q_{l,max}} \pm 0,05, & w \in P \\ x_{pert_{t,w}} &= \frac{q_{t,w}}{Q_{inj,max}} \pm 0,05, & w \in I \end{aligned} \quad (26)$$

As equações acima representam uma variação de $\pm 20m^3/dia$ e $\pm 22m^3/dia$ para as vazões dos poços produtores e injetores, respectivamente, no caso estudado que será detalhado no próximo capítulo. Os valores de limite foram escolhidos com o intuito de gerar variações pequenas que afetem minimamente as vazões originais, objetivo das perturbações, podendo ou não continuar respeitando as restrições impostas.

No passo 7 é indicada a continuidade do passo 6 até que um dos critérios de parada seja alcançado. Para o problema integrado, os critérios de parada são o número máximo de iterações ($i_{max} = 60$), representando o número máximo total de avaliações de função que é igual a 300 para um enriquecimento de modelo com tamanho $5n$, e a convergência que é a mesma indicada pela Eq.(25).

Com exceção das etapas indicadas acima, todas as outras restantes são iguais dentro do processo adaptativo do modelo substituto para o problema de locação e vazão integrados.

4.2 OTIMIZAÇÃO POR APROXIMAÇÃO SEQUENCIAL

Para uma busca local, nem sempre é necessário saber como uma função se comporta em todo o espaço de projeto. Portanto, um modelo substituto que seja construído apenas numa pequena área de interesse é suficiente para uma avaliação local. As aproximações do tipo local são válidas apenas na vizinhança de onde a função é avaliada, pois sua precisão é limitada a essa região de influência que possui uma distância pequena a partir do ponto em que ela foi construída (OLIVEIRA, 2013).

A principal característica da otimização sequencial por aproximação (*Sequential Approximate Optimization* – SAO) é a decomposição do problema inicial de otimização em uma sequência de subproblemas menores ficam confinados em pequenas sub-regiões, também chamadas de regiões de confiança (RC), do domínio de projeto inicial (Δ^k). O algoritmo de otimização opera sobre um modelo substituto, de baixo custo computacional, utilizando funções aproximadas ao invés de utilizar as respostas obtidas de uma simulação real que são computacionalmente mais caras (PINTO, 2014).

A cada nova iteração, é realizada uma análise de consistência entre os modelos real e aproximado, procedimento que auxilia na precisão dos modelos criados. As avaliações das funções reais ainda são necessárias para essa análise e são utilizadas durante o processo para construção do modelo substituto, no entanto em uma quantidade menor.

4.2.1 Formulação matemática

O esquema de região de confiança (RC) atualiza as variáveis de projeto a cada iteração do SAO que está relacionada a cada subproblema. Portanto, matematicamente, cada subproblema na k -ésima iteração do SAO é definido pela Eq.(27):

$$\begin{aligned} &\text{Minimize } \hat{f}^k(\mathbf{x}) \\ &\text{Sujeito a: } \hat{g}_i^k(\mathbf{x}) \leq 0, \quad i = 1, \dots, m \end{aligned} \quad (27)$$

$$x_{lb} \leq x_{lb}^k \leq \mathbf{x} \leq x_{ub}^k \leq x_{ub}, \quad k = 1, \dots, k_{max}$$

onde

$$x_{lb}^k = x_c^k - \frac{\Delta^k}{2} \quad \text{e} \quad x_{ub}^k = x_c^k + \frac{\Delta^k}{2} \quad (28)$$

Nas equações acima, $\hat{f}^k(\mathbf{x})$ e $\hat{g}^k(\mathbf{x})$ representam as aproximações das funções objetivo e de restrições, respectivamente. O ponto central da região de confiança é dado por x_c^k , o tamanho de RC é representado por Δ^k , e x_{lb}^k e x_{ub}^k são, nesta ordem, os limites inferiores e superiores das variáveis de projeto na iteração k do SAO (GIUNTA; ELDRED, 2000).

4.2.2 Atualização da região de confiança

Após cada iteração k da estratégia SAO, o tamanho da região de confiança, Δ^k , é atualizado com base na medição da acurácia das funções aproximadas no k -ésimo ponto ótimo, $\mathbf{x}_*^k$. Tal precisão é designada por ρ^k e é medida a partir da Eq.(29) abaixo:

$$\rho^k = \frac{f(\mathbf{x}_c^k) - f(\mathbf{x}_*^k)}{\hat{f}(\mathbf{x}_c^k) - \hat{f}(\mathbf{x}_*^k)}, \quad (29)$$

que é a proporção da melhoria real para a melhoria prevista pela otimização no modelo substituto. No contexto de multifidelidade, esse índice mede o desempenho do modelo de baixa fidelidade corrigido ao encontrar novas iterações que melhoram a função objetivo de alta fidelidade (ELDRED; GIUNTA; COLLIS, 2004).

O valor para ρ define a aceitação da etapa e o próximo tamanho da região de confiança (Δ^{k+1}) que é atualizada como detalhado a seguir.

1. $\rho^k \leq 0$: Os modelos substitutos são imprecisos. Rejeite a etapa e diminua a região de confiança pela metade para melhorar a precisão. Desse modo, $\Delta^{k+1} = 0,5\Delta^k$.
2. $0 < \rho^k \leq 0,25$: Os modelos são ligeiramente precisos. Aceite a etapa, mas, assim como na condição anterior, reduza o tamanho de RC pela metade. Portanto, $\Delta^{k+1} = 0,5\Delta^k$.
3. $0,25 < \rho^k < 0,75$ ou $\rho^k > 1,25$: Os modelos são moderadamente precisos. Aceite a etapa e mantenha o tamanho de RC atual. Assim, $\Delta^{k+1} = \Delta^k$.
4. $0,75 \leq \rho^k \leq 1,25$: Os modelos são precisos. Aceite a etapa e dobre o tamanho da RC. Com isso, $\Delta^{k+1} = 2\Delta^k$.

Na condição 4, uma pequena alteração foi feita no fator utilizado de modo a não aumentar tanto a região de confiança após a atualização. Portanto, ao invés de dobrar o tamanho de RC, optou-se por limitar esse aumento em 50%. Levando isso em consideração, para este trabalho, foi adotado $\Delta^{k+1} = 1,5\Delta^k$.

O procedimento de atualização da região de confiança, descrito nos itens acima e utilizado aqui, pode ser resumido como:


O centro da região de confiança para a próxima iteração $\mathbf{x}_c^{k+1}$ é obtido seguindo a Eq.(30).

$$\mathbf{x}_c^{k+1} = \begin{cases} \mathbf{x}_*^k & \text{se } \rho^k > 0 \\ \mathbf{x}_c^k & \text{se } \rho^k \leq 0 \end{cases} \quad (30)$$

A Figura 10 demonstra como funciona a estratégia SAO. Cada um dos retângulos da imagem representam as regiões de confiança que são atualizadas a cada iteração do SAO. As

marcações em cruz são os pontos amostrais gerados, o círculo branco faz referência ao ponto central da RC e a estrela é o ponto ótimo.

Figura 10 – Evolução das regiões de confiança a cada iteração da estratégia.



Fonte: Giunta (2002)

4.2.3 Algoritmo

O problema de vazão formulado neste trabalho foi solucionado seguindo os passos do algoritmo SAO baseado em Giunta e Eldred (2000) e descrito abaixo.

1. Assumir o tamanho e o ponto central inicial da região de confiança (RC);
2. Computar as funções objetivo e de restrições do ponto central definido na etapa 1;
3. Gerar amostras no interior de RC. O tamanho de amostra é fixado em $m = 2n + 1$ com n igual ao número de variáveis do problema;
4. Calcular as funções objetivo e de restrições nos locais de amostras definidos para a construção do modelo substituto;
5. Construir o modelo substituto para as funções objetivo e restrições não lineares;
6. Otimizar dentro da região de confiança utilizando o modelo construído no passo anterior, substituindo a função objetivo real e restrições. Nesse passo, as variáveis de projeto são limitadas pelas fronteiras da RC;
7. Calcular a função objetivo real e as restrições no ponto ótimo encontrado na etapa 5;
8. Verificar a convergência. Se alcançada, o procedimento é finalizado e o ótimo é obtido. Caso contrário, o processo segue para a etapa 9;
9. Mover/reduzir/expandir a nova sub-região de acordo com a precisão do modelo substituto comparado com a função real e os valores das restrições;
10. Repetir o processo a partir do passo 2.

4.2.4 Critérios de convergência

Três critérios de parada foram considerados para a estratégia de otimização por aproximação sequencial. O primeiro é definido a partir da convergência global que determina o final do processo de otimização. O segundo é baseado na convergência local durante o processo de otimização dos subproblemas confinados nas sub-regiões do espaço de projeto. E o último está relacionado ao número máximo de iterações do processo. Todos eles estão detalhados abaixo:

1. Em relação a convergência global, o processo para se o valor do ótimo baseado no modelo substituto não apresenta mudanças significativas nas últimas três iterações ($k = 3$), ou seja, o valor absoluto da diferença entre ótimo e a média das três últimas iterações é menor do que uma tolerância determinada. O valor de $1,5e^{-5}$ para todos os casos desse estudo. A Eq.(31) demonstra, matematicamente, essa condição.

$$tol = \left| \hat{f}^k(\mathbf{x}) - \frac{\sum_{i=k-2}^k \hat{f}^i(\mathbf{x})}{k - i + 1} \right| \leq 1.5e^{-5} \quad (31)$$

2. A convergência local está relacionada ao tamanho mínimo das regiões de confiança (HOROWITZ; AFONSO; DE MENDONÇA, 2013). A tolerância adotada para Δ^k é igual a $1e^{-3}$.

3. O processo de otimização para se o número máximo de iterações é alcançado. O máximo adotado foi de 20 iterações.


5 CASOS ESTUDADOS E RESULTADOS OBTIDOS

Como o objetivo de validar as ferramentas desenvolvidas para os problemas de gerenciamento ótimo de reservatórios de petróleo, três casos foram estudados baseados nas formulações apresentadas no Capítulo 2 e nas metodologias apresentadas nos capítulos seguintes. Com abordagens sequenciais e simultâneas, esses casos envolvem os problemas de locação e gerenciamento de vazões dos poços com a aplicação de estratégias distintas de otimização. Algoritmos genéticos associados a modelos substitutos adaptativos e a estratégia SAO foram aqui utilizados. Todos os estudos dessa dissertação foram realizados em um reservatório sintético bifásico que é apresentado na sequência.

5.1 RESERVATÓRIO EGG MODEL

O reservatório estudado nesta dissertação, *Egg Model*, foi desenvolvido como parte da tese de doutorado de Maarten Zandvliet e Gijs van Essen (JANSEN et al., 2014). A primeira publicação sobre ele foi feita por Zandvliet et al. (2007) e envolvia uma única realização determinística do modelo. Posteriormente, Van Essen, Zandvliet e Jansen (2009) estudaram uma versão com várias realizações para o *Egg Model*. O modelo original “estocástico” é altamente heterogêneo e consiste em um conjunto de 100 realizações de um reservatório canalizado na forma de campos discretos de permeabilidade modelados numa grade de $60 \times 60 \times 7 = 25.200$ células, das quais 18.553 células são ativas. As células inativas estão todas do lado de fora do modelo, conferindo um formato de ovo de células ativas e, portanto, justificando a sua nomenclatura (JANSEN et al., 2014).

Figura 11 – Disposição inicial dos poços e campo de permeabilidade do reservatório *Egg Model*.



Fonte: A autora (2022)

No presente trabalho foi analisado o modelo determinístico do reservatório. O campo de permeabilidade adotado aqui, bem como a disposição inicial dos poços podem ser observados na Figura 11. Este é o caso base utilizado para os estudos deste trabalho.

O *Egg model* é um reservatório sintético bifásico (óleo e água) tridimensional, com canais de alta permeabilidade em campos pouco permeáveis que representam padrões típicos de rios sinuosos como encontrados em ambientes fluviais. Todas as 18.553 células ativas possuem dimensão $8\text{ m} \times 8\text{ m} \times 4\text{ m}$ e há sete camadas verticais. Essas camadas possuem uma correlação vertical forte, de modo que os campos de permeabilidade são quase bidimensionais. O modelo não tem aquífero e nem capa de gás, portanto a produção primária é quase desprezível e o mecanismo de produção é a inundação de água com o auxílio de oito poços de injeção e quatro poços de produção. O período de concessão do reservatório é de 3600 dias (JANSEN et al., 2014). Os parâmetros do modelo adotado nesta dissertação são apresentados na Tabela 1.

Tabela 1 – Propriedades petrofísicas do reservatório *Egg Model*.

Malha de simulação	$60 \times 60 \times 7$
Blocos ativos	18.553
Altura de bloco (h)	4 m
Largura e comprimento de bloco ($\Delta x, \Delta y$)	8 m
Porosidade (ϕ)	20%
Compressibilidade do óleo (c_o)	$1.0 \times 10^{-10} Pa^{-1}$
Compressibilidade da rocha (c_r)	$0 Pa^{-1}$
Compressibilidade da água (c_w)	$1.0 \times 10^{-10} Pa^{-1}$
Pressão inicial de reservatório (camada de topo) (p_R)	$40 \times 10^6 Pa$
Viscosidade dinâmica do óleo (μ_o)	$5.0 \times 10^{-3} Pa\ s$
Viscosidade dinâmica da água (μ_w)	$1.0 \times 10^{-3} Pa\ s$
Tempo de concessão (T)	3600 dias

Fonte: Adaptado de Jansen et al. (2014)

Além disso, todos os poços possuem restrições. Os injetores estão sujeitos a uma restrição individual para injeção de água de $79.5\text{ m}^3/\text{dia}$, já os produtores possuem restrição de líquidos de $120\text{ m}^3/\text{dia}$. Adicionalmente, as plataformas que comportam os poços também estão sujeitas a restrições de $400\text{ m}^3/\text{dia}$ para a produção máxima do conjunto e de $440\text{ m}^3/\text{dia}$ para injeção. As condições de operação dos poços aplicadas neste trabalho estão resumidas na Tabela 2.

Tabela 2 – Condições operacionais dos poços do reservatório *Egg Model*.

	Tipo	Produtor	Injetor
	BHP (kPa)	39.500 (<i>mín</i>)	42.000 (<i>máx</i>)
	Raio (m)	0.1	0.1
	Geofac	0.37	0.37
	Wfrac	1	1
	Skin	0	0
	Vazão máxima de líquidos por poço (m^3/dia)	120	79.5
	Vazão máxima de líquidos por plataforma (m^3/dia)	400	440

Fonte: A autora (2022)

A função objetivo para todos os problemas que envolvem o reservatório *Egg Model* é o valor presente líquido (VPL) do projeto. Os parâmetros econômicos usados para o cálculo do VPL, para os casos base e otimizados, foram baseados em Siraj, Van Den Hof e Jansen (2015) e estão indicados na Tabela 3.

Tabela 3 – Parâmetros econômicos do reservatório *Egg Model*.

Parâmetro	Valor
Preço do óleo ($\$/m^3$)	126
Custo de produção de água ($\$/m^3$)	19
Custo de injeção de água ($\$/m^3$)	6
Taxa de desconto ($\%/ano$)	0

Fonte: A autora (2022)

Os valores apresentados acima são difundidos na literatura para o Reservatório *Egg Model*. Portanto, servem como referência para análises comparativas entre estudos que envolvem o reservatório citado.

5.2 PARÂMETROS DO AG

Um dos otimizadores utilizados no desenvolvimento desta dissertação é o Algoritmo Genético (AG) e é disponibilizado através da *Toolbox* de otimização do MATLAB (MATHWORKS, INC., 2018). Para um melhor desempenho durante o processo de otimização foi necessário definir alguns parâmetros para o otimizador que estão listados a seguir.

1. Tipo de população: variáveis inteiras (problema 1), variáveis inteiras e reais (problemas 2 e 3);

2. População inicial (ps): criada considerando a técnica de amostragem LHS (MCKAY; BECKMAN; CONOVER, 1979) com 150 indivíduos;
3. Escalonamento dos indivíduos: de acordo com a classificação;
4. Seleção: seleção estocástica uniforme;
5. Taxa de elitismo: 5%;
6. Taxa de cruzamento: 20%;
7. Tipo de cruzamento: cruzamento por Laplace;
8. Tipo de mutação: mutação Gaussiana;
9. Número máximo de gerações: $100 * n$, com n igual a dimensão do problema;
10. Número máximo de gerações para verificação na alteração do valor da melhor aptidão: 100.

Foi necessário definir também os parâmetros utilizados para a construção dos modelos substitutos e no processo adaptativo dos modelos. Conforme indicado anteriormente, foi adotado o percentual de 60% de pontos viáveis para a criação dos modelos substitutos.

Os dados utilizados para problema 1 estão especificados na Tabela 4.

Tabela 4 – Parâmetros adotados para o modelo substituto (problema 1).

	Parâmetro	Valor
	Número de variáveis (n)	24
	Tamanho do modelo substituto inicial (t_{DoE})	$5 * n$
	Número de pontos viáveis	$0.60 * t_{DoE}$
	Número de pontos inviáveis	$0.40 * t_{DoE}$
	Número de pontos adicionados ao modelo por iteração	5
	Tamanho do enriquecimento do modelo ($máx$)	$10 * n$

Fonte: A autora (2022)

A Tabela 5 mostra os dados utilizados para os problemas 2 e 3. Nela, nota-se que as principais diferenças para o problema 1 (Tabela 4) são o número de variáveis dos problemas e o tamanho máximo do enriquecimento do modelo substituto.

Tabela 5 – Parâmetros adotados para o modelo substituto (problemas 2 e 3).

Parâmetro	Valor
Número de variáveis (n)	60
Tamanho do modelo substituto inicial (t_{DoE})	$5 * n$
Número de pontos viáveis	$0.60 * t_{DoE}$
Número de pontos inviáveis	$0.40 * t_{DoE}$
Número de pontos adicionados ao modelo por iteração	5
Tamanho do enriquecimento do modelo ($máx$)	$5 * n$

Fonte: A autora (2022)

No item 3.2 desta dissertação que trata do plano de amostragem, foi visto que quando se trabalha com funções de base radial, um modelo substituto com muitos pontos amostrais nem sempre reflete em um modelo de maior qualidade, pois está sujeito ao problema de sobreajuste, ou *overfitting* (AMOUZGAR; STRÖMBERG, 2016). Podendo resultar apenas em um modelo mais caro e, não necessariamente, mais eficiente. Garrido (2019) realizou um experimento de incremento de amostras com dois modelos substitutos: um de tamanho $10n$ e outro de tamanho $5n$. A partir desse experimento, ele concluiu que o modelo construído com o menor número de amostras conseguiu se aproximar do valor da função real, calculado pelo otimizador, ao longo do processo de enriquecimento. Essa estratégia que reduz o tamanho da amostra de $10n$ para $5n$ foi indicada para diminuir as possibilidades de ocorrência do problema de sobreajuste, bem como obter uma melhoria na aproximação do modelo e ainda reduzir o custo computacional do processo de otimização.

Aqui também foi realizada uma avaliação inicial para comparar diferentes tamanhos de amostras na construção de modelos substitutos e diferentes limites para a etapa de enriquecimento do modelo. Foram gerados três grupos iniciais de modelos substitutos com tamanhos de $5n$, $10n$ e $15n$, onde n é o número de variáveis do problema. Cada um dos grupos possuía cinco modelos substitutos diferentes. Totalizando 15 modelos substitutos base para essa etapa de testes. Além disso, para o enriquecimento adaptativo de cada modelo substituto foi feito um estudo com diferentes limites de pontos a serem adicionados na amostra. Nesse contexto, foram consideradas as seguintes alternativas para adição de pontos: $5n$, $10n$ e $15n$. Essas avaliações resultaram em sete combinações, conforme demonstrado na Tabela 6.

Tabela 6 – Resumo de resultados para escolha dos tamanhos de amostras.

Pontos iniciais do MS	Pontos para adaptação do MS	Otimizações realizadas	Melhor solução encontrada (%)	Média de melhoria em relação ao caso base (%)	Pior solução encontrada (%)	Desvio padrão	Número de avaliações de função da melhor solução	Média do número de avaliações de função
5n	5n	5	60,22	41,55	25,29	0,1184	241	241
	10n	5	68,70	54,50	36,87	0,1210	361	361
10n	5n	5	49,46	36,49	24,93	0,0961	361	361
	10n	5	53,69	42,75	36,68	0,0636	481	481
15n	5n	5	52,73	44,44	38,47	0,0573	601	601
	10n	5	50,62	46,84	37,70	0,0464	601	601
	15n	5	60,83	49,33	37,30	0,0751	721	721

Fonte: A autora (2022)

Diante dos resultados obtidos, foi adotado o plano de amostragem LHS com tamanho inicial $5n$ e enriquecimento de tamanho $10n$ para a primeira parte do problema 1 que envolve a locação ideal dos poços. Essa escolha levou em consideração o bom desempenho dessa combinação que possui um número baixo de avaliações de função, quando comparada com a maioria das outras opções. Os resultados para melhor solução, média e pior solução também são satisfatórios para essa etapa inicial, mesmo com o desvio padrão sendo o maior entre todas as outras. Já para os problemas integrados de locação e vazão, devido a quantidade de variáveis que esses problemas envolvem, optou-se por definir as amostras do LHS com tamanho inicial de $5n$ e enriquecimento de $5n$, evitando um excesso de avaliações de função.

5.3 PROBLEMAS ESTUDADOS

Neste tópico são descritos os problemas estudados nesta dissertação, os processos de otimização que foram utilizados para solucionar tais problemas, bem como seus principais resultados.

5.3.1 Problema 1 - Otimização em dois estágios: locação dos poços (AG) e gerenciamento de vazões (SAO)

O problema 1 envolve a otimização da locação e do gerenciamento de vazões de maneira sequencial, ou seja, a otimização é realizada em duas etapas sequenciais: a primeira

visa otimizar o posicionamento dos poços. A segunda utiliza os melhores posicionamentos encontrados na primeira etapa, os mantém fixos e otimiza as vazões de produção e injeção.

As formulações matemáticas desse problema são descritas pelas equações Eq.(2) para locação de poços e Eq.(3) para o gerenciamento de vazões, onde o objetivo principal é maximizar o valor presente líquido (VPL) do fluxo de caixa do campo.

De acordo com Eq.(2), as variáveis de projeto do problema de locação estão sujeitas a restrições como os limites do reservatório nas direções i e j , aqui $x_{i,w} \leq 60$ blocos e $x_{j,w} \leq 60$ blocos; uma distância mínima entre poços dada por $\|(X_a, X_b)\| \geq 4$ blocos; e poços posicionados em regiões associadas a blocos ativos ($id_w(x_{k,w}) = 1$) na malha do reservatório.

A Eq.(3) indica que as variáveis relacionadas ao problema de vazão estão sujeitas as seguintes restrições: os poços produtores e injetores devem respeitar os limites máximos diários impostos por plataforma.

No *Egg Model*, os limites individuais máximos e mínimos para a produção de líquidos são definidos por $0.001 \leq x_{t,w} \leq 0.30$ e $0.001 \leq x_{t,w} \leq 0.1807$ para injeção de água. Esses valores de limites foram normalizados pela capacidade das suas respectivas plataformas, portanto são referentes às taxas de rateio de vazão dos poços conforme descrito na Eq.(5).

O problema 1 possui um total de 60 variáveis, solucionadas através de duas abordagens sequenciais. As equações Eq.(1) e Eq.(7) demonstram como é feito o cálculo do número total de variáveis de cada problema. A Eq.(1) indica que o número de variáveis do problema de locação (ndv_{loc}), primeira etapa do problema 1, depende do número de poços e da quantidade de coordenadas associadas a cada poço.


O reservatório de estudo possui um total de 12 poços, dos quais quatro poços (PROD1, PROD2, PROD3 e PROD4) formam o conjunto dos produtores e oito poços (INJECT1, INJECT2, INJECT3, INJECT4, INJECT5, INJECT6, INJECT7 e INJECT8) formam o conjunto dos injetores, como mostra a Figura 11. Cada poço possui duas coordenadas topográficas a serem determinadas ($x_{i,w}, x_{j,w}$). Portanto, ndv_{loc} é dado pela Eq.(32).

$$\begin{aligned} ndv_{loc} &= (n_p + n_i) \cdot n_c \\ ndv_{loc} &= (4 + 8) \cdot 2 = 24 \end{aligned} \tag{32}$$

Para a segunda etapa do problema 1, gerenciamento ótimo de vazões do reservatório *Egg Model*, foi considerada a operação em capacidade não-topada (OCNT) (HOROWITZ; AFONSO; DE MENDONÇA, 2013). Uma abordagem comumente usada para os problemas

de vazão, e adotada aqui, é subdividir o período de concessão (T) em um número de ciclos de controle (n_t) cujos tempos de controle são fixos (ver Figura 12).

Figura 12 – Intervalos de tempo de ciclos de controle com tempos fixos.



Fonte: Adaptado de Horowitz, Afonso e De Mendonça (2013)

Como indica a Eq.(9), o número de variáveis (ndv_{vaz}) está associado a quantidade total de poços e ao número total de ciclos de controle das vazões.

Para a obtenção dos tempos de controle foi realizada uma análise prévia dos resultados de vazão obtidos na etapa de otimização da locação e, a partir disso, foram observados os instantes nas quais houve o surgimento de água nos poços produtores. O primeiro tempo é o tempo inicial de concessão. O segundo tempo foi definido como o período médio de surgimento de água calculado com base nas 20 soluções ótimas de locação, primeira etapa do problema 1. O tempo para o último ciclo de controle foi determinado a partir da média entre as datas para definição do tempo do segundo ciclo de controle e o tempo final de concessão do reservatório (T). Para o exemplo em estudo, isto resultou em $T_{cc1} = 0$ dias, $T_{cc2} = 600$ dias e $T_{cc3} = 2010$ dias. A Figura 13 apresenta a divisão do tempo de concessão para os três ciclos estabelecidos.

Figura 13 – Definição prévia do intervalo dos 3 ciclos de controle para o reservatório *Egg Model*.



Fonte: A autora (2022)

Portanto, ndv_{vaz} é dado por Eq.(33).

$$\begin{aligned} ndv_{vaz} &= (n_p + n_l) \cdot n_t \\ ndv_{vaz} &= (4 + 8) \cdot 3 = 36 \end{aligned} \quad (33)$$

Para os estudos relacionados a primeira etapa do problema 1, locação ótima dos poços, foram realizadas 20 otimizações sucessivas com o intuito de mitigar a natureza randômica do otimizador. Para isso, foi utilizado o AG do MATLAB associado a modelos substitutos adaptativos que foram enriquecidos ao longo do processo de otimização. A repetição das análises experimentais é necessária para avaliar com maior precisão os efeitos de dispersão nos estudos realizados. Como indicado anteriormente, Tabela 4, todos os modelos substitutos foram inicializados com amostras de tamanho $5n$ utilizando o LHS e foram enriquecidos com um máximo de $10n$. Os parâmetros estatísticos avaliados nessa primeira etapa considerando o conjunto de 20 análises (otimizações completas), incluindo a avaliação do custo computacional que está indicado através do número médio de simulações do IMEX, são apresentados na Tabela 7.

Tabela 7 – Resultados estatísticos obtidos na primeira etapa do problema 1 (locação de poços).

Função VPL (10^6 \$)	Nº de Otimizações	Melhor	Média	Pior	Desvio Padrão	Média do Nº de Simulações
	20	48.1440	42.2404	38.5398	2.7002	361

Fonte: A autora (2022)

Os valores apresentados mostram resultados satisfatórios e consistentes, mesmo com o baixo número de avaliações de função realizadas. Também pode ser observada uma boa distribuição das soluções devido ao baixo desvio padrão apresentado. Isso demonstra também a qualidade dos modelos utilizados, visto que nesse ponto só estão sendo consideradas as variáveis de locação.

Garrido (2019) realizou um estudo que constatou que a otimização da locação de poços trazia resultados melhores e com um menor número de avaliações do que a otimização dos controles de vazões. Mesmo se tratando de problemas diferentes do que foi apresentado aqui, dois estudos recentes envolvendo a otimização de vazões do reservatório *Egg Model* foram utilizados apenas para critério de comparação.

O primeiro foi desenvolvido por Silva (2019) e seu melhor resultado trouxe um VPL de $\$ 49.8259 \times 10^6$ ao aplicar o método cooperativo assistido do enxame de partículas (CAPSO) ao reservatório *Egg* com a definição de seis ciclos para o controle de vazões.

O segundo estudo foi apresentado por Pinto (2020) aplicando a estratégia de otimização por aproximação sequencial (SAO). Para o comparativo realizado aqui, foi


escolhido o resultado referente a otimização nominal (ON) com o estabelecimento de dois ciclos de controles para o gerenciamento das vazões, pois os outros resultados envolviam abordagens como controle reativo (CR) e otimização robusta (OR). A ON com dois ciclos de controles trouxe um VPL de $\$ 48.8048 \times 10^6$.

A partir disso, verificou-se que as soluções obtidas a partir da otimização da locação de poços utilizando o AG não conseguiram ser melhores do que os resultados de VPLs das referências citadas acima. Essa conclusão levou aos estudos que serão apresentados a seguir ainda neste problema 1 e nos problemas 2 e 3, onde o controle de vazões também é feito durante o processo de otimização.

As otimizações alteraram o posicionamento de todos os poços previamente locados no campo (Figura 11). Todas as locações obtidas nessa etapa (Figura 65) e as coordenadas associadas a cada cenário (Tabela 24 e Tabela 25) são apresentadas no Apêndice deste documento.

A melhor solução para a locação dos poços neste trabalho é apresentada na Figura 14 através de uma superposição comparativa. As posições antigas referentes ao caso base e as novas referentes ao melhor caso otimizado no reservatório estudado são mostradas com poços produtores à esquerda e injetores à direita. A maioria dos poços injetores se concentrou em regiões mais próximas das bordas do reservatório. Para os produtores, a mudança de posição foi mais significativa. Inicialmente, esses poços ocupavam a região central do reservatório, onde estão presentes canais de maior permeabilidade, e agora estão, em sua maioria, também em regiões periféricas.


Figura 14 – Disposição dos poços da melhor solução para o problema 1: produtores (à esquerda) e injetores (à direita).



Fonte: A autora (2022)

Uma melhor visualização das locações ótimas apresentadas acima, com a devida identificação dos poços, é mostrada na Figura 15.

Figura 15 – Distribuição dos poços produtores e injetores da melhor solução do problema 1.




Fonte: A autora (2022)

É possível identificar que o cenário da melhor solução, assim como para as outras, alterou o posicionamento de todos os poços com os produtores locados, preferencialmente, em regiões de menor permeabilidade e a maioria dos injetores em proximidades de zonas onde essa propriedade é maior.

Os poços produtores estão todos locados em regiões de menor permeabilidade, conforme mostram os cortes apresentados na Figura 16.


Figura 16 – Permeabilidade dos cortes verticais das camadas do reservatório onde estão locados os poços produtores pós otimização de localização: (a) PROD1, (b) PROD3, (c) PROD2 e (d) PROD4.



Fonte: A autora (2022)

A maioria dos poços injetores está posicionado em blocos mais periféricos e muito próximos onde a permeabilidade é mais alta (Figura 17), porém em regiões que não estão ligadas diretamente aos produtores. Portanto, não induzindo a produção de água nesses poços.


Figura 17 – Permeabilidade dos cortes verticais das camadas do reservatório onde estão locados os poços injetores pós otimização de locação: (a) INJECT1 e INJECT5, (b) INJECT2, (c) INJECT3, (d) INJECT4, (e) INJECT6 e (f) INJECT7 e INJECT8.



Fonte: A autora (2022)

Esse cenário é diferente do apresentado no caso base, Figura 11, onde todos os produtores e injetores são locados inicialmente em regiões de alta permeabilidade. A notável ligação direta entre esses poços coloca esse cenário base como um facilitador no processo de avanço da água pelos canais do reservatório, favorecendo assim uma maior produção de água, o que justifica o baixo VPL obtido relacionado a esse cenário base. Um melhor panorama da localização dos produtores pode ser observado na Figura 18.

Figura 18 – Permeabilidade dos cortes verticais das camadas do reservatório onde foram locados os poços produtores no caso base: (a) PROD1, (b) PROD2, (c) PROD3 e (d) PROD4.




Fonte: A autora (2022)

Diante dos resultados obtidos para a locação, é perceptível que a resposta do otimizador não apresenta nenhum padrão de posicionamento, pois todas as soluções encontradas diferem bastante entre si. Embora isso aconteça, também é clara a eficiência do reservatório diante das novas configurações de locação visto que há uma significativa melhoria no VPL em cada solução. Portanto, nem sempre há um padrão quando a permeabilidade do reservatório é heterogênea. Isso é mais notável quando observamos de perto as soluções encontradas, rodada a rodada, após a otimização da locação. Por exemplo, a partir da Tabela 28 presente no Apêndice deste trabalho, é possível notar que os resultados de posicionamento de poços para as rodadas 3, 9 e 14 (Figura 65) são muito diferentes entre si, no entanto, seus VPLs são muito semelhantes. Essa proximidade é demonstrada pela diferença percentual entre seus respectivos valores, onde a maior diferença entre eles é de apenas 0,28%. Essa situação descrita também ocorre com as rodadas 5 e 17, e 10 e 13, onde essa diferença percentual entre os VPLs é de 0,27% e 0,09%, respectivamente. Isso indica que a otimização da locação de poços tem muitas soluções viáveis, sendo um desafio encontrar uma solução global única.


Nessa primeira etapa, os controles dos poços não são otimizados, cabendo ao simulador controlar internamente cada poço de acordo com suas capacidades individuais e de plataforma. A Figura 19 e a Figura 20 demonstram o comportamento do simulador que atua livremente na produção líquidos e a injeção de água no reservatório.

Figura 19 – Produção de líquidos (m³/dia) no caso base do problema 1.



Fonte: A autora (2022)

Figura 20 – Injeção de água (m³/dia) no caso base do problema 1.



Fonte: A autora (2022)

Como é possível observar, a produção e a injeção flutuam muito dentro dos limites estabelecidos para cada poço e plataforma devido as regras impostas pelo gerenciamento do simulador. Essas oscilações acontecem devido a manutenção dos limites de pressão estabelecidos como controle secundário no simulador e a ação do otimizador que está buscando melhorar o VPL considerando até então somente o posicionamento dos poços produtores e injetores.


Para a segunda etapa do problema 1, o objetivo principal é também maximizar o VPL utilizando os rateios de vazão como as variáveis do problema a ser solucionado. As vazões de produção e injeção são otimizadas usando as novas locações dos poços, obtidas na etapa anterior. Depois disso, simulações numéricas usando o IMEX são analisadas para cada caso otimizado, incluindo seus resultados de vazão. Para os processos dessa etapa final foi utilizada a técnica de otimização sequencial aproximada (SAO), tendo como otimizador o SQP do MATLAB (MATHWORKS, INC., 2018).

Algumas observações devem ser feitas sobre as etapas de otimização que envolvem o problema 1. Na primeira etapa, todas as otimizações aumentaram o valor da função objetivo (VPL). No entanto, na segunda etapa, 2 das 20 soluções não foram melhoradas, ou seja, os resultados foram piores do que os obtidos na primeira etapa. Esses resultados adversos aconteceram, pois, para implementar a abordagem sequencial sugerida é necessário inserir os dados de vazão obtidos pelas soluções encontradas na etapa de locação como ponto de partida da etapa de vazão. Esses dados iniciais são importantes, pois são eles que definem o VPL inicial a ser melhorado, principal parâmetro de comparação no processo de otimização.

Em todos os casos estudados, não foi possível obter o mesmo VPL final da primeira etapa, visto que não há uma definição de ciclos de controle de vazões durante o processo de otimização da locação dos poços, ou seja, não há interferência do otimizador na definição das vazões. Isso pode ser percebido quando se comparam os resultados ao final da etapa 1 (Figura 21 e Figura 22), pós otimização do posicionamento dos poços, com os valores usados no início da segunda etapa (Figura 23 e Figura 24), otimização de vazões.


Os gráficos de produção de líquidos e injeção de água após a etapa 1 são apresentados na Figura 21 e na Figura 22, respectivamente.

Figura 21 – Produtores pós otimização da locação (etapa 1) com AG para o problema 1.



Fonte: A autora (2022)

Figura 22 – Injetores pós otimização da locação (etapa 1) com AG para o problema 1.




Fonte: A autora (2022)

Nas figuras acima, é possível notar o simulador trabalhando livre devido a não definição de ciclos de controle.


As vazões dos produtores e injetores usadas como ponto inicial para a etapa final são apresentadas na Figura 23 e Figura 24.

Figura 23 – Produtores pós otimização da locação com definição dos ciclos de controle para entrada no SAO (início da etapa final) do problema 1.



Fonte: A autora (2022)

Figura 24 – Injetores pós otimização da locação com definição dos ciclos de controle para entrada no SAO (início da etapa final) do problema 1.



Fonte: A autora (2022)

Como pode ser observado, não há compatibilidade entre os resultados de uma etapa para a outra, pois quando as vazões entram como restrição, o simulador trabalha diferente e tenta alcançar os controles definidos. No entanto, é importante frisar que todos os resultados de vazão apresentados acima são válidos, pois todas as restrições para poços e plataformas são controladas internamente pelo simulador.

O caso base da primeira etapa do problema 1 é estabelecido a partir de uma configuração de posicionamento de poços presente e bem estabelecida na literatura para o reservatório *Egg*. As coordenadas associadas a cada poço no caso base são apresentadas na Tabela 8.

Tabela 8 – Coordenadas do caso base do problema 1.

Poço	Coordenadas	
	<i>i</i>	<i>j</i>
PROD1	16	43
PROD2	35	40
PROD3	23	16
PROD4	43	48
INJECT1	5	57
INJECT2	30	53
INJECT3	2	35
INJECT4	27	29
INJECT5	50	35
INJECT6	8	9
INJECT7	32	2
INJECT8	57	6

Fonte: A autora (2022)

Os resultados obtidos a partir da locação ótima dos poços, para a melhor solução, e os dados de produção e injeção dos poços, em m^3/dia , em cada tempo dos ciclos de controle adotados para a etapa seguinte são descritos na Tabela 9.

Tabela 9 – Valores de vazões em m³/dia, adotadas para entrada na segunda etapa, e coordenadas após etapa 1 do problema 1.

Poço	Ciclo de controle			Coordenadas	
	1	2	3	<i>i</i>	<i>j</i>
PROD1	47,42	16,38	19,58	58	6
PROD2	38,26	17,91	13,93	20	17
PROD3	41,08	17,59	23,80	16	4
PROD4	46,37	27,59	21,92	19	56
INJECT1	39,75	39,75	39,75	13	41
INJECT2	39,75	39,75	39,75	48	36
INJECT3	14,54	0,00	0,00	41	2
INJECT4	23,77	0,00	0,00	33	2
INJECT5	37,15	0,00	0,00	43	41
INJECT6	21,60	0,00	0,00	57	15
INJECT7	25,80	0,00	0,00	39	27
INJECT8	17,64	0,00	0,00	39	23

Fonte: A autora (2022)

A apresentação dos resultados de vazão associados ao cenário ótimo é necessária para entender o que foi definido e utilizado como ponto inicial para a etapa seguinte onde é realizado o gerenciamento de vazões através de ciclos de controle.

A partir de todas as considerações feitas até aqui a respeito da dificuldade de compatibilizar as etapas do problema 1, foi estudada uma estratégia para fazer a ligação entre elas. Para isso, foi realizada uma análise dos dados de vazão obtidos após a otimização da locação. O ponto inicial com os valores de vazão a serem otimizados foi definido com base nas vazões obtidas ao final da primeira etapa. Tais vazões foram extraídas nos tempos correspondentes a cada um dos três ciclos de controle a serem adotados para a etapa final. No entanto, o resultado a ser usado no SAO, obtido após otimização com o AG, não representa o que ocorreu na etapa 1, pois nela não é realizado diretamente o controle de vazões e na etapa seguinte são definidos três ciclos de controle para as vazões, ou seja, os resultados não são compatíveis, havendo uma diferença significativa entre os VPLs.

Diante disso, foi aplicada uma redução aos valores de vazão da etapa 1, resultando na utilização de 70% e 50% dos mesmos. O primeiro percentual também apresentou uma diferença considerável entre os VPLs entre as etapas. A opção que considerou 50% do valor das vazões se mostrou mais compatível. Portanto, essa foi a estratégia definida.

É possível notar uma diferença entre o que é apresentado na Figura 21 e Figura 22, e os valores contidos na Tabela 9. Essa diferença se deve ao procedimento adotado para contornar o problema de incompatibilidade. Portanto, os valores da Tabela 9 são referentes a um percentual de 50% das vazões ao final da etapa de locação, cenário otimizado, e foram extraídos exatamente nos tempos definidos para cada ciclo de controle da etapa seguinte.

É importante destacar que o ponto inicial para o SAO é específico e está atrelado a cada uma das soluções de locação, ou seja, há 20 pontos iniciais e, conseqüentemente, 20 otimizações conduzidas pelo SAO. Todos os resultados apresentados são referentes apenas à melhor solução entre elas.

Ao final do processo de otimização da etapa de vazões, foram obtidos os controles ótimos de produção e injeção dos poços, em m^3/dia . Eles são apresentados na Tabela 10 junto com as coordenadas ótimas que foram fixadas ao final da etapa 1 e já apresentadas anteriormente na Tabela 9.

Tabela 10 – Valores de finais de vazões em m^3/dia para o caso otimizado pós SAO.

Poço	Ciclo de controle			Coordenadas	
	1	2	3	i	j
PROD1	40,49	49,47	42,77	58	6
PROD2	50,22	48,14	18,08	20	17
PROD3	62,71	16,51	67,32	16	4
PROD4	21,82	27,32	46,95	19	56
INJECT1	41,05	46,42	57,35	13	41
INJECT2	18,52	45,24	75,54	48	36
INJECT3	0,44	0,44	5,14	41	2
INJECT4	0,44	10,33	3,05	33	2
INJECT5	66,65	30,86	4,48	43	41
INJECT6	17,02	0,44	1,27	57	15
INJECT7	22,77	4,02	3,86	39	27
INJECT8	8,34	3,69	24,43	39	23

Fonte: A autora (2022)

Todos os gráficos e análises apresentados estão relacionadas a melhor solução encontrada para o problema 1. A comparação entre os resultados da primeira etapa onde apenas a locação foi otimizada e das duas etapas sequenciais, locação e vazão, que configuram o problema 1, é apresentada na Tabela 11. A análise para a segunda etapa considera apenas os resultados em que o VPL foi melhorado.

Tabela 11 – Resultados estatísticos obtidos para o problema 1.

Função VPL (10 ⁶ \$)	Nº de Otimizações	Melhor	Média	Pior	Desvio Padrão	Média do Nº de Simulações
AG	20	48.1440	42.2404	38.5398	2.7002	361
AG + SAO	18	50.0749	46.1872	41.9391	2.3498	1398

Fonte: A autora (2022)

O comparativo entre o caso base e os resultados obtidos para o problema 1 é resumida, através de dados percentuais, na Tabela 12.


Tabela 12 – Resultados estatísticos obtidos para o problema 1 em relação ao caso base.

Estratégia	Nº de Otimizações	Melhor Solução (%)	Média das Soluções (%)	Pior Solução (%)	Desvio Padrão (%)
AG	20	68.70	48.01	35.04	9.46
AG + SAO	18	75.46	61.84	46.96	8.23

Fonte: A autora (2022)

Para um melhor entendimento dos resultados obtidos, para efeito de comparação, os histogramas dos VPLs das otimizações realizadas foram produzidos e são mostrados na Figura 25. As barras azuis são relacionadas à primeira etapa do problema 1 e as barras verdes são referentes ao final do processo, em que locação e vazões foram otimizadas.

Figura 25 – Histograma do VPL após etapas de otimização do problema 1.



Fonte: A autora (2022)


Como é possível notar, os dados das otimizações não seguem uma distribuição normal, visto que se concentram mais à esquerda (primeira etapa) e mais à direita (ao final do

processo). Há também *outliers*, marcado em vermelho, no histograma referente ao processo final onde duas soluções se distanciam das outras. Estas foram as soluções desconsideradas nos dados estatísticos presentes na Tabela 12, quando o AG e o SAO são empregados. A não consideração desses resultados tem como objetivo evitar interpretações equivocadas, pois a sua consideração pode levar a crer que os dados são menos significativos do que realmente são. Diante disso, através do AG, a otimização da locação gera bons resultados em termos de VPL e estes são melhorados ainda mais após o uso do SAO. Portanto, é perceptível a eficiência do processo sequencial, pois ao final de tudo, há uma maior concentração de VPLs mais altos do que os que foram obtidos na etapa anterior.

A partir da Tabela 11, tem-se que o melhor resultado obtido na abordagem combinada, AG para locação de poços e SAO para vazões, possui um VPL de $\$ 50.0749 \times 10^6$, o que representa uma melhoria de 75,46% em relação ao caso base conforme indicado na Tabela 12. Esse melhor resultado foi encontrado ao final da segunda etapa do problema 1, quando a estratégia SAO foi utilizada.


Os parâmetros de água acumulada (redução) e corte de água (retardo e redução) justificam a melhoria do VPL. Uma queda significativa da quantidade de água produzida ocorreu durante o período de concessão do reservatório, influenciando diretamente no aumento do VPL. Essa situação é notada tanto para a otimização da locação, através do AG, quanto para a solução final do problema 1, combinação do AG com o SAO. Ao final de 10 anos de exploração em campo, a água acumulada apresentou uma redução de mais de 84% no caso otimizado com a combinação de estratégias em relação ao caso base. É possível notar também que a produção de óleo sofreu reduções nos casos otimizados em relação ao caso base, porém isso não foi significativo visto que a redução de água é o principal fator para o aumento do VPL. Já o corte de água é mantido por bastante tempo em níveis mais baixos e, ao final do tempo de simulação, apresenta um percentual de 80,86% para o caso otimizado. Isso representa uma diferença de 13,32% em relação ao caso base que possuía corte de água de 94,18%. Todas essas considerações mencionadas podem ser observadas na Figura 26 e na Figura 27.

Figura 26 – Comparativo de óleo e água acumulados (m³) para o reservatório *Egg Model* no problema 1.



Fonte: A autora (2022)

Figura 27 – Comparativo do corte de água (%) para o reservatório *Egg Model* no problema 1.




Fonte: A autora (2022)

O surgimento e avanço tardios da água no caso otimizado foi determinante no processo de otimização, pois a partir do momento que um poço começa a produzir água, sua razão água-óleo pode seguir uma tendência de crescimento e atingir altos índices. Portanto, podendo interferir na maximização do VPL, objetivo da otimização.

Abaixo são apresentados os mapas de saturação de água ao longo do período de concessão do reservatório em um comparativo entre o caso base (Figura 28a) e a melhor solução encontrada (Figura 28b) para o problema 1.

Figura 28 – Saturação de água para o reservatório *Egg Model* para o problema 1.




Fonte: A autora (2022)

Na melhor solução encontrada, é possível observar uma região do reservatório que concentrou uma maior saturação de água por grande parte do tempo. Nela estão locados os poços INJECT2, INJECT5, INJECT6, INJECT 7 e INJECT 8, ou seja, cinco dos oito poços injetores.

A baixa produção de água vista na Figura 26 e o avanço tardio de água no reservatório, Figura 28, são percebidos de maneira mais detalhada quando se analisa, individualmente, cada poço produtor. A partir da Figura 29, é possível observar que o poço PROD1 é o único onde a água surge mais precocemente, pouco tempo depois do início da simulação. Isso se justifica pelo seu posicionamento no reservatório, visto que ele é o único poço produtor locado nessa região e possui proximidade com sete dos oito injetores (*vide* Figura 15). Sendo, portanto, o primeiro produtor a ser atingido pela água.

Já os poços PROD2, PROD3 e PROD4 permanecem com uma produção irrisória de água até seis anos e meio após início da exploração do campo, pois estão localizados numa região oposta aos injetores do reservatório, onde, posteriormente, são atingidos pelo arraste de água.


Figura 29 – Produção acumulada de água para o reservatório *Egg Model* na melhor solução para o problema 1.



Fonte: A autora (2022)

Tais observações são confirmadas através da Figura 30 que demonstra o corte de água de cada poço produtor individualmente, com o poço PROD1 tendo maior destaque, pois é o único que foge do padrão de comportamento dos demais devido a sua localização no campo.

Figura 30 – Corte de água do reservatório *Egg Model* (GA+SAO – problema 1).




Fonte: A autora (2022)

Em relação a solução encontrada pelo otimizador e apresentada na Tabela 10, observa-se que os controles foram aplicados de maneira direta, com exceção dos poços PROD1, durante o segundo ciclo, e PROD3, durante os ciclos primeiro e terceiro, conforme demonstrado na Figura 31. O que pode ser explicado pela pressão de fundo de poço (BHP) do PROD1 que teve uma queda de pressão na transição do primeiro para o segundo ciclo. Já para

o PROD3, a pressão de fundo de poço (BHP) apresentou uma variabilidade muito maior, o que pode ter gerado uma certa instabilidade, impedindo assim a manutenção da vazão determinada.

Figura 31 – Produção de líquidos dos poços produtores no reservatório *Egg Model* (GA+SAO – problema 1).




Fonte: A autora (2022)

Nota-se também que todos os poços produtores foram mantidos abertos durante todo o período de concessão do reservatório. Essa foi uma escolha deliberadamente feita desde o início quando se optou por remover uma restrição que indicava o fechamento de poços quando um determinado percentual de corte de água fosse atingido.

A pressão de fundo de poço (BHP) dos produtores, Figura 32, apresentou certa instabilidade, especialmente no decorrer do tempo do último ciclo de controle. E apenas o poço PROD3, no início do terceiro ciclo, atingiu valor limite mínimo de 39.500 *kPa*.


Figura 32 – Pressão de fundo de poço (BHP) dos poços produtores do reservatório *Egg Model* (GA+SAO – problema 1).



Fonte: A autora (2022)

Além do que já foi apresentado, é importante analisar também a produção acumulada de óleo de cada poço. A Figura 33 traz essa informação.


Figura 33 – Produção acumulada de óleo para o reservatório *Egg Model* (GA+SAO – problema 1).



Fonte: A autora (2022)

A Figura 34 traz a saturação de óleo do reservatório nos casos base, pós otimização da locação e pós otimização das vazões. Mesmo após o final do processo de otimização, ainda há bastante óleo remanescente no reservatório, fato observado ao comparar a saturação dos casos otimizado final com o base. Nesse cenário, o objetivo da otimização é a maximização do VPL.

Figura 34 – Saturação de óleo: (a) caso base, (b) pós otimização da locação e (c) pós otimização de vazões.




Fonte: A autora (2022)

Uma investigação que tenha como objetivo a maximização da produção acumulada de óleo pode trazer um cenário diferente do que foi apresentado acima.

Em relação aos poços injetores, os controles obtidos pelo otimizador foram aplicados para todos os ciclos, conforme demonstrado na Figura 35, não sofrendo variações como ocorreu com os poços produtores.


Figura 35 – Injeção de água no reservatório *Egg Model* (GA+SAO – problema 1).



Fonte: A autora (2022)

A pressão de fundo de poço (BHP) dos injetores, Figura 36, que em nenhum momento atingiu o seu valor limite máximo de 42.000 *kPa*, se manteve estável, o que pode justificar também o obediência rigoroso dos controles propostos.

Figura 36 – Pressão de fundo de poço (BHP) dos poços injetores do reservatório *Egg Model* (GA+SAO – problema 1).



Fonte: A autora (2022)

5.3.2 Problema 2 - Otimização simultânea da locação dos poços e do gerenciamento de vazões (AG)

O problema 2 engloba a otimização da locação e do gerenciamento de vazões de maneira integrada. Desse modo, o posicionamento ótimo dos poços e os melhores controles para as vazões de produção e injeção são definidos simultaneamente.

A formulação matemática desse problema é descrita pela equação Eq.(8), onde o objetivo principal, assim como no problema 1, é maximizar o valor presente líquido (VPL) do fluxo de caixa do campo.

O reservatório estudado para este problema também é o *Egg model*, portanto, as variáveis de projeto estão sujeitas às mesmas restrições do problema 1, com a diferença de que agora estas devem ser obedecidas ao mesmo tempo pelo otimizador.

Portanto, as variáveis referentes a locação estão sujeitas a restrições de limites do reservatório nas direções i e j , com $x_{i,w} \leq 60$ blocos e $x_{j,w} \leq 60$ blocos; uma distância mínima entre poços dada por $\|(X_a, X_b)\| \geq 4$ blocos; e poços posicionados em regiões associadas a blocos ativos ($id_w(x_{k,w}) = 1$) na malha do reservatório.

Já as variáveis relacionadas ao problema de vazão estão sujeitas às restrições de limites de produção e injeção, ou seja, os poços produtores e injetores devem respeitar os limites máximos diários impostos por plataforma e os limites individuais máximos e mínimos para a produção de líquidos que são definidos por $0.001 \leq x_{t,w} \leq 0.30$ e $0.001 \leq x_{t,w} \leq 0.1807$ para injeção de água. Esses valores de limites são valores normalizados pela capacidade das suas respectivas plataformas, sendo, portanto, referentes às taxas de rateio de vazão dos poços conforme descrito na Eq.(8).

O reservatório *Egg* foi utilizado na sua configuração original com 12 poços, dos quais quatro são produtores (PROD1, PROD2, PROD3 e PROD4) e oito são injetores (INJECT1, INJECT2, INJECT3, INJECT4, INJECT5, INJECT6, INJECT7 e INJECT8), conforme apresentado na Figura 11.

Esse problema envolve muitas variáveis, 60 ao todo, e é solucionado através de uma abordagem integrada. A Eq.(9) indica como é realizado o cálculo do número total de variáveis desse problema (ndv_{int}), as equações Eq.(1) e Eq.(7) são usadas como referências, pois demonstram o que envolve cada problema em separado. Para locação de poços há duas coordenadas associadas a cada poço por se tratar de uma locação topográfica, já para o gerenciamento de vazões foram definidos três ciclos de controle. Desse modo, ndv_{int} é dado pela Eq.(34).

$$\begin{aligned} ndv_{int} &= ndv_{loc} + ndv_{vaz} = (n_p + n_l) \cdot n_c + (n_p + n_l) \cdot n_t \\ ndv_{int} &= (4 + 8) \cdot 2 + (4 + 8) \cdot 3 = 60 \end{aligned} \quad (34)$$

Assim como no problema 1, a operação em capacidade não-topada (OCNT) (HOROWITZ; AFONSO; DE MENDONÇA, 2013) foi considerada para o gerenciamento de vazões. Três ciclos de controle foram definidos nos mesmos períodos do problema 1, $T_{cc1} = 0$ dias, $T_{cc2} = 600$ dias e $T_{cc3} = 2010$ dias, para um tempo total de concessão T do reservatório igual a 3600 dias, conforme demonstrado anteriormente na Figura 13.

Para o problema 2 foram realizadas 20 otimizações para entender melhor o comportamento randômico das soluções. Foi usado o AG do MATLAB associado a modelos substitutos adaptativos que foram enriquecidos durante o processo de otimização. Como indicado na Tabela 5, para o problema 2 foram utilizados modelos substitutos com amostras geradas através de LHS de tamanho $5n$ e seu enriquecimento estava limitado a $5n$.

Para melhor observação dos resultados obtidos, foi feita a avaliação do custo computacional das simulações realizadas pelo IMEX e foram levantados os dados estatísticos do conjunto de 20 otimizações completas referentes ao problema 2. Tais informações são apresentadas na Tabela 13.

Tabela 13 – Resultados estatísticos obtidos para o problema 2.

Função VPL (10^6 \$)	Nº de Otimizações	Melhor	Média	Pior	Desvio Padrão	Média do Nº de Simulações
	20	49.7853	46.5290	44.4949	1.6085	601

Fonte: A autora (2022)

Os resultados apresentados na Tabela 13 demonstram resultados consistentes associados a uma média baixa de avaliações de função realizadas, contribuindo para um baixo custo computacional. É perceptível que há uma excelente distribuição das soluções visto que o desvio padrão apresentado também é baixo. A qualidade dos modelos substitutos utilizados no processo contribuiu diretamente para esses resultados.

A Tabela 14 traz os resultados do melhor, pior e média das soluções em valores percentuais comparados ao caso base. Nela é possível notar uma melhoria significativa do caso otimizado em relação ao caso base.

Tabela 14 – Resultados estatísticos obtidos para o problema 2 em relação ao caso base.

Estratégia	Nº de Otimizações	Melhor Solução (%)	Média das Soluções (%)	Pior Solução (%)	Desvio Padrão (%)
AG _{int}	20	45.32	35.82	29.88	4.70


Fonte: A autora (2022)

Assim como ocorreu no problema 1, observou-se alguns casos com VPLs muito próximos mesmo com os posicionamentos associados sendo bem diferentes entre si. É o caso das rodadas 6 e 9 que possuem VPLs com uma diferença de apenas 0,04% entre elas e suas locações não são semelhantes. Essa situação também ocorre com as duplas de rodadas 1 e 10, 7 e 19, e 8 e 13, onde essa diferença percentual entre os VPLs é de 0,24%, 0,16% e 0,11%, respectivamente. Essas informações comparativas estão presentes na Tabela 29 do Apêndice e confirmam que é um grande desafio encontrar uma solução única, tendo em vista que foram obtidas diferentes soluções viáveis para este problema de locação de poços e gerenciamento de vazões.

Todas as soluções modificaram a locação inicial (Figura 11) aplicada aos poços do *Egg Model* e alteraram também todas as configurações iniciais de controle de vazões. Todos os resultados de VPLs (Tabela 29), posicionamento de poços (Figura 66) e suas coordenadas associadas (Tabela 26 e Tabela 27) são apresentadas no Apêndice deste trabalho.

A melhor locação obtida pós otimização para o problema 2 é apresentada na Figura 37 por meio de uma comparação por superposição.


Figura 37 – Disposição dos poços da melhor solução para o problema 2: produtores (à esquerda) e injetores (à direita).



Fonte: A autora (2022)

A Figura 38 apresenta uma melhor visualização, incluindo identificação, do posicionamento dos poços no cenário ótimo apresentado acima.

Figura 38 – Distribuição dos poços produtores e injetores da melhor solução para o problema 2.




Fonte: A autora (2022)

No cenário apresentado na Figura 38 é possível observar que todos os poços sofreram modificações de posicionamento e que a maioria dos poços produtores foi deslocada para regiões de menor permeabilidade. Os injetores seguiram uma tendência inversa, sendo deslocados para proximidades de regiões de mais alta permeabilidade.

A partir da Figura 39 é possível observar que a maioria dos poços produtores, com exceção do poço PROD1, estão posicionados em regiões com permeabilidade baixa. O cenário apresentado é diferente do que é visto no caso base na qual todos os poços (injetores e produtores) estão localizados em regiões de permeabilidade mais alta, *vide* Figura 11.

Figura 39 – Permeabilidade dos cortes verticais das camadas do reservatório onde estão localizados os poços produtores pós otimização simultânea de localização e vazão: (a) PROD1, (b) PROD2, (c) PROD3 e (d) PROD4.




Fonte: A autora (2022)

Outra tendência observada na melhor solução para locação de poços foi a concentração de poços injetores de um lado do reservatório e a concentração dos produtores no lado oposto.

Assim como ocorreu na melhor solução do problema 1, a maioria dos poços injetores estão locados em zonas mais periféricas e nas proximidades de onde a permeabilidade é maior (Figura 40), sem ligação direta com a maioria dos produtores e, desse modo, não estimulando a produção de água.


Figura 40 – Permeabilidade dos cortes verticais das camadas do reservatório onde estão locados os poços injetores pós otimização simultânea de locação e vazão: (a) INJECT1, (b) INJECT2, (c) INJECT3, (d) INJECT4 e INJECT8, (e) INJECT5 e (f) INJECT6 e INJECT7.



Fonte: A autora (2022)


Para uma avaliação mais adequada da melhor solução obtida para o problema 2, o comportamento do reservatório estudado no caso base é apresentado na Figura 41 e Figura 42 através dos gráficos de produção de líquidos em m^3/dia e injeção de água em m^3/dia .

Figura 41 – Produção de líquidos (m³/dia) no caso base do problema 2.



Fonte: A autora (2022)

Figura 42 – Injeção de água (m³/dia) no caso base do problema 2.



Fonte: A autora (2022)

O melhor resultado obtido na abordagem integrada, AG para locação de poços e controle de vazões, possui um VPL de $\$ 49.7853 \times 10^6$, o que representa uma melhoria de 45,32% em relação ao caso base. O controle utilizado inicialmente e o controle proposto pós-otimização são apresentados na Tabela 15 e na Tabela 16, respectivamente, juntamente com as coordenadas iniciais e as coordenadas otimizadas.

Tabela 15 – Valores de vazões em m³/dia e coordenadas do caso base para o problema 2.

Poço	Ciclo de controle			Coordenadas	
	1	2	3	<i>i</i>	<i>j</i>
PROD1	120,00	120,00	120,00	16	43
PROD2	84,90	64,82	98,08	35	40
PROD3	103,15	95,18	98,52	23	16
PROD4	91,95	120,00	83,41	43	48
INJECT1	79,50	79,50	0,00	5	57
INJECT2	79,50	73,70	79,50	30	53
INJECT3	48,57	41,04	55,78	2	35
INJECT4	39,36	63,36	62,99	27	29
INJECT5	54,02	39,43	37,34	50	35
INJECT6	30,86	0,00	79,50	8	9
INJECT7	64,02	78,19	63,33	32	2
INJECT8	44,16	29,96	21,86	57	6

Fonte: A autora (2022)

Tabela 16 – Valores de vazões em m³/dia e coordenadas da melhor solução para o problema 2.


Poço	Ciclo de controle			Coordenadas	
	1	2	3	<i>i</i>	<i>j</i>
PROD1	60,72	69,51	81,83	4	54
PROD2	8,82	54,05	114,27	6	58
PROD3	110,45	3,07	13,28	5	14
PROD4	117,39	3,28	91,86	20	50
INJECT1	21,67	65,42	51,47	59	10
INJECT2	7,23	6,43	36,22	54	5
INJECT3	64,01	25,25	26,73	57	17
INJECT4	60,73	60,78	7,36	33	2
INJECT5	5,73	75,95	2,75	25	23
INJECT6	20,98	27,44	20,36	21	16
INJECT7	60,31	34,77	72,22	39	9
INJECT8	33,22	27,95	54,98	46	2

Fonte: A autora (2022)

Como pode ser observado acima, todos os controles e coordenadas adotados inicialmente foram modificados no cenário pós otimização.

O parâmetro de água acumulada (Figura 43) foi um dos pontos mais determinantes para a significativa melhoria do VPL na melhor solução para o problema 2, cenário semelhante ao que ocorreu no problema 1.

Figura 43 – Comparativo de óleo e água acumulados (m^3) para o reservatório *Egg Model* no problema 2.




Fonte: A autora (2022)

A Figura 43 mostra uma redução da água acumulada no caso otimizado de 80,15% quando comparado ao caso base. Ainda na Figura 43 para o caso otimizado é notado que um índice baixíssimo de água acumulada é mantido com grande estabilidade até meados de 2017. Já no caso base, logo no início de 2012, é apresentado um crescimento da produção de água.

Como já mencionado, o aparecimento e o avanço tardios da água na melhor solução do problema 2 tiveram um peso significativo no decorrer da otimização, o que possibilitou a maximização do VPL. Na Figura 44 são apresentados mapas de saturação da água para os casos base (Figura 44a) e otimizado (Figura 44b) ao longo dos dez anos de exploração do reservatório.


Figura 44 – Saturação de água para o reservatório *Egg Model* para o problema 2.



Fonte: A autora (2022)

Quando se observa separadamente cada poço produtor nota-se de maneira mais clara a baixa produção de água que foi demonstrada na Figura 43 e o avanço tardio da água exposto na Figura 44.


Figura 45 – Comparativo da produção acumulada de água (m³) entre o caso base e a melhor solução para o problema 2.



Fonte: A autora (2022)

Através da Figura 45 e Figura 46, nota-se que os quatro poços produtores (PROD1, PROD2, PROD3 e PROD4) só começam a produzir água de maneira significativa a partir de 2017. Isso demonstra que até antes da metade do tempo total de exploração do reservatório, seus níveis de produção de água se mantiveram baixos, situação diferente do que é visto no caso base. O poço PROD2, por exemplo, logo no início de 2012 já apresenta um desenvolvimento na produção acumulada de água, sendo seguido pelos outros poços no intervalo dos inícios de 2013 a 2014.


Figura 46 – Comparativo do corte de água dos poços produtores do caso base e da melhor solução para o problema 2.



Fonte: A autora (2022)


A melhor solução encontrada pelo otimizador para o problema 2 trouxe os resultados para o controle de vazões que foram apresentados na Tabela 16. A partir da Figura 47 é visto que os controles máximos propostos para os produtores foram obedecidos para os poços PROD1 e PROD3. Os poços PROD2, durante o segundo e terceiro ciclos, e PROD4 durante o último ciclo não conseguiram manter a vazão máxima devido ao limite de pressão. O comportamento desses dois últimos poços citados pode ser explicado através da Figura 48 que expõe uma queda de pressão exatamente no momento onde a vazão decai para o PROD2. Já para o PROD4, no último ciclo de controle, também há uma queda de pressão. Posteriormente, tanto para o PROD2 quanto para o PROD4, a pressão é mantida nos limites mínimos ($39.500kPa$).

Figura 47 – Produção de líquidos da melhor solução para o problema 2.



Fonte: A autora (2022)


Figura 48 – Pressão de fundo de poço (BHP) dos poços produtores na melhor solução para o problema 2.



Fonte: A autora (2022)


A Figura 49 traz os controles propostos aos poços injetores. Nela é possível perceber que os poços INJECT1, INJECT4, INJECT5, durante o segundo ciclo, e INJECT8, no segundo e último ciclos, não conseguiram manter os controles máximos estabelecidos. O que pode ser explicado pelo atingimento da pressão máxima para esses poços e, assim, o controle de vazões passa a ser operado pelo simulador (Figura 50).

Figura 49 – Injeção de água dos poços injetores na melhor solução para o problema 2.



Fonte: A autora (2022)

Figura 50 – Pressão de fundo de poço (BHP) dos poços injetores na melhor solução para o problema 2.



Fonte: A autora (2022)

5.3.3 Problema 3 - Otimização da locação dos poços e gerenciamento de vazões integradas (AG) + gerenciamento de vazões (SAO)

O problema 3 utiliza uma abordagem híbrida que parte de uma primeira etapa onde a locação de poços e o gerenciamento de vazões desses poços são otimizados de maneira simultânea através do uso do algoritmo genético do MATLAB (MATHWORKS, INC., 2018). Em seguida, os dados obtidos nessa etapa inicial são o ponto de partida para mais uma etapa onde somente as vazões são otimizadas através da técnica de otimização sequencial aproximada (SAO) que utiliza o SQP do MATLAB.

Desse modo, neste trabalho são utilizadas as soluções encontradas para o problema 2, locação de poços e gerenciamento de vazões através de uma abordagem de otimização integrada, como caso base. Os posicionamentos de poços definidos no problema 2 são fixados e, na sequência, as vazões são otimizadas.

A formulação matemática do problema 3 é descrita de acordo com cada etapa do problema. A etapa inicial que utiliza o AG para o procedimento integrado é descrita pela Eq.(8) que engloba a função objetivo de maximização do VPL e suas restrições. Ainda sobre essa etapa, as restrições referentes a locação de poços e ao gerenciamento de vazões para o problema 3 são as mesmas definidas no item 5.3.2 que trata da descrição do problema 2.

A formulação matemática da última etapa para a solução do problema 3 é descrita pela Eq.(6) e está associada ao problema de otimização do gerenciamento de vazões. Essa equação indica que o problema 3 está sujeito às restrições de limites máximos diários de produção e injeção que são impostos por plataforma e individualmente a cada poço. Portanto, para atender a essas restrições é empregada uma normalização a partir da Eq.(5) que impõe os limites mínimos e máximos de $0.001 \leq x_{t,w} \leq 0.30$ para a produção de líquidos e de $0.001 \leq x_{t,w} \leq 0.1807$ para a injeção de água.

Para o cálculo do número total de variáveis do problema 3 são utilizadas as equações que definem o número de variáveis para cada etapa e, ao final, são somadas. Para a etapa inicial integrada, o número de variáveis é 60, conforme demonstrado na Eq.(34) no tópico 5.3.2. Para a última etapa é utilizada a Eq.(7) que depende apenas do número de poços e da quantidade de ciclos de controle de vazões são empregados. Esse problema possui 12 poços totais, dentre eles quatro produtores (PROD1, PROD2, PROD3 e PROD4) e oito injetores (INJECT1, INJECT2, INJECT3, INJECT4, INJECT5, INJECT6, INJECT7 e INJECT8). Para o gerenciamento de vazões foram definidos três ciclos de controle ($T_{cc1} = 0$ dias, $T_{cc2} = 600$ dias e $T_{cc3} = 2010$ dias) conforme esquematizado na Figura 13. Desse modo, para última

etapa do problema 3 há 36 variáveis de projeto, conforme demonstrado na Eq.(35). Portanto, o problema 3 envolve o total de 96 variáveis a serem definidas.

$$\begin{aligned} ndv_{vaz} &= (n_P + n_I) \cdot n_t \\ ndv_{vaz} &= (4 + 8) \cdot 3 = 36 \end{aligned} \quad (35)$$

Os indicadores estatísticos para as soluções encontradas e a avaliação do custo computacional para as rodadas realizadas (número médio de simulações do IMEX) são dadas na Tabela 17. A média do número de simulações é o somatório das médias das duas etapas.

Tabela 17 – Resultados estatísticos obtidos para o problema 3.

Função VPL (10 ⁶ \$)	Nº de Otimizações	Melhor	Média	Pior	Desvio Padrão	Média do Nº de Simulações
AG _{int} + SAO	20	51.5385	48.5768	45.7473	1.6817	1381

Fonte: A autora (2022)

Os VPLs apresentados na Tabela 17 fazem referência aos percentuais presentes na Tabela 18 que traz um comparativo dos resultados obtidos em relação ao caso base.


Tabela 18 – Resultados estatísticos obtidos para o problema 3 em relação ao caso base.

Estratégia	Nº de Otimizações	Melhor Solução (%)	Média das Soluções (%)	Pior Solução (%)	Desvio Padrão (%)
AG _{int} + SAO	20	50.44	41.80	33.54	4.91

Fonte: A autora (2022)

As 20 configurações iniciais de locação e vazão usados como entrada para a última etapa do problema 3, como já mencionado, são as mesmas obtidas após a resolução do problema 2 e estão apresentados na Figura 66 no Apêndice desta dissertação. Como é possível notar na Tabela 30, a melhor solução do problema 2, rodada 4, não trouxe a melhor solução para o problema 3, rodada 6. A locação obtida a partir da melhor solução para a primeira etapa é apresentada na Figura 51 através de uma sobreposição dos poços produtores e injetores.


Figura 51 – Disposição dos poços da melhor solução para o problema 3: produtores (à esquerda) e injetores (à direita).



Fonte: A autora (2022)

A Figura 52 mostra a distribuição ótima apresentada na Figura 51 com a identificação dos poços.

Figura 52 – Distribuição dos poços produtores e injetores da melhor solução para o problema 3.



Fonte: A autora (2022)

Assim como aconteceu nos outros casos estudados, a otimização com o uso do AG alterou todas as locações e vazões iniciais.

Os dados de entrada da etapa final para o problema 3 são resumidos na Tabela 19, incluindo as coordenadas que indicam o melhor posicionamento para os poços.

Tabela 19 – Valores de vazões em m³/dia e as coordenadas do caso base para o problema 3.


Poço	Ciclo de controle			Coordenadas	
	1	2	3	<i>i</i>	<i>j</i>
PROD1	93,90	76,17	40,91	54	11
PROD2	0,66	65,34	42,72	26	3
PROD3	11,33	45,36	12,68	57	14
PROD4	45,42	113,77	79,97	33	2
INJECT1	16,19	65,96	34,69	11	59
INJECT2	62,09	63,95	25,63	22	55
INJECT3	33,25	3,08	27,73	8	25
INJECT4	62,51	21,72	6,37	6	50
INJECT5	13,26	29,88	51,91	2	36
INJECT6	16,14	31,99	28,93	46	37
INJECT7	36,34	4,60	33,56	4	54
INJECT8	32,94	3,29	8,51	4	41

Fonte: A autora (2022)

Diferentemente do que foi visto no problema 1, onde não havia compatibilidade de VPLs entre as etapas sequenciais, os VPLs obtidos ao final da resolução do problema 2 são iguais aos dos casos utilizados como base (iniciais) no problema 3. Essa compatibilidade aconteceu, pois desde o início do problema 3 foram utilizados os mesmos três ciclos de controle estabelecidos para o problema 2.


O caso base utilizado para a etapa do SAO e vinculado à melhor solução obtida para o problema 3 é apresentado através dos seus gráficos de produção de líquidos em m³/dia e injeção de água em m³/dia na Figura 53 e na Figura 54, respectivamente. Eles representam o que foi obtido na rodada 6 após a etapa de otimização integrada com o AG, problema 2.

Figura 53 – Produção de líquidos (m^3/dia) no caso base do problema 3.



Fonte: A autora (2022)

Figura 54 – Injeção de água (m^3/dia) no caso base do problema 3.



Fonte: A autora (2022)

Ao final do processo de otimização de vazões para o problema 3, obteve-se os controles ótimos para produção e injeção em m^3/dia . Os controles da melhor solução, rodada 6, são apresentados na Tabela 20.

Tabela 20 – Valores de vazões em m³/dia da melhor solução para o problema 3.

Poço	Ciclo de controle		
	1	2	3
PROD1	106,45	50,10	46,30
PROD2	14,14	81,00	0,49
PROD3	8,60	33,34	36,20
PROD4	35,33	67,88	51,48
INJECT1	19,22	63,92	20,46
INJECT2	71,02	79,07	8,34
INJECT3	0,44	1,37	21,17
INJECT4	35,87	30,77	5,94
INJECT5	1,00	38,21	50,48
INJECT6	0,44	13,64	25,10
INJECT7	30,47	9,11	11,35
INJECT8	6,34	4,44	0,44

Fonte: A autora (2022)

Assim como foi feito para os problemas 1 e 2, os gráficos e análises feitas nesta seção estão relacionadas à melhor solução encontradas ao final da última etapa do problema 3. Devido a relação direta que há entre os problemas 2 e 3, podemos estabelecer um comparativo entre os seus respectivos resultados pós otimização. Através da Tabela 21 é vista a evolução do VPL diante do acréscimo da etapa onde é usada a técnica de otimização sequencial aproximada (SAO), metodologia complementar aplicada ao problema 3.

Tabela 21 – Comparativo entre os resultados estatísticos obtidos para os problemas 2 (AG_{int}) e 3 (AG_{int} + SAO).

Função VPL (10 ⁶ \$)	Nº de Otimizações	Melhor	Média	Pior	Desvio Padrão	Média do Nº de Simulações
AG _{int}	20	49.7853	46.5290	44.4949	1.6085	601
AG _{int} + SAO	20	51.5385	48.5768	45.7473	1.6817	1381

Fonte: A autora (2022)

A partir da Tabela 21 nota-se que há melhorias relacionadas ao melhor e pior resultados e em relação à média dos VPLs obtidos. O desvio padrão aumentou com a inclusão da etapa do SAO, no entanto essa diferença não é significativa.

A mesma análise realizada na Tabela 21 é resumida na Tabela 22 por meio de um comparativo percentual em relação ao caso base.


Tabela 22 – Comparativo entre os resultados estatísticos, em percentual, obtidos para os problemas 2 (AG_{int}) e 3 (AG_{int} + SAO).

Estratégia	Nº de Otimizações	Melhor Solução (%)	Média das Soluções (%)	Pior Solução (%)	Desvio Padrão (%)
AG _{int}	20	45.32	35.82	29.88	4.70
AG _{int} + SAO	20	50.44	41.80	33.54	4.91

Fonte: A autora (2022)

Essa evolução dos VPLs entre as soluções dos problemas 2 e 3 fica mais clara ainda quando se organiza tais resultados em um histograma comparativo. Na Figura 55, as barras azuis fazem referência às soluções do problema 2 onde as locações e as vazões dos poços foram otimizadas de maneira integrada através do AG. Ainda na Figura 55, as barras verdes representam os resultados complementares de otimização do problema 3 que adiciona o SAO ao processo iniciado no problema 2.

Figura 55 – Histograma com evolução do VPL após otimizações dos problemas 2 e 3.



Fonte: A autora (2022)

Como é possível perceber na Figura 55, as soluções referentes ao problema 2 se concentram mais à esquerda no histograma, portanto, com um menor VPL quando comparado aos resultados trazidos pela abordagem de solução do problema 3. Esta é uma boa maneira de perceber a eficiência do processo híbrido empregado aqui, visto que maiores VPLs foram obtidos, objetivo deste trabalho.

Como visto anteriormente na primeira etapa de resolução do problema 1, os resultados de VPL obtidos a partir somente da otimização da locação dos poços não foram suficientemente bons ao ponto de serem melhores do que as duas referências apresentadas,


(SILVA, 2019) utilizando CAPSO e (PINTO, 2020) utilizando SAO, que estudaram o problema de gerenciamento de vazões no reservatório *Egg Model*. Isso motivou a inclusão do estudo das vazões em conjunto com a locação de poços por meio de diferentes abordagens, conforme demonstrado nos problemas 1, 2 e 3.

A abordagem integrada com o AG (problema 2) apresentou um VPL muito próximo do que foi obtido a partir do otimizador CAPSO, com uma diferença de apenas 0,07% entre eles. Já a estratégia apresentada para o problema 3, AG_{int} + SAO, teve destaque ao demonstrar um ganho percentual de 3,44% em relação ao CAPSO. Todas essas observações reforçam a eficiência das abordagens aqui estudadas e demonstram que trabalhar com uma estratégia que solucione tanto os problemas de locação quanto os de vazão é bastante promissora, pois as soluções obtidas estão associadas a melhores VPLs.

Assim como foi percebido nas melhores soluções para os problemas 1 e 2, o parâmetro de água acumulada teve um peso significativo para a maximização do VPL no problema 3. Como visto anteriormente na descrição do problema 2, houve uma redução de 80,15% na água acumulada em relação ao caso base após o emprego da abordagem integrada através do AG, primeira etapa do problema 3. Esse valor chegou a 87,70% após o uso do SAO.

O óleo acumulado também sofreu uma pequena redução de 7,94% após a primeira etapa do processo de otimização (processo integrado com o AG). Posteriormente, com o emprego do SAO, houve uma recuperação e a diferença para o caso base (ponto de partida do problema 2), passou a ser de 6,19%. Essas informações podem ser observadas na Figura 56.


Figura 56 – Comparativo de óleo e água acumulados (m³) para o reservatório *Egg Model* no problema 3.



Fonte: A autora (2022)

Ainda sobre essa redução da água acumulada no reservatório, a Figura 57 traz um comparativo através dos mapas de saturação da água durante os dez anos de exploração do reservatório *Egg Model*, onde são apresentados os casos base, antes do emprego do AG, (Figura 57a) e otimizado (Figura 57b). É possível identificar que a área de maior saturação de água do reservatório é na região onde os poços injetores estão locados, justificando assim a baixa produção de água dos poços produtores.


Figura 57 – Saturação de água para o reservatório *Egg Model* para o problema 3.



Fonte: A autora (2022)

O comportamento individual dos poços produtores mostrado na Figura 58 também corrobora como a redução da produção de água foi significativa quando se compara o cenário ótimo com o caso base (antes do emprego do AG integrado e do SAO).


Figura 58 – Comparativo da produção acumulada de água (m^3/dia) entre os casos base e a melhor solução encontrada para o problema 3.



Fonte: A autora (2022)

O corte de água está atrelado a produção de água nos poços. Portanto, o retardo da produção de água é mais notável ainda na Figura 59 que trata do corte de água de cada poço.

Figura 59 – Comparativo do corte de água dos produtores para o caso base e para a melhor solução encontrada para o problema 3.




Fonte: A autora (2022)

É possível perceber que, no caso otimizado, essa produção começa apenas alguns anos depois do início da exploração do reservatório. Diferente do caso base que já apresenta, através do PROD2, uma curva ascendente logo no início de 2012.

A Tabela 21 trouxe a informação de que a melhor solução obtida para o problema 3 possui um VPL de $\$ 51.5385 \times 10^6$, representando uma melhoria de 50,44% em relação ao caso base, conforme visto na Tabela 22. Essa solução está associada aos controles de vazões apresentados na Figura 60 e na Figura 61.


Na Figura 60 é perceptível que apenas o poço PROD2 conseguiu seguir rigorosamente os controles máximos determinados pós otimização para a produção de líquidos.

Figura 60 – Produção de líquidos (m^3/dia) da melhor solução para o problema 3.



Fonte: A autora (2022)


Figura 61 – Injeção de água (m^3/dia) da melhor solução para o problema 3.



Fonte: A autora (2022)

Os outros poços (PROD1, PROD3 e PROD4) sofreram oscilações durante o segundo e ao final do terceiro ciclos. Essas situações tiveram influência direta das quedas de pressão que ocorreram pouco antes do início de 2014 e, mais significativamente, pouco tempo após a primeira metade de 2019, respectivamente, como pode ser observado na Figura 62.


Figura 62 – Pressão de fundo de poço (BHP) dos poços produtores na melhor solução para o problema 3.



Fonte: A autora (2022)

Por outro lado, a maioria dos poços injetores obedeceu aos controles máximos propostos e apresentados na Tabela 20. As exceções foram os poços INJECT1, que não conseguiu manter as vazões máximas estabelecidas nos segundo e terceiro ciclos, e INJECT 7 no último ciclo. Assim como ocorreu com os produtores, isso se deve à queda de pressão apresentada ao final de 2013 e após a primeira metade de 2019, *vide* Figura 63.

Figura 63 – Pressão de fundo de poço (BHP) dos poços injetores na melhor solução para o problema 3.




Fonte: A autora (2022)

A Figura 64 apresenta a saturação de óleo do reservatório nos casos base, pós otimização da locação e vazões através do AG e pós otimização das vazões com o uso do SAO. Assim como ocorreu no problema 1, é visto que ainda há óleo remanescente no

reservatório após a última etapa de otimização. É perceptível também que o caso base apresenta um maior aproveitamento na extração de óleo do reservatório. No entanto, o objetivo principal para todos os casos estudados neste trabalho é a maximização do VPL. Este foi objetivo atingido mesmo diante de uma redução no cenário de produção de óleo, especialmente por conta da redução da produção de água no reservatório.

Figura 64 – Saturação de óleo: (a) caso base, (b) solução da locação e vazões através de abordagem integrada com o AG e (c) solução final com acréscimo de etapa com o SAO.



Fonte: A autora (2022)

5.4 RESUMO DOS RESULTADOS

Os resultados estatísticos obtidos para todos os problemas estudados nesta dissertação estão resumidos na Tabela 23.

Tabela 23 – Resumo dos resultados estatísticos obtidos todos os problemas estudados.

Função VPL (10 ⁶ \$)	Nº de Otimizações	Melhor	Média	Pior	Desvio Padrão	Média do Nº de Simulações
Problema 01 (AG)	20	48.1440	42.2404	38.5398	2.7002	361
Problema 01 (AG + SAO)	18	50.0749	46.1872	41.9391	2.3498	1398
Problema 02 (AG _{int})	20	49.7853	46.5290	44.4949	1.6085	601
Problema 03 (AG _{int} + SAO)	20	51.5385	48.5768	45.7473	1.6817	1381

Fonte: A autora (2022)

6 OBSERVAÇÕES FINAIS

Este trabalho teve como objetivo desenvolver e apresentar metodologias que auxiliem na tomada de decisão a partir de soluções otimizadas para os problemas de posicionamento de poços e gerenciamento de vazões. Tais soluções foram apresentadas no capítulo anterior. A seguir são apresentadas as principais conclusões obtidas a partir dos estudos realizados neste trabalho e sugestões para trabalhos futuros.

6.1 CONCLUSÕES

Os resultados aqui obtidos mostraram que resolver o problema de posicionamento de poço e de gerenciamento de vazões simultaneamente ou, mesmo em etapas separadas, pode melhorar significativamente o valor presente líquido (VPL) do reservatório durante o desenvolvimento de campo.

As restrições aplicadas para o problema de posicionamento de poços no reservatório *Egg Model*, atividade dos blocos e distância entre poços, se mostram adequadas para reservatórios reais. Elas também adicionam complexidade ao reduzir a região viável de projeto e limitar o campo de distribuição de pontos através do LHS. Pelas características do reservatório e dos problemas estudados, optou-se pela utilização de modelos substitutos com o intuito de reduzir os custos computacionais envolvidos no processo de otimização.

As otimizações foram realizadas utilizando modelos substitutos (MS) criados a partir de funções de base radial cúbica. Para o processo de criação dos modelos substitutos foi implementada uma metodologia que se mostrou efetiva ao tratar as amostras visando atingir os percentuais de pontos viáveis definidos. Os MS foram enriquecidos por meio de um procedimento desenvolvido nesta dissertação, tal procedimento foi importante ao criar regiões em torno das respostas do otimizador e acelerou o processo de solução dos problemas aqui estudados.

As técnicas de manipulação de restrições, reparo de cromossomos e penalização adaptativa, foram importantes no processo de solução com o algoritmo genético (AG), pois permitiram que o otimizador pudesse atuar adequadamente e trazer respostas viáveis trabalhando com problemas restritos.

Todas as soluções do problema de locação de poços para o *Egg Model* modificaram o posicionamento estabelecido inicialmente. Foi observada uma tendência de dispor os poços em regiões mais periféricas do reservatório, afastando-os de regiões centrais que concentram zonas com canais de alta permeabilidade. Em alguns casos, foi notado também o

posicionamento dos grupos de poços injetores e produtores em regiões opostas. Essa situação possivelmente retardou o aparecimento e o avanço da água nos poços produtores.

A solução associada ao melhor VPL, entre todos os casos e abordagens estudados, incrementou o VPL em 50,44% em relação ao caso base. Uma outra característica importante foi observada em todos os casos estudados: a produção de água sofreu grandes reduções e foi o principal parâmetro para maximização do VPL e, por consequência, definição da melhor solução. Essa redução chegou a atingir 87,70% no último caso estudado (problema 3) e se deve, principalmente, à estratégia adotada para a recuperação de petróleo que ocasionou um declínio substancial da água produzida ao longo do tempo de exploração do reservatório.

Já a quantidade de óleo extraída do reservatório sofreu uma pequena redução nos casos otimizados. Sabe-se que este cenário não é ideal para a Indústria de Petróleo e Gás, pois um dos principais interesses da indústria é maximizar a recuperação de petróleo e não apenas aumentar o VPL do reservatório.

Observou-se que a abordagem híbrida que envolve o algoritmo genético integrado (AG_{int}) e a estratégia de otimização sequencial aproximada (SAO) conseguiu superar as outras duas abordagens tanto ao atingir valores mais altos de VPL, aumentando também o VPL médio, quanto ao apresentar um baixo desvio padrão para as 20 soluções encontradas. Essa abordagem híbrida pode estar associada a um custo computacional maior, onde sejam requeridas mais avaliações de função devido ao maior número de variáveis de projeto.

Diante do que foi relatado, as metodologias apresentadas se mostraram eficientes e satisfatórias para todas as execuções realizadas ao trazer soluções consistentes com melhorias significativas no VPL, objetivo principal deste trabalho.

6.2 SUGESTÕES PARA TRABALHOS FUTUROS

A partir do que foi desenvolvido e estudado, são apresentadas a seguir algumas sugestões que possam dar continuidade ao presente trabalho.

- Otimização envolvendo a localização de poços e vazões sob incertezas geológicas.
- Otimização multiobjetivo visando maximizar a produção acumulada de óleo e o valor presente líquido para os problemas de locação e vazão através de uma abordagem integrada utilizando algoritmos genéticos, semelhante ao caso 2 deste trabalho.
- Desenvolver novos procedimentos para a criação dos pontos a serem utilizados no processo de enriquecimento dos modelos substitutos durante a otimização.

- Incluir a definição de profundidade, quantidade e objetivos dos poços ao problema de locação acoplado com o problema de gerenciamento de vazões.
- Consideração de poços inteligentes.
- Acrescentar uma etapa de busca local para os estudos de locação de poços.
- Substituir ciclos de controles por polinômio.
- Trabalhar com mais ciclos de controle para verificar a influência do número de ciclos.

REFERÊNCIAS

AFONSO, S. M. B.; HOROWITZ, B.; WILLMERSDORF, R. B. Comparative study of surrogate models for engineering problems. p. 17, 2008.

AFONSO, S. M. B.; HOROWITZ, B.; OLIVEIRA, L. C. de. Hybrid multicriteria solutions for optimum reservoir management. In: FOURTH INTERNATIONAL CONFERENCE ON SOFT COMPUTING TECHNOLOGY IN CIVIL, STRUCTURAL AND ENVIRONMENTAL ENGINEERING, 40., 2015, Dubrovnik, Croácia. **Proceedings [...]**. Escócia: Civil-Comp Press, 2015.

ALEXANDROV, N. M. et al. A trust-region framework for managing the use of approximation models in optimization. **Structural Optimization**, v. 15, n. 1, p. 16–23, fev. 1998.

AMOUZGAR, K.; STRÖMBERG, N. Radial basis functions as surrogate models with a priori bias in comparison with a posteriori bias. **Structural and Multidisciplinary Optimization**, v. 55, n. 4, p. 1453–1469, set. 2016.

ANDRADE, E. DE F. et al. **Optimum well location and rates using genetic algorithms considering surrogates**. . Em: 26^a INTERNATIONAL CONGRESS OF MECHANICAL ENGINEERING (COBEM). 2021a.

ANDRADE, E. DE F. et al. **Well rates and location optimization considering genetic algorithms and surrogate models**. . Em: XLII IBERO-LATIN-AMERICAN CONGRESS ON COMPUTATIONAL METHODS IN ENGINEERING AND III PAN-AMERICAN CONGRESS ON COMPUTATIONAL MECHANICS (CILAMCE-PANACM). Rio de Janeiro, Brasil: 2021b.

ARIADJI, T. et al. A novel tool for designing well placements by combination of modified genetic algorithm and artificial neural network. **Journal of Petroleum Science and Engineering**, v. 122, p. 69–82, out. 2014.

AUDZE, P.; EGLAIS, V. New approach for planning out of experiments. v. 35, p. 104–107, 1977.

BABAEI, M.; PAN, I. Performance comparison of several response surface surrogate models and ensemble methods for water injection optimization under uncertainty. **Computers & Geosciences**, v. 91, p. 19–32, jun. 2016.

BANGERTH, W. et al. On optimization algorithms for the reservoir oil well placement problem. **Computational Geosciences**, v. 10, n. 3, p. 303–319, set. 2006.

BARBOSA, H. J. C.; LEMONGE, A. C. C. **An adaptive penalty scheme in genetic algorithms for constrained optimization problems**. . Em: PROCEEDINGS OF THE 4TH ANNUAL CONFERENCE ON GENETIC AND EVOLUTIONARY COMPUTATION. 2002.

BARBOSA, H. J. C.; LEMONGE, A. C. C.; BERNARDINO, H. S. A Critical Review of Adaptive Penalty Techniques in Evolutionary Computation. Em: DATTA, R.; DEB, K.

(Eds.). **Evolutionary Constrained Optimization**. Infosys Science Foundation Series. New Delhi: Springer India, 2015. p. 1–27.

BARTHELEMY, J.-F. M.; HAFTKA, R. T. Approximation concepts for optimum structural design — a review. **Structural Optimization**, v. 5, n. 3, p. 129–144, set. 1993.

BELLOUT, M. C. et al. Joint optimization of oil well placement and controls. **Computational Geosciences**, v. 16, n. 4, p. 1061–1079, set. 2012.

BHATTI, M. A. **Practical Optimization Methods: With Mathematica® Applications**. 1. ed. New York, NY: Springer Science & Business Media, 2000.

BOOR, C. DE; RON, A. Computational aspects of polynomial interpolation in several variables. v. 58, n. 198, p. 705–727, 1992.

BRINDLE, A. **Genetic algorithms for function optimization**. Doctoral dissertation and Technical Report TR81-2, Department of Computer Science—Edmonton: University of Alberta, 1980.

CHEN, G. et al. Global and Local Surrogate-Model-Assisted Differential Evolution for Waterflooding Production Optimization. **SPE Journal**, v. 25, n. 01, p. 105–118, 17 fev. 2020.

CHUNG, H.-S.; ALONSO, J. **Comparison of approximation models with merit functions for design optimization**. 8th Symposium on Multidisciplinary Analysis and Optimization. **Anais... Em: 8TH SYMPOSIUM ON MULTIDISCIPLINARY ANALYSIS AND OPTIMIZATION**. Long Beach, CA, U.S.A.: American Institute of Aeronautics and Astronautics, 6 set. 2000.

COMPUTER MODELLING GROUP LTD. **IMEX User Guide 2016.10: Three-phase, Blackoil Reservoir Simulator**.

DE JONG, K. A. **An analysis of the behavior of a class of genetic adaptive systems**. Doctoral dissertation and Technical Report 185, Computer and Communication Sciences Department—Ann Arbor: University of Michigan, 1975.

DEB, K.; GOLDBERG, D. E. **An Investigation of Niche and Species Formation in Genetic Function Optimization**. . Em: PROCEEDINGS OF THE THIRD INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS. J. David Schaffer, 1989.

DEEP, K. et al. A real coded genetic algorithm for solving integer and mixed integer optimization problems. **Applied Mathematics and Computation**, v. 212, n. 2, p. 505–518, jun. 2009.

DIMITROV, S.; DIMOV, I.; TODOROV, V. Latin Hypercube Sampling and Fibonacci Based Lattice Method Comparison for Computation of Multidimensional Integrals. Em: DIMOV, I.; FARAGÓ, I.; VULKOV, L. (Eds.). **Numerical Analysis and Its Applications**. Lecture Notes in Computer Science. Cham: Springer International Publishing, 2017. v. 10187p. 302–310.

DUARTE, N. M. et al. Accelerating Multi-Objective Control System Design Using a Neuro-Genetic Approach. **IFAC Proceedings Volumes**, v. 33, n. 24, p. 87–92, 2000.

ELDRED, M.; GIUNTA, A.; COLLIS, S. **Second-Order Corrections for Surrogate-Based Optimization with Model Hierarchies**. 10th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference. **Anais...** Em: 10TH AIAA/ISSMO MULTIDISCIPLINARY ANALYSIS AND OPTIMIZATION CONFERENCE. Albany, New York: American Institute of Aeronautics and Astronautics, 30 ago. 2004.

FOROUZANFAR, F.; POQUIOMA, W. E.; REYNOLDS, A. C. Simultaneous and Sequential Estimation of Optimal Placement and Controls of Wells With a Covariance Matrix Adaptation Algorithm. **SPE Journal**, v. 21, n. 02, p. 501–521, 14 abr. 2016.

FORRESTER, A. I. J.; SÓBESTER, A.; KEANE, A. J. **Engineering Design via Surrogate Modelling: A Practical Guide**. 1. ed. Chichester, United Kingdom: John Wiley & Sons Ltd, 2008.

GARRIDO, M. A. **Otimização da locação de poços em reservatório de petróleo**. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Civil—Recife, Brasil: Universidade Federal de Pernambuco (UFPE), 2019.

GIUNTA, A. **Use of data sampling, surrogate models, and numerical optimization in engineering design**. 40th AIAA Aerospace Sciences Meeting & Exhibit. **Anais...** Em: 40TH AIAA AEROSPACE SCIENCES MEETING & EXHIBIT. Reno,NV,U.S.A.: American Institute of Aeronautics and Astronautics, 14 jan. 2002.

GIUNTA, A.; ELDRED, M. **Implementation of a trust region model management strategy in the DAKOTA optimization toolkit**. 8th Symposium on Multidisciplinary Analysis and Optimization. **Anais...** Em: 8TH SYMPOSIUM ON MULTIDISCIPLINARY ANALYSIS AND OPTIMIZATION. Long Beach,CA,U.S.A.: American Institute of Aeronautics and Astronautics, 6 set. 2000.

GORISSEN, D. et al. A Surrogate Modeling and Adaptive Sampling Toolbox for Computer Based Design. n. 11, p. 2051–2055, 2010.

GUTMANN, H. M. A Radial Basis Function Method for Global Optimization. v. 19, n. 3, p. 201–227, 2001.

HARDY, R. L. Multiquadric equations of topography and other irregular surfaces. **Journal of Geophysical Research**, v. 76, n. 8, p. 1905–1915, 10 mar. 1971.

HOLLAND, J. H. Genetic Algorithms and Adaptation. Em: SELFRIDGE, O. G.; RISSLAND, E. L.; ARBIB, M. A. (Eds.). **Adaptive Control of Ill-Defined Systems**. Boston, MA: Springer US, 1984. p. 317–333.

HOROWITZ, B.; AFONSO, S. M. B.; DE MENDONÇA, C. V. P. Surrogate based optimal waterflooding management. **Journal of Petroleum Science and Engineering**, v. 112, p. 206–219, dez. 2013.

HUMPHRIES, T. D.; HAYNES, R. D.; JAMES, L. A. Simultaneous and sequential approaches to joint optimization of well placement and control. **Computational Geosciences**, v. 18, n. 3–4, p. 433–448, ago. 2014.

IEA. **Oil 2021 - Analysis and forecast to 2026**.

ISEBOR, O. J.; DURLOFSKY, L. J.; ECHEVERRÍA CIAURRI, D. A derivative-free methodology with local and global search for the constrained joint optimization of well locations and controls. **Computational Geosciences**, v. 18, n. 3–4, p. 463–482, ago. 2014.

JANSEN, J. D. et al. The egg model - a geological ensemble for reservoir simulation. **Geoscience Data Journal**, v. 1, n. 2, p. 192–195, nov. 2014.

JAROSZ, W. **Efficient Monte Carlo Methods for Light Transport in Scattering Media**. Ph.D. dissertation—San Diego, CA, USA: University of California San Diego (UCSD), 2008.

JONES, D. R. A Taxonomy of Global Optimization Methods Based on Response Surfaces. **A Taxonomy of Global Optimization Methods Based on Response Surfaces**, v. 21, p. 345–383, 2001.

KEANE, A. J.; NAIR, P. B. **Computational Approaches for Aerospace Design: The Pursuit of Excellence**. 1. ed. [s.l.] Wiley, 2005.

LEMONGE, A. C. C.; BARBOSA, H. J. C. An adaptive penalty scheme for genetic algorithms in structural optimization. **International Journal for Numerical Methods in Engineering**, v. 59, n. 5, p. 703–736, 7 fev. 2004.

LI, L.; JAFARPOUR, B. A variable-control well placement optimization for improved reservoir development. **Computational Geosciences**, v. 16, n. 4, p. 871–889, set. 2012.

LI, L.; JAFARPOUR, B.; MOHAMMAD-KHANINEZHAD, M. R. A simultaneous perturbation stochastic approximation algorithm for coupled well placement and control optimization under geologic uncertainty. **Computational Geosciences**, v. 17, n. 1, p. 167–188, fev. 2013.

LIMA, R.; ABREU, A. C.; PACHECO, M. A. **Optimization of Reservoir Development Plan Using the System OCTOPUS**. Day 3 Thu, October 29, 2015. **Anais...** Em: OTC BRASIL. Rio de Janeiro, Brazil: OTC, 27 out. 2015.

LU, R.; FOROUZANFAR, F.; REYNOLDS, A. C. **Bi-Objective Optimization of Well Placement and Controls Using StoSAG**. Day 1 Mon, February 20, 2017. **Anais...** Em: SPE RESERVOIR SIMULATION CONFERENCE. Montgomery, Texas, USA: SPE, 20 fev. 2017.

MATHWORKS, INC. Natick, Massachusetts: 2018.

MCKAY, M. D.; BECKMAN, R. J.; CONOVER, W. J. Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code. **Technometrics**, v. 21, n. 2, p. 239–245, maio 1979.

MICCHELLI, C. A. Interpolation of scattered data: Distance matrices and conditionally positive definite functions. v. *Constructive Approximation* 2, p. 11–22, 1986.

NING, A.; HICKEN, J. Multidisciplinary Design Optimization. **Multidisciplinary Design Optimization**, p. 269, 2017.

OLIVEIRA, D. F. B. **Técnicas de Otimização da Produção para Reservatórios de Petróleo: Abordagens Sem Uso de Derivadas para Alocação Dinâmica das Vazões de**

Produção e Injeção. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Civil—Recife, Brasil: Universidade Federal de Pernambuco (UFPE), 2006.

OLIVEIRA, L. C. DE. **Estratégia híbrida aplicada ao gerenciamento ótimo de reservatórios.** Tese de Doutorado, Programa de Pós-Graduação em Engenharia Civil—Recife, Brasil: Universidade Federal de Pernambuco (UFPE), 2013.

PETROLEUM, B. **British Petroleum Statistical Review of World Energy 2021.** London, England: 2021.

PETROLEUM, B. **British Petroleum Statistical Review of World Energy 2022.** London, England: 2022.

PHAM, D. T.; KARABOGA, D. **Intelligent Optimisation Techniques.** London: Springer London, 2000.

PIETROBOM, H. C. **Otimização utilizando funções substitutas e extração de regras difusas.** Tese de Doutorado, Divisão de Pós-Graduação em Engenharia Eletrônica e Computação—São José dos Campos, Brasil: Instituto Tecnológico de Aeronáutica (ITA), 2002.

PINTO, J. W. O. **Uso de otimização sequencial aproximada em problemas uni e multiobjetivos de gerenciamento de reservatórios.** Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Civil—Recife, Brasil: Universidade Federal de Pernambuco (UFPE), 2014.

PINTO, J. W. O. **Otimização robusta do controle de poços de reservatórios de petróleo utilizando modelo substituto.** Tese de Doutorado, Programa de Pós-Graduação em Engenharia Civil—Recife, Brasil: Universidade Federal de Pernambuco (UFPE), 2020.

POWELL, J. D. Radial basis function approximations to polynomials. p. 223–241, 1989.

RAJ, D. **Sampling Theory.** New York: McGraw-Hill, 1968.

REDOUANE, K.; ZERAIBI, N.; NAIT AMAR, M. Adaptive surrogate modeling with evolutionary algorithm for well placement optimization in fractured reservoirs. **Applied Soft Computing**, v. 80, p. 177–191, jul. 2019.

ROEVA, O.; FIDANOVA, S.; PAPRZYCKI, M. **Influence of the Population Size on the Genetic Algorithm Performance in Case of Cultivation Process Modelling.** . Em: CONFERENCE ON COMPUTER SCIENCE AND INFORMATION SYSTEMS (FEDCSIS). Kraków, Poland: 2013.

ROMERO, C. E. et al. **Improved Reservoir Characterization through Evolutionary Computation.** . Em: SPE ANNUAL TECHNICAL CONFERENCE. Dallas, Texas: 2000.

ROMERO, V. J. et al. Comparison of pure and “Latinized” centroidal Voronoi tessellation against various other statistical sampling methods. **Reliability Engineering & System Safety**, v. 91, n. 10–11, p. 1266–1280, out. 2006.

ROUSSOULY, N.; PETITJEAN, F.; SALAUN, M. A new adaptive response surface method for reliability analysis. **Probabilistic Engineering Mechanics**, v. 32, p. 103–115, 2013.

SALEHIAN, M.; SEFAT, M. H.; MURADOV, K. A Multisolution Optimization Framework for Well Placement and Control. **SPE Reservoir Evaluation & Engineering**, v. 24, n. 04, p. 923–939, 10 nov. 2021.

SATTER, A.; IQBAL, G. M. Reservoir engineering: the fundamentals, simulation, and management of conventional and unconventional recoveries. Gulf Professional Publishing, 2015.

SEIXAS, M. G. **Otimização Sequencial Aproximada aplicada a métodos de recuperação suplementar em reservatórios de petróleo**. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Civil—Recife, Brasil: Universidade Federal de Pernambuco (UFPE), 2010.

SILVA, H. V. C. **Método cooperativo assistido do enxame de partículas aplicado à otimização do controle das vazões dos poços em reservatórios de petróleo**. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Civil—Recife, Brasil: Universidade Federal de Pernambuco (UFPE), 2019.

SIMON, D. **Evolutionary Optimization Algorithms**. [s.l.] John Wiley & Sons, 2013.

SIMPSON, T. et al. **Design and Analysis of Computer Experiments in Multidisciplinary Design Optimization: A Review of How Far We Have Come - Or Not**. 12th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference. **Anais...** Em: 12TH AIAA/ISSMO MULTIDISCIPLINARY ANALYSIS AND OPTIMIZATION CONFERENCE. Victoria, British Columbia, Canada: American Institute of Aeronautics and Astronautics, 10 set. 2008.

SIRAJ, M. M.; VAN DEN HOF, P. M. J.; JANSEN, J. D. Handling risk of uncertainty in model-based production optimization: a robust hierarchical approach. **IFAC-PapersOnLine**, v. 48, n. 6, p. 248–253, 2015.

STOCKI, R. A method to improve design reliability using optimal latin hypercube sampling. v. 12, p. 393–411, 2005.

U.S. EIA. **Annual Energy Outlook 2022 (AEO2022)**. Washington, D.C., 2022.

VAN ESSEN, G. M.; ZANDVLIET, M. J.; JANSEN, J. D. Robust Waterflooding Optimization of Multiple Geological Scenarios. p. 202–210, 2009.

WANG, C. et al. An evaluation of adaptive surrogate modeling based optimization with two benchmark problems. **Environmental Modelling & Software**, v. 60, p. 167–179, out. 2014.

WANG, X. et al. Well control optimization using derivative-free algorithms and a multiscale approach. **Computers & Chemical Engineering**, v. 123, p. 12–33, abr. 2019.

WATSON, G. S. Smoothing and interpolation by kriging and with splines. **Journal of the International Association for Mathematical Geology**, v. 16, n. 6, p. 601–615, ago. 1984.

WHITLEY, D. **The Genitor Algorithm and Selection Pressure: Why Rank-Based Allocation of Reproductive Trials is Best**. . Em: PROCEEDINGS OF THE THIRD INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS. J. David Schaffer, 1989.

WU, C.-F.; HAMADA, M. **Experiments: planning, analysis, and optimization**. 2nd ed ed. Hoboken, N.J: Wiley, 2009.

ZANDVLIET, M. J. et al. Bang-bang control and singular arcs in reservoir flooding. **Journal of Petroleum Science and Engineering**, v. 58, n. 1–2, p. 186–200, ago. 2007.

ZANDVLIET, M. J.; HANDELS, M.; VAN ESSEN, G. M. Adjoint-Based Well-Placement Optimization Under Production Constraints. **SPE Journal**, p. 8, 2008.

ZHANG, H. et al. Construction and optimization of adaptive well pattern based on reservoir anisotropy and uncertainty. **Journal of Petroleum Science and Engineering**, v. 181, p. 106252, out. 2019.

ZHANG, L. et al. Production optimization for alternated separate-layer water injection in complex fault reservoirs. **Journal of Petroleum Science and Engineering**, v. 193, p. 107409, out. 2020.

ZHAO, M. et al. A surrogate-assisted multi-objective evolutionary algorithm with dimension-reduction for production optimization. **Journal of Petroleum Science and Engineering**, v. 192, p. 107192, set. 2020.

APÊNDICE A – PROBLEMAS 1, 2 E 3

A seguir são apresentadas informações complementares referentes aos problemas estudados nesta dissertação.

Conforme enfatizado nos problemas 1, 2 e 3, o processo de otimização alterou o posicionamento inicial do reservatório *Egg Model* (Figura 11) para todas as 20 rodadas.

Os resultados referentes a locação do problema 1 estão organizados na Tabela 24, Tabela 25 que trazem as coordenadas encontradas em cada rodada para os poços produtores e injetores, respectivamente. A Figura 65 traz a locação base e os posicionamentos otimizados obtidos para o problema 1, onde os pontos azuis representam os poços injetores e os vermelhos representam os produtores.

Tabela 24 – Coordenadas dos poços produtores obtidas na primeira parte do problema 1 (locação de poços).

PROBLEMA 1 - Coordenadas dos produtores								
Rodada	PROD01		PROD02		PROD03		PROD04	
	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>
base	16	43	35	40	23	16	43	48
01	58	6	20	17	16	4	19	56
02	6	56	38	17	53	4	28	53
03	54	28	5	30	22	55	55	22
04	52	4	16	7	28	53	12	57
05	15	38	37	36	47	5	7	53
06	57	5	11	6	53	29	31	52
07	23	48	17	6	51	8	2	21
08	25	3	20	54	11	59	31	52
09	17	5	6	48	36	32	55	26
10	52	4	2	46	19	57	3	23
11	25	45	41	2	4	43	55	10
12	46	16	50	34	7	37	12	59
13	48	3	37	48	11	59	57	5
14	7	44	9	13	53	30	46	39
15	5	56	24	12	10	25	28	39
16	35	15	52	13	10	7	14	49
17	55	26	8	55	14	17	31	44
18	20	56	7	57	41	2	13	5
19	5	54	54	25	8	44	24	55
20	8	32	20	53	57	18	49	3


Fonte: A autora (2022)

Tabela 25 – Coordenadas dos poços injetores obtidas na primeira parte do problema 1 (locação de poços).

PROBLEMA 1 - Coordenadas dos injetores																
Rodada	INJECT01		INJECT02		INJECT03		INJECT04		INJECT05		INJECT06		INJECT07		INJECT08	
	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>
base	5	57	30	53	2	35	27	29	50	35	8	9	32	2	57	6
01	13	41	48	36	41	2	33	2	43	41	57	15	39	27	39	23
02	44	40	57	9	5	50	54	28	2	37	3	26	8	11	7	31
03	21	31	21	24	37	3	24	40	10	7	42	45	20	14	4	18
04	9	8	47	29	30	24	4	27	51	9	58	7	36	36	20	7
05	16	12	16	58	12	26	36	46	42	21	11	59	13	54	16	4
06	8	14	45	10	3	22	3	45	22	41	45	30	23	3	29	32
07	27	7	4	49	57	15	14	57	57	8	28	3	43	41	8	58
08	17	30	39	41	51	30	53	4	2	32	12	29	8	9	55	26
09	58	10	26	53	3	22	32	22	49	9	6	12	30	50	17	9
10	10	58	36	33	57	16	14	33	16	38	23	13	51	30	58	6
11	20	10	48	32	39	47	16	4	54	18	10	58	44	38	29	53
12	31	24	35	50	25	31	19	4	41	45	13	11	55	24	28	2
13	32	51	28	18	8	9	16	56	12	6	42	45	53	29	2	29
14	28	33	26	39	25	51	50	14	56	5	30	2	27	5	3	26
15	57	17	4	52	19	31	21	47	8	32	53	30	58	6	33	51
16	58	6	48	5	17	58	5	51	36	45	6	31	5	55	57	12
17	46	39	48	3	25	37	50	24	10	59	7	10	41	44	16	23
18	35	48	44	42	56	6	49	30	54	27	46	38	43	25	15	25
19	14	8	5	18	10	11	41	9	58	7	38	6	34	49	18	18
20	11	51	5	17	37	2	6	57	58	6	54	8	37	35	23	3

Fonte: A autora (2022)

Figura 65 – Locação base e posicionamento otimizado dos poços para as 20 soluções do problema 1.



Fonte: A autora (2022)

Os resultados referentes a locação dos problemas 2 e 3 estão organizados na Tabela 26 e na Tabela 27 que trazem as coordenadas encontradas em cada rodada para os poços produtores e injetores, respectivamente. A Figura 66 traz a locação base e os posicionamentos otimizados obtidos para os problemas 2 e 3. Novamente, os pontos azuis fazem referência os poços injetores e os vermelhos aos produtores.

Tabela 26 – Coordenadas dos poços produtores obtidas nos problemas 2 e 3.

Rodada	PROBLEMAS 2 E 3 - Coordenadas dos produtores							
	PROD01		PROD02		PROD03		PROD04	
	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>
base	16	43	35	40	23	16	43	48
01	9	8	20	7	2	31	12	54
02	3	51	14	53	4	46	25	3
03	16	4	41	3	56	4	51	4
04	54	4	58	6	14	5	50	20
05	25	3	12	46	7	10	29	27
06	54	11	26	3	57	14	33	2
07	3	18	56	13	9	59	15	15
08	3	36	2	21	14	10	40	29
09	57	13	53	30	56	4	44	7
10	25	50	30	38	19	25	6	38
11	6	56	24	54	2	21	4	27
12	2	42	5	48	4	18	43	42
13	8	38	33	5	58	6	37	2
14	58	6	29	5	54	4	22	3
15	2	27	10	48	19	50	5	54
16	7	58	36	19	28	37	19	56
17	30	2	54	17	41	2	4	23
18	17	6	13	5	27	19	5	14
19	32	42	28	4	39	6	7	10
20	41	4	24	3	31	2	39	25


Fonte: A autora (2022)

Tabela 27 – Coordenadas dos poços injetores obtidas nos problemas 2 e 3.

PROBLEMAS 2 E 3 - Coordenadas dos injetores																
Rodada	INJECT01		INJECT02		INJECT03		INJECT04		INJECT05		INJECT06		INJECT07		INJECT08	
	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>	<i>i</i>	<i>j</i>
base	5	57	30	53	2	35	27	29	50	35	8	9	32	2	57	6
01	29	18	37	15	47	15	6	12	58	6	56	20	58	11	41	2
02	38	34	29	2	54	13	37	8	17	58	39	46	13	5	53	4
03	3	47	4	51	12	59	14	35	7	57	22	7	29	45	18	53
04	10	59	5	54	17	57	2	33	23	25	16	21	9	39	2	46
05	40	45	54	23	58	9	30	2	28	53	34	7	23	55	14	57
06	11	59	22	55	8	25	6	50	2	36	46	37	4	54	4	41
07	24	3	40	31	8	34	2	42	29	2	48	37	19	4	24	37
08	16	58	46	39	28	43	3	50	6	46	33	44	57	5	48	25
09	17	32	58	8	36	46	2	37	10	59	6	38	6	49	5	56
10	4	53	56	4	45	3	16	4	21	14	47	18	27	2	11	19
11	3	51	27	10	52	5	44	10	39	3	23	3	43	19	52	9
12	33	49	29	16	52	24	2	27	58	9	48	37	37	10	55	4
13	21	56	11	59	4	17	4	54	2	38	3	22	33	22	16	45
14	5	56	22	9	7	39	30	52	53	27	49	34	3	47	10	59
15	3	19	34	2	16	4	53	18	51	4	40	3	42	30	2	33
16	56	4	10	7	36	49	23	17	43	43	55	14	16	5	47	11
17	5	55	58	9	7	46	25	49	13	39	2	46	21	34	9	59
18	48	36	53	22	32	2	9	59	23	44	56	9	44	35	2	46
19	42	44	50	34	39	2	2	42	48	3	5	55	29	23	55	26
20	7	36	17	58	7	58	11	29	2	36	43	40	24	54	12	57

Fonte: A autora (2022)

Figura 66 – Locação base e posicionamento otimizado dos poços para as 20 soluções dos problemas 2 e 3.



Fonte: A autora (2022)

Tabela 28 – Resultados de VPL obtidos para o problema 1.

Problema 1 - Locação e vazão integradas (AG) + vazão (SAO)											
Etapa 1 - Locação de poços (AG)					Etapa 2 - Apenas vazão (SAO)					Resumo (AG + SAO)	
Rod.	VPL base (10e6 \$)	VPL ótimo (10e6 \$)	Melhoria em relação ao caso base (%)	Número de avaliações de função	VPL da etapa anterior (10e6 \$)	VPL ótimo (10e6 \$)	Melhoria em relação a etapa anterior (%)	Número de iterações	Número de avaliações de função	Melhoria total em relação ao caso base (%)	Número total de avaliações de função
1	28,5390	48,1440	68,70	361	35,7770	50,0749	4,01	19	1407	75,46	1768
2	28,5390	45,4860	59,38	361	45,0000	49,1430	8,04	10	741	72,20	1102
3	28,5390	39,0622	36,87	361	36,0180	44,8746	14,88	15	1111	57,24	1472
4	28,5390	46,7022	63,64	361	30,8060	48,1726	3,15	20	1481	68,80	1842
5	28,5390	41,0651	43,89	361	39,7450	44,5187	8,41	7	519	55,99	880
6	28,5390	40,1103	40,55	361	28,2990	41,9391	4,56	20	1481	46,95	1842
7	28,5390	42,3688	48,46	361	30,6500	42,7412	0,88	20	1481	49,76	1842
8	28,5390	46,1832	61,82	361	42,5650	49,6464	7,50	8	593	73,96	954
9	28,5390	39,1532	37,19	361	30,9430	45,7231	16,78	20	1481	60,21	1842
10	28,5390	43,0480	50,84	361	35,4010	35,4008	-17,76	4	297	24,04	658
11	28,5390	40,7348	42,73	361	28,4040	46,4326	13,99	20	1481	62,70	1842
12	28,5390	41,2337	44,48	361	38,3080	46,5251	12,83	8	593	63,02	954
13	28,5390	43,0078	50,70	361	38,8950	48,5489	12,88	15	1111	70,11	1472
14	28,5390	39,0426	36,80	361	34,4030	44,3248	13,53	10	741	55,31	1102
15	28,5390	38,5398	35,04	361	30,3400	46,6410	21,02	20	1481	63,43	1842
16	28,5390	43,2703	51,62	361	39,5420	43,5124	0,56	6	445	52,47	806
17	28,5390	40,9534	43,50	361	32,5810	36,2463	-11,49	7	519	27,01	880
18	28,5390	40,2556	41,05	361	43,8490	48,5502	20,60	14	1037	70,12	1398
19	28,5390	42,1330	47,63	361	32,8790	45,0009	6,81	6	445	57,68	806
20	28,5390	44,3150	55,28	361	34,0570	44,9997	1,54	14	1037	57,68	1398

Fonte: A autora (2022)

Tabela 29 – Resultados de VPL obtidos para o problema 2.

Problema 2 - Locação e vazão integradas (AG_{int})				
Rodada	VPL base (10e6 \$)	VPL ótimo (10e6 \$)	Melhoria da solução em relação ao caso base (%)	Número de avaliações de função
1	34,2583	45,9677	34,18	601
2	34,2583	46,5428	35,86	601
3	34,2583	48,3742	41,20	601
4	34,2583	49,7853	45,32	601
5	34,2583	46,1079	34,59	601
6	34,2583	48,7549	42,32	601
7	34,2583	45,1717	31,86	601
8	34,2583	44,5811	30,13	601
9	34,2583	48,7363	42,26	601
10	34,2583	45,8572	33,86	601
11	34,2583	46,3147	35,19	601
12	34,2583	46,9690	37,10	601
13	34,2583	44,5301	29,98	601
14	34,2583	49,0566	43,20	601
15	34,2583	44,9814	31,30	601
16	34,2583	45,2765	32,16	601
17	34,2583	47,2458	37,91	601
18	34,2583	44,4949	29,88	601
19	34,2583	45,0971	31,64	601
20	34,2583	46,7341	36,42	601

Fonte: A autora (2022)

Tabela 30 – Resultados de VPL obtidos para o problema 3.

Problema 3 - Locação e vazão integradas (AG _{int}) + vazão (SAO)											
Etapa 1 - Locação e vazão integradas (AG _{int})					Etapa 2 - Apenas vazão (SAO)					Resumo (AG _{int} + SAO)	
Rod.	VPL base (10e6 \$)	VPL ótimo (10e6 \$)	Melhoria em relação ao caso base (%)	Número de avaliações de função	VPL da etapa anterior (10e6 \$)	VPL ótimo (10e6 \$)	Melhoria em relação a etapa anterior (%)	Número de iterações	Número de avaliações de função	Melhoria total em relação ao caso base (%)	Número total de avaliações de função
1	34,2583	45,9677	34,18	601	45,9677	48,9865	6,57	15	1111	42,99	1712
2	34,2583	46,5428	35,86	601	46,5428	49,7203	6,83	20	1481	45,13	2082
3	34,2583	48,3742	41,20	601	48,3742	51,5073	6,48	18	1333	50,35	1934
4	34,2583	49,7853	45,32	601	49,7853	50,0386	0,51	6	445	46,06	1046
5	34,2583	46,1079	34,59	601	46,1079	47,7585	3,58	6	445	39,41	1046
6	34,2583	48,7549	42,32	601	48,7549	51,5385	5,71	12	889	50,44	1490
7	34,2583	45,1717	31,86	601	45,1717	48,4791	7,32	7	519	41,51	1120
8	34,2583	44,5811	30,13	601	44,5811	46,6436	4,63	8	593	36,15	1194
9	34,2583	48,7363	42,26	601	48,7363	49,6669	1,91	7	519	44,98	1120
10	34,2583	45,8572	33,86	601	45,8572	46,5647	1,54	5	571	35,92	1172
11	34,2583	46,3147	35,19	601	46,3147	49,6284	7,15	7	519	44,87	1120
12	34,2583	46,9690	37,10	601	46,9690	47,5096	1,15	10	741	38,68	1342
13	34,2583	44,5301	29,98	601	44,5301	47,2134	6,03	20	1481	37,82	2082
14	34,2583	49,0566	43,20	601	49,0566	49,8961	1,71	7	519	45,65	1120
15	34,2583	44,9814	31,30	601	44,9814	45,7473	1,70	7	519	33,54	1120
16	34,2583	45,2765	32,16	601	45,2765	46,3702	2,42	6	445	35,35	1046
17	34,2583	47,2458	37,91	601	47,2458	50,8241	7,57	10	741	48,36	1342
18	34,2583	44,4949	29,88	601	44,4949	47,5936	6,96	13	963	38,93	1564
19	34,2583	45,0971	31,64	601	45,0971	47,5064	5,34	12	889	38,67	1490
20	34,2583	46,7341	36,42	601	46,7341	48,3433	3,44	12	889	41,11	1490

Fonte: A autora (2022)