

## OTIMIZAÇÃO DA LOCAÇÃO DE POÇOS EM RESERVATÓRIOS DE PETRÓLEO UTILIZANDO MODELOS SUBSTITUTOS E ALGORITMOS GENÉTICOS

**Matheus Alves Garrido**

**Silvana M. B. Afonso**

**Leonardo Correia de Oliveira**

*matheus.agarrido@gmail.com*

*smb@ufpe.br*

*Leonardo.cdo@gmail.com*

*Universidade Federal de Pernambuco*

*Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE, 50670-901, Pernambuco, Brasil*

**Resumo.** O desenvolvimento de um reservatório de petróleo envolve diversas variáveis, sendo o seu desempenho altamente dependente de escolhas ótimas por parte de seus operadores. Dentre aquelas, se destaca a localização de poços, visando um maior varrido do fluido de interesse e menor produção de água durante a vida produtiva do campo. O objetivo deste trabalho é maximizar o valor presente líquido (VPL) de um modelo sintético de reservatório, através da locação de seus poços produtores e injetores. Para tanto, utilizou-se o algoritmo genético (GA) na otimização da função objetivo (VPL) acoplado a um simulador comercial, que fornece as curvas de produção de óleo e água do modelo. Foi verificado um aumento de 60% no valor presente líquido em comparação ao caso base, devido, principalmente, a redução da produção de água. O cenário otimizado apresentou diferentes posições para todos os poços, daquelas propostas inicialmente pelo operador, ressaltando a robustez do GA no auxílio de tomada de decisões.

**Palavras-chave:** Locação de poços, Algoritmo Genético, Otimização.

**Abstract.** The development project of a reservoir involves many different variables, and its performance is strongly correlated function of the optimized choices from the operators. Among them, it is worth highlighting the well placement in the increasement of the recovery factor of the fluid of interest, while providing low water production during the well lifetime. The purpose of this study is to maximize the Net Present Value (NPV) of a reservoir's synthetic model through managing the production and injection well placement. In order to accomplish that, it was used a genetic algorithm (GA) for the optimization of the objective function (NPV) coupled with a comercial simulator, which provided oil and water production curves of the model. It was verified an increase of 60% of the net present value when compared to its case model, as consequence of, mainly, the decrease of water production. The optimized scenario case displayed a different well placement in comparison to what was initially proposed by the operators, highlighting the aspect of relevance of the GA in the decision making process of the reservoir development project.

**Keywords:** Well Placement, Genetic algorithm, Optimization.

## 1 Introdução

O alto nível de investimento associado ao desenvolvimento e à operação de um reservatório, torna o gerenciamento de tarefas muito complexo, onde pequenos erros podem causar imensas perdas. Neste contexto, uma boa tomada de decisão é crucial, fazendo com que os profissionais do setor busquem incessantemente por decisões ótimas [1].

A aquisição de dados pode ser considerada como a primeira etapa do processo de modelagem do reservatório. Nesta fase, os dados necessários devem ser coletados e tratados. Alguns dos dados que podem ser reunidos incluem estudos de afloramentos, sísmica 2D e 3D, experimentos PVT em laboratório e testes de poços. Depois, um modelo estrutural e geológico do reservatório, que representa as grandes falhas e horizontes, é criado por meio dos dados adquiridos. Este modelo é desenvolvido usando interpretações dos dados sísmicos confrontados com os dados de *logging* dos poços. Nesta fase, os limites do reservatório e diferentes geometrias dele são especificadas no modelo. Em seguida, o modelo dinâmico do reservatório é completado pela adição de dados dinâmicos e propriedades dos fluidos. Conhecendo tais características e propriedades, o plano de desenvolvimento do campo deve ser determinado. Finalmente, o estudo técnico e as considerações econômicas do cenário de desenvolvimento, como a locação dos poços, são definidos [2].

A otimização da locação de poços é um aspecto estratégico para um projeto de exploração e desenvolvimento (E&P) de um campo, uma vez que, afeta a sua vida produtiva. Neste ponto de vista, otimizar a E&P em engenharia de reservatório significa desenvolver uma metodologia para aumentar a recuperação de hidrocarbonetos e o valor presente líquido (VPL), respeitando limitações físicas e econômicas. O VPL é responsável pela receita associada ao petróleo produzido, bem como, pelos custos de perfuração e do manuseio de água ocorridos durante a produção (injeção e separação).

A locação dos poços é um problema complexo devido ao grande número de variáveis de decisão, não-linearidade da resposta do reservatório, e as restrições de alocação de poços. Uma série de pesquisas tem sido desenvolvidas sobre este tema, a maioria destas utilizando otimizadores acoplados a simulação de reservatórios e modelos econômicos. Dentre as quais, pode-se citar Bittencourt e Horner [3] que aplicou um GA híbrido combinado ao método *polytope*, para a localização de 33 poços verticais e horizontais, sendo eles produtores e injetores. Os efeitos dos parâmetros internos sobre o desempenho do GA na otimização da alocação de poços foram analisados por Montes et al. [4]. Ozdogan et al. [5] introduziu na otimização de posicionamento de poços restrições geométricas, considerando formas não uniforme de reservatório. Emerick et al. [6] apresentou o desenvolvimento de uma ferramenta de otimização eficiente auxiliada por computador, para lidar com problemas de alocação de poços, com restrições lineares e não-lineares. As aplicações desta ferramenta em campos reais são mostradas em Lima et al. [1].

No presente trabalho foi empregado o Algoritmo Genético (GA), apresentado pela primeira vez por Holland em 1975 [7] na otimização de problemas complexos da engenharia de reservatórios. O algoritmo se baseia na teoria da evolução natural e genética, combinando conceitos de sobrevivência dos indivíduos mais aptos e seletividade aleatória.

O processo de evolução começa com a criação aleatória de indivíduos para formar uma população inicial. Os novos indivíduos são inseridos na população, removendo os indivíduos menos aptos das gerações prévias. A nova população é, então, avaliada e o ciclo (avaliação, evolução) é reiniciado. A condição de parada é baseado no número máximo de gerações.

## 2 Declaração do problema

Os ambientes, as áreas de trabalho e as condições nas quais os campos de petróleo e gás estão sendo descobertos são muito complexos e desafiadores. Além de que os campos existentes estão se tornando cada vez mais esgotados e, portanto, mais marginais. A menos que haja maneiras para otimizar sua produtividade e para tomar ações corretivas, seria difícil justificar economicamente o investimento para produzir esses campos [8]. Por outro lado, novas descobertas também precisam de um gerenciamento de produção ideal para ser economicamente viável. Uma das etapas mais onerosas ao processo de

desenvolvimento de um campo é a perfuração dos poços produtores e injetores.

O problema de locação de poços abordado neste trabalho visa a maximização do valor presente líquido do campo, com a otimização não somente da locação de poços, sendo, portanto, as variáveis de produção controladas em níveis máximos. Os problemas aqui tratados apresentam restrições, impostas pelos limites das coordenadas espaciais do reservatório e pelas distâncias mínimas entre poços ( $D_{w_{min}}$ ), e também, pela própria forma de manuseio das variáveis, que devem pertencer ao domínio dos números inteiros.

A função avaliadora do desempenho da metodologia proposta neste trabalho, leva em consideração o fluxo de caixa das entradas (produção de óleo) e saídas (despesas de perfuração e manuseio da água do campo), ao longo do tempo de concessão exploratória do reservatório.

$$\begin{aligned}
& \text{Maximize}_x \quad f_{obj}(\vec{x}) = VPL(\vec{x}) \\
& \text{Sujeito a} \quad x_i^l \leq x_{i,w} \leq x_i^u, \quad x_{i,w} = 1, 2, \dots, cell_i, \\
& \quad \quad \quad x_j^l \leq x_{j,w} \leq x_j^u, \quad x_{j,w} = 1, 2, \dots, cell_j, \\
& \quad \quad \quad ||(\vec{x}_w, \vec{x}_{w'})|| \geq D_{w_{min}} \quad w = 1, \dots, N_w, \quad w' = 1, \dots, N_w \text{ e } w' \neq w,
\end{aligned} \tag{1}$$

sendo  $\vec{x} = [\vec{x}_1, \vec{x}_2, \dots, \vec{x}_w, \dots, \vec{x}_{N_w}]$ , onde  $\vec{x}_w = [x_{i,w}, x_{j,w}]$  representa as informações sobre o poço  $w$ ,  $N_w$  é o número total de poços locados no reservatório (injetores e produtores),  $x_{i,w}$  e  $x_{j,w}$  definem a posição do bloco na malha onde o poço está localizado,  $cell_i$  e  $cell_j$  são, respectivamente, o número máximo de blocos nas direções  $i$  e  $j$  da malha do reservatório, e  $D_{w_{min}}$  é uma constante que estabelece a distância mínima euclidiana entre o poço  $\vec{x}_w$  e  $\vec{x}_{w'}$  qualquer.

Como neste trabalho a produção se dá em um único ciclo de controle, ou seja, ao longo do tempo de concessão do campo, a função VPL pode ser escrita como:

$$VPL(\vec{x}) = f_{obj}(\vec{x}) = \frac{1}{(1+d)^{\tau_t}} F(\vec{x}), \tag{2}$$

sendo  $d$  a taxa de desconto, e  $\tau_t$  o tempo do  $t$ -ésimo ciclo de controle.

O termo de fluxo de caixa, dado por  $F(\vec{x})$  representa o balanço financeiro entre o faturamento pela venda do óleo e as despesas com a perfuração, produção e injeção de água, e é dado por:

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

sendo  $\Delta\tau_t$  o intervalo de tempo do  $t$ -ésimo ciclo de controle, aqui, igual ao tempo de concessão do campo,  $r_o$  preço do petróleo,  $c_w$  e  $c_{wi}$  os custos com água produzida e injetada, respectivamente. As variáveis  $q_{p,t}^o$  e  $q_{p,t}^w$  correspondem, respectivamente, às vazões de produção de óleo e água no poço  $p$ , durante o tempo de concessão  $t$  (ciclo de controle único). Na Equação 3,  $C_d$  representa os custos de perfuração e completção dos poços de produção e injeção, expressado matematicamente pela Eq. (4):

$$C_d = \sum_{w=1}^{N_w} [c_t + c_{zflow}] + \sum_{p=1}^{N_p} c_{w,p} + \sum_{I=1}^{N_i} c_{w,i}, \tag{4}$$

sendo  $N_w$  o número total de poços locados no campo,  $c_{zflow}$  os custos ligados ao canhoneio das zonas de cada poço,  $N_p$  e  $N_i$  o número de poços produtores e injetores, respectivamente, e  $c_{w,p}$  e  $c_{w,i}$  os custos ligados a perfuração dos poços produtores e injetores, respectivamente. Finalmente na Eq. (4),  $c_t$  representa o custo relativo à profundidade do poço e pode ser expressado através da Eq. (5) [9]:

$$c_t = A \cdot \sum_{w=1}^{N_w} \Delta Z_w, \tag{5}$$

sendo  $A$  uma constante específica do campo para valores de conversão e  $\Delta Z_w$  o somatório das profundidades das células que cada poço  $w$  atravessa. Os valores dos parâmetros para o cálculo dos custos relacionados a perfuração dos poços são apresentados na Eq. (6).

$$\begin{aligned} c_{zflow} &= 0.07 \cdot c_t, \\ c_{w,p} &= 0.01 \cdot (c_t + c_{zflow}), \\ c_{w,i} &= 0.02 \cdot (c_t + c_{zflow}). \end{aligned} \quad (6)$$

### 3 Modelo substituto

A otimização de um sistema complexo, como o baseado na simulação numérica de um reservatório, pode ser muito demorada e dispendiosa, devido às frequentes execuções exigidas do simulador. A utilização de modelos substitutos leva a uma redução significativa no tempo computacional. Tais modelos serão portanto operados nas múltiplas chamadas de função requeridas pelo otimizador.

Os metamodelos podem ser enquadrados em duas categorias [10], os modelos funcionais e os modelos físicos:

**Modelos funcionais:** A aproximação da função real é obtida pela interpolação de valores conhecidos da função objetivo em pontos específicos ou amostras. A maioria destes modelos visa interpolar, sob certas condições, os dados fornecidos, resultando frequentemente em modelos de custo computacional bastante baixo. Os métodos mais conhecidos são os que se baseiam-se no emprego de funções de base radial, krigagem, redes neurais, e mais recentemente, o sistema de máquinas de vetores de suporte.

**Modelos Físicos:** são esquemas baseados no conhecimento das equações físicas governantes do problema, envolvendo a solução numérica de equações diferenciais ou integrais simplificadas.

Neste trabalho será utilizado um modelo da categoria funcional, utilizando as funções de base radial, na abordagem global, isto é que cobre todo o espaço de projeto.

O primeiro passo na construção do modelo substituto funcional é projetar os pontos de amostragem no espaço de projeto, que podem ser realizados usando técnicas de projeto de experimentos (*Design of Experiments* (DoE)) [11] [12]. A amostragem hipercubo latino (LHS) [13] é a técnica DoE usada aqui.

O segundo passo é a escolha de um interpolador. A Função de Base Radial (*Radial Basis Function* - RBF), aqui considerada é um método para aproximar funções multivariadas em termos de funções mais básicas, com propriedades conhecidas e análise mais fácil [13]. Seja uma Função de Base Radial (RBF) da forma [14]:

$$\hat{f}(\vec{x}) = p(\vec{x}) + \sum_{i=1}^m \lambda_i \phi(\|\vec{x} - \vec{x}_i\|), \quad \vec{x} \in \mathbb{R}^m, \quad (7)$$

sendo  $\vec{x}_i$  os  $i$ -ésimos centros de função da base  $m$ , que é uma função real avaliada, chamada de função básica. Os coeficientes,  $\lambda_i$ , para  $i = 1, \dots, m$ , são números reais, e a norma  $\|\vec{x} - \vec{x}_i\|$  é a euclidiana em  $\mathbb{R}^m$ ,  $p$  é uma função polinomial de baixo grau, tipicamente linear. Uma RBF consiste de uma soma ponderada de uma função básica radialmente simétrica  $\phi$  localizada nos centros,  $\vec{x}_i$  e um polinômio de baixo grau  $p$ .

A função básica, neste contexto, é uma função real positiva  $r$ , igual à distância (raio) à origem. As escolhas populares para esta função são:

- Linear :  $\phi(r) = r$ .
- Cúbico :  $\phi(r) = r^3$ .
- Spline de placa fina :  $\phi(r) = r^2 \ln(r)$ .

O interpolante RBF,  $\hat{f}(\vec{x})$ , é definido pelos coeficientes do polinômio  $p$  e pelos pesos  $\lambda_i$ . Dados os valores de interpolação  $y^1, \dots, y^m$ , o objetivo é encontrar os pesos  $\lambda_i$  para que a RBF satisfaça a Eq. (8):

$$\hat{f}(\vec{x}^{(i)}) = y^{(i)}, \quad i = 1, \dots, m. \quad (8)$$

Uma vez que esta equação fornece um sistema subdeterminado, isto é, existem mais parâmetros que dados, condições de ortogonalidade ou condições laterais dadas pela Eq. (9) são adicionalmente impostas aos coeficientes  $\lambda = (\lambda_1, \dots, \lambda_m)^T$ .

$$\sum_{i=1}^m \lambda_i \pi(\vec{x}_i) = 0. \quad (9)$$

Seja  $[\pi_1(\vec{x}), \dots, \pi_l(\vec{x})]$  uma base para polinômios de grau no máximo  $k$  e suponha  $\mathbf{c} = [c_1, \dots, c_l]$  ser os coeficientes que dão  $\pi$  em termos desta base. Então as Eq. (7) e Eq. (9) podem ser agrupadas na forma matricial como:

$$\begin{bmatrix} A & P \\ P^T & O \end{bmatrix} \begin{bmatrix} \lambda \\ \mathbf{c} \end{bmatrix} = \begin{bmatrix} F \\ 0 \end{bmatrix}, \quad (10)$$

onde  $A_{i,j} = \pi(\|\vec{x}_i\|)$ ,  $i, j = 1, \dots, m$  e  $P_{i,j} = \pi_j(\vec{x}_i)$ ,  $i = 1, \dots, m$ ,  $j = 1, \dots, l$ . Ao resolver este sistema linear de equações,  $\lambda$  e  $\mathbf{c}$  são determinados e, portanto,  $\hat{f}$  é obtida.

## 4 Algoritmo genético

Os princípios do GA são baseados nos estudos de Darwin acerca do processo de evolução: indivíduos que se adaptam melhor ao ambiente onde vivem apresentam mais chance de se reproduzir e competir por alimentos. Nesse processo, a seleção natural governa as próximas gerações. Darwin também notou que as modificações na mutação dos fenótipos afeta a performance dos indivíduos no meio. Assim, a evolução natural pode ser comparada ao problema de otimização, cujo objetivo é melhor adaptar as espécies ao seu meio.

### 4.1 Algoritmo básico

Em um Algoritmo Genético (GA), a evolução geralmente se inicia a partir de um conjunto de soluções criado aleatoriamente e é realizada por meio de gerações. A cada geração, a aptidão de cada solução na população é avaliada, alguns indivíduos são selecionados para a próxima geração e recombinados ou sofrem mutação para formar uma nova população. A nova população então é utilizada como entrada para a próxima iteração do algoritmo. Geralmente, o GA termina quando o máximo número de gerações ou uma tolerância pré-estabelecida for atingida [15].

Em geral, um GA tem basicamente cinco componentes, como listados [16]:

- Representação genética das soluções do problema;
- Procedimento para criar a população inicial;
- Função de evolução que classifique as soluções em função de sua aptidão;
- Operadores genéticos responsáveis pela composição genética dos filhos (possíveis soluções) durante a reprodução;
- Valores dos parâmetros do GA.

O algoritmo básico do GA segue o esquema:

1. Criação da população inicial de forma randômica no espaço de projeto.
2. Avaliação da função aptidão de cada indivíduo.
3. Seleção dos indivíduos que serão admitidos como "genitores", baseado no valor da sua função aptidão.
4. Criação da nova população através do cruzamento e/ou mutação dos membros selecionados.
5. Verificação da convergência. Caso ocorra, o processo é interrompido, caso não, retorna ao passo 2.

O desenvolvimento deste trabalho foi conduzido através do GA implementado na *toolbox* de otimização global do MATLAB [17]. A *toolbox* de otimização global dessa plataforma contém o GA empregado nos estudos.

Os algoritmos evolucionários nas formas padrão, em geral, lidam apenas com problemas irrestritos. Algumas técnicas tem sido desenvolvidas para contornar essa dificuldade. Na maioria das aplicações do GA que envolvem restrições tem sido aplicado o método de penalização de funções. Neste trabalho foi estudado o uso do método da penalização adaptativa [18], que utiliza informação da população que está sendo avaliada e não requer que o usuário introduza nenhum parâmetro adicional.

Embora o GA seja uma ferramenta para problemas irrestritos, a versão do MATLAB tem um procedimento interno para lidar com restrições [17]. O GA desta plataforma também é capaz de lidar com variáveis inteiras. Isto é um requisito necessário para a solução do problema de locação de poços tratado neste trabalho, uma vez que, para um esquema *block centered*, buscam-se as identificações das locações espacialmente ótimas  $(x,y)$  dos blocos da malha.

## 4.2 Método de penalização adaptativa (APM)

O método de penalização adaptativa (APM) [18] foi desenvolvido para aplicação em problemas restritos. Os coeficientes de penalização são adaptados a cada iteração a partir da leitura de informações da população. A função aptidão é definida na Eq. (11):

$$F(\vec{x}) = \begin{cases} f(\vec{x}) & \text{se } \vec{x} \text{ é viável,} \\ \bar{f}(\vec{x}) + \sum_{j=1}^m \lambda_j v_j(\vec{x}) & \text{caso contrário} \end{cases}, \quad (11)$$

sendo:

$$\bar{f}(\vec{x}) = \begin{cases} f(\vec{x}) & \text{se } f(\vec{x}) > \langle f(\vec{x}) \rangle, \\ \langle f(\vec{x}) \rangle & \text{caso contrário} \end{cases}. \quad (12)$$

Na Eq. (12),  $\langle f(\vec{x}) \rangle$  é a média de valores da função objetivo da população atual. O parâmetro de penalização  $\lambda_i$  é definido pela Eq. (14). Neste trabalho, é realizada uma adaptação a metodologia de penalização proposta em [19]. A quantidade de violações,  $v_j$ , aqui é dada por:

$$v_j(\vec{x}) = \frac{\max\{0, g_j(\vec{x})\}}{2}, \quad (13)$$

tal divisão é realizada devido a simetria da matriz de distâncias. O parâmetro de penalidade  $\lambda_i$  é dado por:

$$\lambda_i = \frac{1}{N_w}, \quad (14)$$

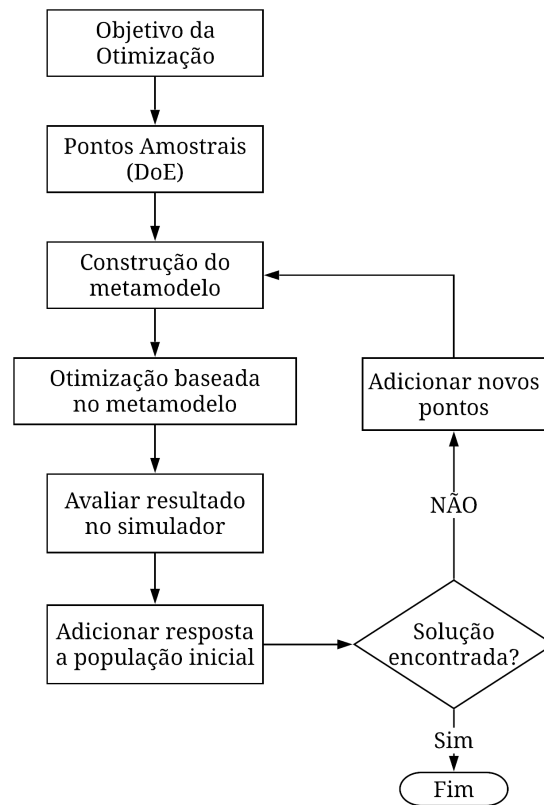
sendo  $N_w$  o número de poços.

## 4.3 Procedimento de otimização utilizando metamodelos

As variáveis de projeto e seus respectivos valores calculados na função real (simulação numérica), neste trabalho, no simulador de fluxo comercial (*black-box*) integram as entradas para construção do modelo substituto. Que uma vez treinado adequadamente, pela escolha de um modelo de regressão, atuará como a superfície de resposta utilizada pelo otimizador (GA), tonando as suas avaliações menos custosas, viabilizando aqui a solução do problema de locação de poços.

No contexto da solução via o GA o modelo substituto varia ao longo das gerações (processo adaptativo). O procedimento básico para otimização utilizando modelo substituto é mostrado na Fig. 1, e corresponde a etapa de escolha da variável, associada à sua importância para a função objetivo, geração de amostra, aqui escolhido o hipercubo latino (LHS - *Latin Hypercube Sampling*), escolha do modelo substituto, neste trabalho adota-se as Funções de Base Radial (RBF) cúbica e construção do preditor. Este é aplicado ao otimizador (GA). Através de uma ferramenta que utiliza tais esquemas, ao final de cada geração uma busca é feita por novos pontos e em seguida, o modelo é refinado utilizando os pontos dados pelo otimizador e gerados randomicamente, com seus valores de função real calculados a partir do simulador [20]. Tal processo é repetido até a convergência do algoritmo.

Figura 1. Esquema de otimização usando modelo substituto adaptativo.



Fonte: Adaptado de [21].

## 5 Exemplo: Brush Canyon Outcrop

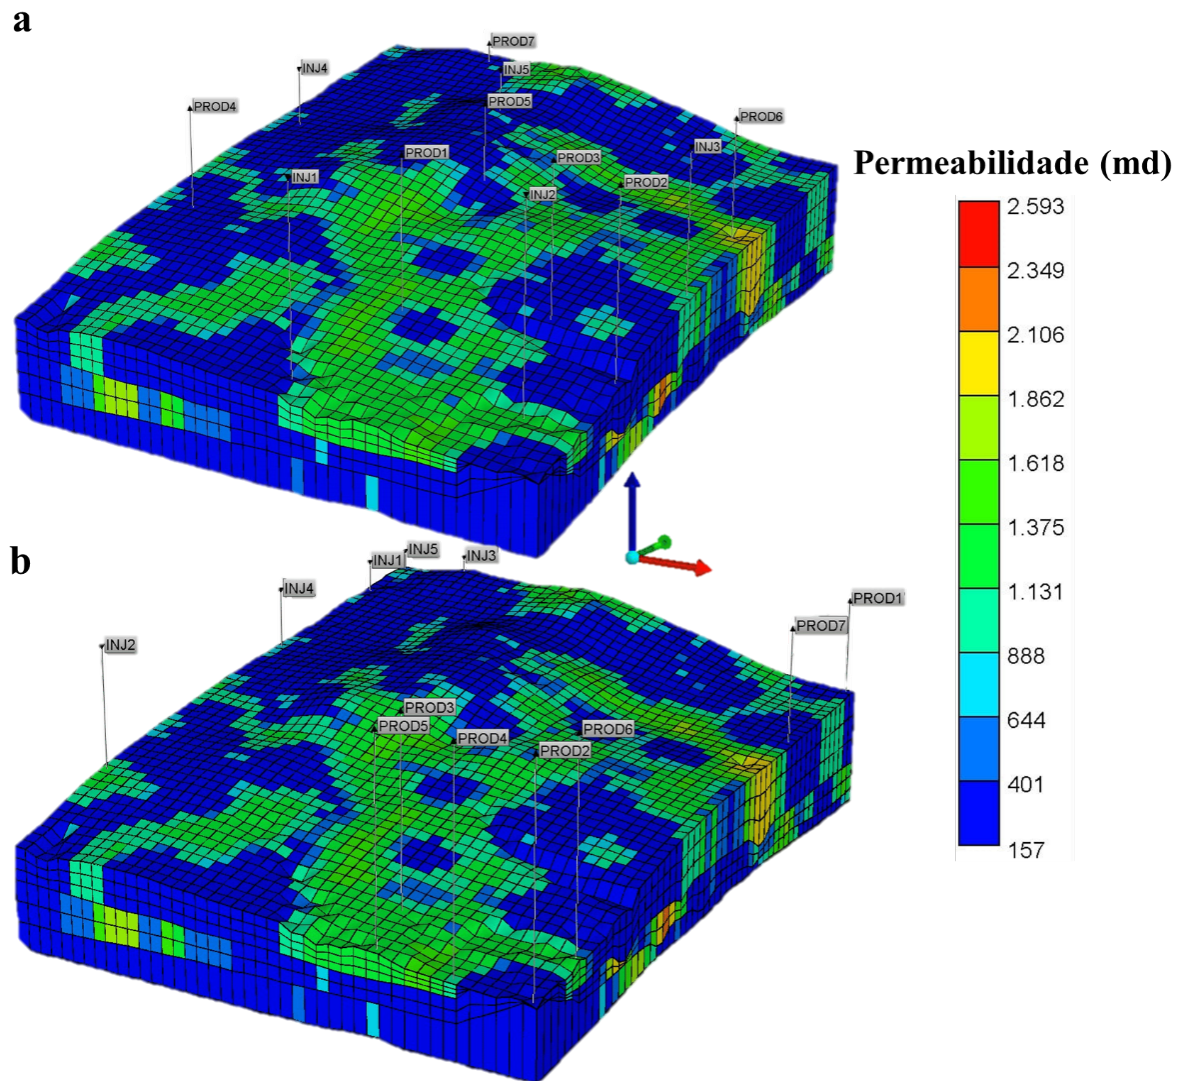
O reservatório sintético Brush Canyon Outcrop (BCO), aqui estudado, está apresentado na Fig. 2. O exemplo tem como objetivo o posicionamento espacial de 12 poços verticais no campo, sendo 7 produtores e 5 injetores, canhoneados ao longo das seis camadas horizontais do reservatório e possui, portanto, 24 variáveis (duas coordenadas por poço). Os resultados foram obtidos através de 20 otimizações utilizando o GA operando em modelos substitutos adaptativos, de modo que a distribuição estatística das respostas possa ser avaliada. Esses parâmetros estáticos são apresentados na Tabela 1. As populações iniciais que deram origem ao modelo substituto, geradas a partir do esquema LHS, foram renovadas a cada iteração do GA, devido ao seu caráter randômico. A não-linearidade da restrição de distância mínima, imposta ao problema, dificultou a geração de amostras viáveis para compor a população inicial, das 1200 amostras inicialmente geradas via o esquema LHS, apenas 265 conseguiram respeitar a imposição.

Tabela 1. Resultados estatísticos para o problema de locação dos poços.

Função	Resultados considerando 20 rodadas				
	GA	Melhor	Média	Pior	Desvio Padrão
$VPL(10^6\$)$	400.7883	383.1742	368.2284	9.2222	

Fonte: O Autor

Figura 2. Distribuição dos poços produtores e injetores no reservatório: (a) caso base (b) caso otimizado.




Fonte: O Autor.

A distribuição dos resultados pode ser melhor observada através do gráfico de barras da Fig. 3, no qual o valor médio do VPL, representado pela linha vermelha, é de  $3.8317 \times 10^8$ , e 1/4 das soluções são superiores a  $3.9 \times 10^8$ . Os resultados das 20 otimizações mostram que o GA foi capaz de solucionar o problema proposto com uma variação de cerca de 2,4%, em relação ao valor médio obtido. Certificando ao otimizador um certo nível de confiabilidade com relação ao seu desempenho.

Este problema foi simulado com as vazões dos poços operando em seus limites máximos, ou seja, na situação em que a unidade de produção trabalha a nível topado. Nem sempre este tipo de gerenciamento representa o ótimo da produção, como visto em [22], os autores utilizaram um algoritmo de aproximação sequencial (*Sequential Approximate Optimization* - SAO), e [20] e [23] utilizaram algoritmos de busca global, GA e PSO, respectivamente, na solução do problema de gerenciamento das vazões dos poços no reservatório BCO. Porém, mesmo utilizando a capacidade máxima de plataforma, a locação de poços, por si só, apresenta ganhos na função objetivo mais representativos, conforme mostrado na Tabela 2, que compara os valores de VPL médio obtido neste trabalho com os melhores resultados obtidos nos problemas de otimização das vazões, citados anteriormente. Mesmo tratando-se de problemas distintos, são comparados, aqui, a fim de discutir o impacto da locação de poços no desenvolvimento do campo.



Figura 3. Valores de VPL obtidos nas 20 otimizações.



Fonte: O Autor.

O número máximo médio de gerações foi de 856, totalizando uma média de 63153 avaliações da função de aptidão, este valor revela a importância da utilização do metamodelo, viabilizando o processo, uma vez que, tantas avaliações de função no simulador seriam impraticáveis. Estes resultados também são capazes de mostrar que os parâmetros utilizados no GA evitaram convergência prematura do otimizador, aumentando as possibilidades de busca no espaço de projeto por um ótimo global. Tal convergência, nas vinte otimizações, se deu porque a mudança cumulativa média no valor da função de adequação sobre as gerações foi menor que  $1 \times 10^{-6}$ .

O melhor VPL encontrado para a localização otimizada dos poços foi de  $400.7883 \times 10^6$ , que representa cerca de 60,8% quando comparado ao VPL do caso base,  $249.2016 \times 10^6$ , cujas posições foram previamente definidas e fornecidas pela literatura. As posições otimizadas dos poços produtores e injetores no campo são apresentadas na Tabela 3.

A otimização alterou a locação de todos os poços pré-posicionados no campo, conforme mostrado na Fig. 2, comparando o posicionamento dos poços no caso base (a) e no caso otimizado (b). Este problema é influenciado fortemente pelas propriedades dos fluidos e rochas, locação dos poços no reservatório, condições de produção e heterogeneidades, especialmente, no tocante a permeabilidade relativa.

Tal como pode ser observado, os poços foram locados, preferencialmente, nos blocos da malha adjacentes aos limites sem fluxo, de lados opostos. Tal configuração proporciona o retardo da chegada da frente de água nos produtores, além do mais, a porção central do campo é de alta permeabilidade e possui ligações com outras regiões com as mesmas propriedades, gerando caminhos preferenciais para irrupções de água. Os poços produtores foram locados nas regiões de alta permeabilidade, e os injetores nas regiões em que esta propriedade é menor. Este comportamento é esperado, uma vez que, os controles de vazão do campo não fazem parte do problema de otimização (gerenciamento reativo) e o grau de liberdade do posicionamento, imposto ao otimizador, faz com que, para otimizar a função objetivo (VPL), aumente a produção de óleo e reduza a de água, através das propriedades do campo. A Fig. 2 sugere que a melhor localização para os poços injetores é adjacente ao limite esquerdo, que são os blocos mais distantes dos

Tabela 2. Comparação dos resultados obtidos nos problemas de gerenciamento de vazão e locação de poços.

Otimizador	Problema	VPL(10 <sup>6</sup> \$)	Média N. <sup>o</sup> Simulações
GA	Locação de poços	383.1742	168
SAO <sup>1</sup>	Gerenciamento das vazões	356.072	1093
SAO <sup>2</sup>	Gerenciamento das vazões	360.8930	1079
Híbrido GA-SAO <sup>2</sup>	Gerenciamento das vazões	364.0400	1155
CAPSO <sup>3</sup>	Gerenciamento das vazões	360.0574	509

<sup>1</sup> [24]

<sup>2</sup> [20]

<sup>3</sup> [23]

Fonte: O Autor.

Tabela 3. Blocos da malha em  $i$  e  $j$  em que os poços produtores e injetores foram posicionados.

Poços Produtores							
Poços	Prod1	Prod2	Prod3	Prod4	Prod5	Prod6	Prod7
<b>Blocos (<math>i,j</math>)</b>	(43, 1)	(43, 55)	(30, 50)	(37, 55)	(31, 55)	(43, 49)	(43, 13)

Poços Injetores					
Poços	Inj1	Inj2	Inj3	Inj4	Inj5
<b>Blocos (<math>i,j</math>)</b>	(1, 7)	(1, 45)	(7, 1)	(1, 21)	(1, 1)

Fonte: O Autor

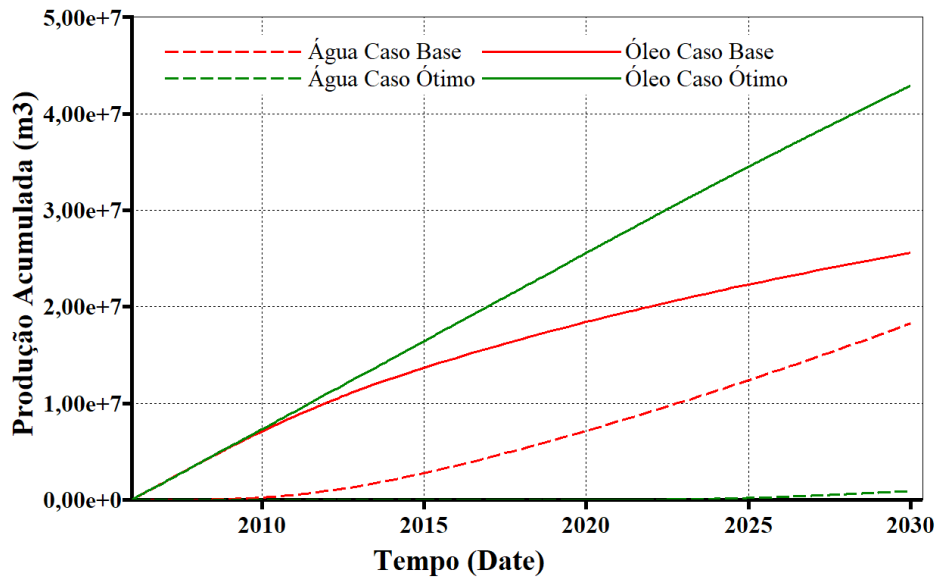
sete produtores, o que significa que o tempo de penetração da água nestes são dominantes em relação a outros fatores.

Tal configuração proporcionou melhores valores no VPL devido ao efetivo aumento no fator de recuperação do campo, que passou de 31.23% do caso base para 52.43% no otimizado. O alto fator de recuperação aliado a diminuição da produção de água, impactam grandemente no valor da função objetivo. O gráfico da Figura 23 mostra a produção acumulada de óleo e água para os casos base (locações previamente definidas) e otimizado. É possível notar uma redução de aproximadamente 97% na produção de água e um aumento de 40% na produção de óleo para o caso otimizado. O comportamento quase linear da produção acumulada de óleo no caso otimizado, demonstra a eficiência do varrido de óleo no reservatório pela frente de água e o retardo de sua irrupção nos poços produtores.

Tais resultados podem ser melhores observados na Fig. 5, que mostra as produções acumuladas de óleo e água por poço produtor. Na locação original dos poços, os produtores 2 e 3 ficam próximos ao injetor 3 (Fig. 2), e com isto, a frente de água chega ligeiramente neles devido a região de alta permeabilidade que os interconectam. O contrário pode ser observado no produtor 7, que detém a maior produção de óleo, mesmo estando próximo ao injetor 5, porém, o mesmo está posicionado em uma área do campo com menor permeabilidade.

A alta produção de água do caso base também é explicada devido ao posicionamento dos poços produtores e injetores na região de alta permeabilidade do reservatório, com ligação direta entre eles, funcionando como canais para a frente de água. Comportamento esse, que a locação otimizada evitou,

Figura 4. Produções acumuladas de óleo e água dos casos base e otimizado (locação).



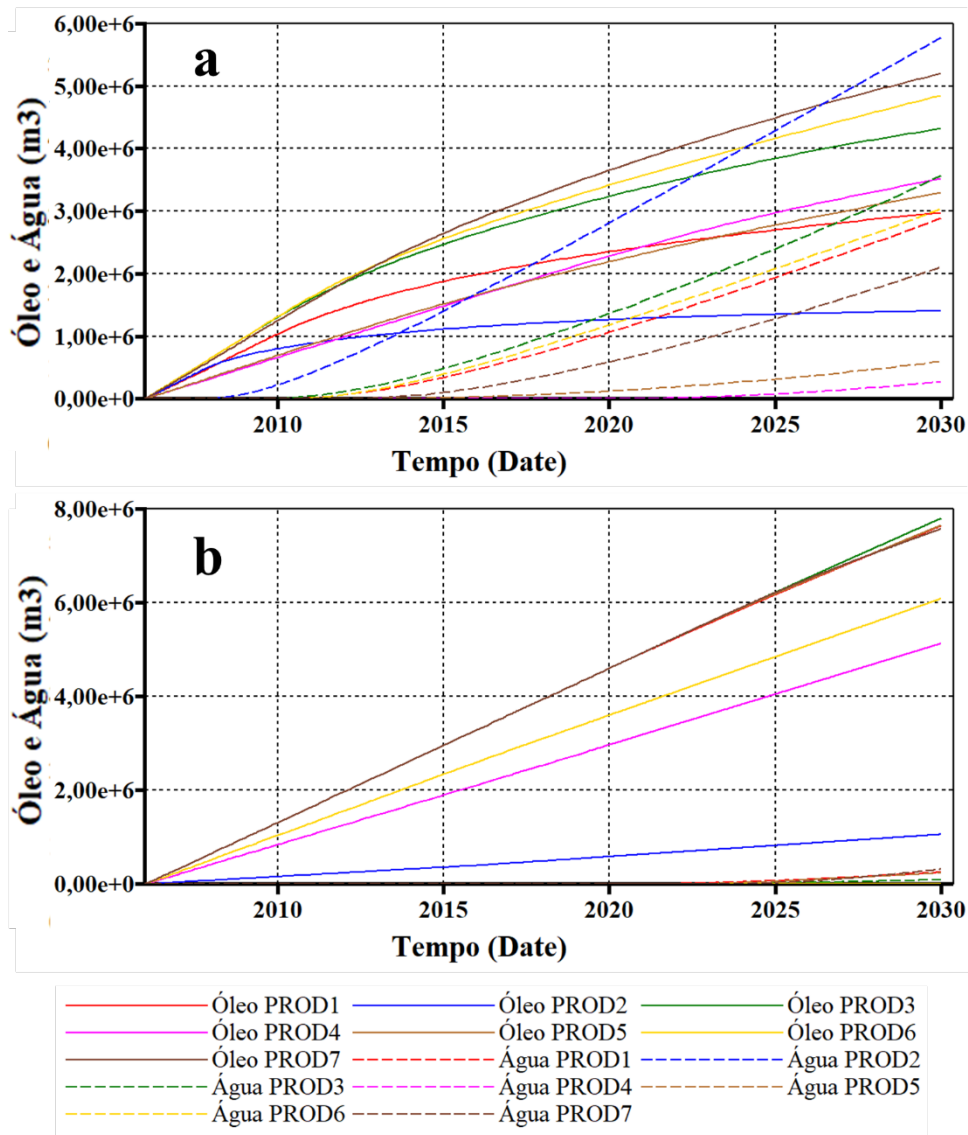
Fonte: O Autor.

posicionando os injetores e produtores em limites opostos do campo, e evitando o posicionamento de injetores na área central, cujas permeabilidades ao longo das 6 camadas são maiores. As diferenças na produção de água e óleo ficam evidentes nos gráficos da Fig. 5, para os casos base (a) e otimizado (b).

Fica evidenciada na Fig. 5b a baixa produção de água e o retardo da sua irrupção nos poços produtores na locação otimizada, de anterior ao ano de 2010 no caso base, para próximo de 2025 no caso otimizado.

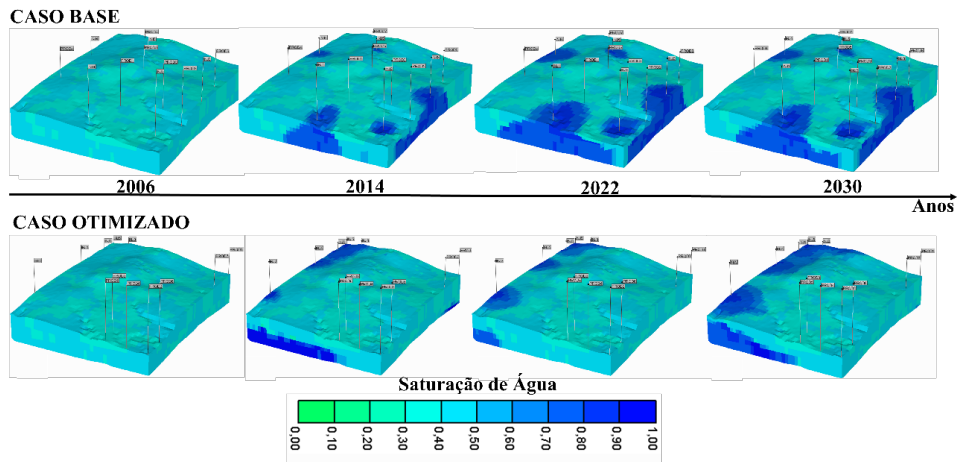
As observações feitas anteriormente, acerca da chegada prematura de água no caso base, são mais facilmente notadas na Fig. 6 (casos base e otimizado), que apresenta a saturação do líquido ao longo do tempo de concessão do campo. O retardo da irrupção é importante para a produção do campo, uma vez que, ao atingir o poço produtor, a frente começa a ser produzida e rapidamente provoca o surgimento de grandes valores para a razão água-óleo. Na locação dos injetores, o tempo de concessão do campo é importante para o entendimento do comportamento do deslocamento da frente de água. Ao final dos 24 anos de produção, tal avanço não afetou bruscamente a produção.

Figura 5. Produções acumuladas de óleo e água nos poços: (a) caso base (b) caso otimizado(locação).



Fonte: O Autor.

Figura 6. Saturação de água no reservatório ao longo do tempo de concessão.



Fonte: O Autor.

## 6 Conclusões

Neste artigo foi desenvolvida uma ferramenta para a maximização do VPL, através da locação de poços em reservatórios de petróleo. O otimizador utilizado foi o GA. Por se tratar de um problema discreto, esse algoritmo apresenta-se como uma técnica indicada para encontrar o ótimo global do problema em estudo.

Foi utilizado o procedimento de otimização via GA com o tratamento de restrições através de uma adaptação da técnica APM, e esta se mostrou importante no processo de otimização para contornar as dificuldades de lidar com um grande número de restrições.

Devido ao elevado número de avaliações, normalmente requeridas pelo GA, onde aqui cada avaliação representa uma simulação numérica com custo computacional significativo, modelos substitutos baseados no uso de funções de base radial cúbica foram criados e utilizados de uma forma adaptativa, isto é, a cada geração do algoritmo um novo modelo é usado. Portanto, tal esquema viabilizou aqui a solução do problema da otimização da locação de poços.

O processo de otimização foi aplicado a um modelo sintético de reservatório disponível na literatura, com número e locação dos poços previamente definidos (caso base). Os resultados correspondentes as 20 otimizações mostram que o GA foi capaz de solucionar o problema proposto com uma variação de cerca de 2.4%, em relação ao valor médio obtido. Isto certifica ao otimizador um bom nível de confiabilidade com relação ao seu desempenho. Além disto, o melhor VPL encontrado para a locação otimizada dos poços representa cerca de 60.8% quando comparado ao VPL do caso base.

O caso estudado apontou que a metodologia proposta foi capaz de otimizar os planos de drenagem do campo, ressaltando seu poder em lidar com problemas complexos de otimização com restrições. Extensões futuras deste trabalho incluem variáveis de projeto associadas à profundidade do poço, tipo do poço e acoplamento desta ferramenta com o problema de gerenciamento das vazões.

## Agradecimentos

A CAPES e a *Energy Simulation* pelo apoio financeiro ao desenvolvimento deste trabalho.

## References

- [1] Lima, R., Abreu, A. C., Pacheco, M. A., et al., 2015. Optimization of reservoir development plan using the system octopus. In *OTC Brasil*. Offshore Technology Conference.
- [2] Karkevandi-Talkhoonchah, A., Sharifi, M., & Ahmadi, M., 2018. Application of hybrid adaptive neuro-fuzzy inference system in well placement optimization. *Journal of Petroleum Science and Engineering*, vol. 166, pp. 924–947.
- [3] Bittencourt, A. C., Horne, R. N., et al., 1997. Reservoir development and design optimization. In *SPE annual technical conference and exhibition*. Society of Petroleum Engineers.
- [4] Montes, G., Bartolome, P., Udias, A. L., et al., 2001. The use of genetic algorithms in well placement optimization. In *SPE Latin American and Caribbean petroleum engineering conference*. Society of Petroleum Engineers.
- [5] Özdoğan, U., Horne, R. N., et al., 2004. Optimization of well placement with a history matching approach. In *SPE Annual technical conference and Exhibition*. Society of Petroleum Engineers.
- [6] Emerick, A. A., Silva, E., Messer, B., Almeida, L. F., Szwarcman, D., Pacheco, M. A. C., Vellasco, M. M. B. R., et al., 2009. Well placement optimization using a genetic algorithm with nonlinear constraints. In *SPE reservoir simulation symposium*. Society of Petroleum Engineers.

- [7] Holland, J., 1975. Adaptation in natural and artificial systems: an introductory analysis with application to biology. *Control and artificial intelligence*.
- [8] Babadagli, T., 2007. Development of mature oil fields—a review. *Journal of Petroleum Science and Engineering*, vol. 57, n. 3-4, pp. 221–246.
- [9] Leeuwenburgh, O. & Fonseca, R. M., 2018. Field development optimization exercise. *Isapp Field Development Optimization Challenge*, pp. 4–9.
- [10] Serafini, D. B., 1999. *A framework for managing models in nonlinear optimization of computationally expensive functions*. Doutorado em mecânica computacional, Rice University, Texas.
- [11] Giunta, A. & Eldred, M., 2000. Implementation of a trust region model management strategy in the dakota optimization toolkit. In *8th Symposium on Multidisciplinary Analysis and Optimization*, pp. 4935.
- [12] Giunta, A., Wojtkiewicz, S., & Eldred, M., 2003. Overview of modern design of experiments methods for computational simulations. In *41st Aerospace Sciences Meeting and Exhibit*, pp. 649.
- [13] Forrester, A., Sobester, A., & Keane, A., 2008. *Engineering design via surrogate modelling: a practical guide*. John Wiley & Sons.
- [14] Gutmann, H.-M., 2001. A radial basis function method for global optimization. *Journal of global optimization*, vol. 19, n. 3, pp. 201–227.
- [15] Goldberg, D. E. & Holland, J. H., 1988. Genetic algorithms and machine learning. *Machine learning*, vol. 3, n. 2, pp. 95–99.
- [16] Michalewicz, Z., 1995. Genetic algorithms, numerical optimization, and constraints. In *Proceedings of the sixth international conference on genetic algorithms*, volume 195, pp. 151–158. Citeseer.
- [17] MATLAB, 2014. *version 7.10.0 (R2014a)*. The MathWorks Inc., Natick, Massachusetts.
- [18] Barbosa, H. J. & Lemonge, A. C., 2002. An adaptive penalty scheme in genetic algorithms for constrained optimization problems. In *GECCO*, volume 2, pp. 287–294. Citeseer.
- [19] Lemonge, A. C. & Barbosa, H. J., 2004. An adaptive penalty scheme for genetic algorithms in structural optimization. *International Journal for Numerical methods in engineering*, vol. 59, n. 5, pp. 703–736.
- [20] Oliveira, L. C., 2013. *Estratégia Híbrida Aplicado ao Gerenciamento Ótimo de Reservatórios*. Doutorado em engenharia civil, Universidade Federal de Pernambuco, Recife.
- [21] Foroud, T., Seifi, A., & Hassani, H., 2012. Surrogate-based optimization of horizontal well placement in a mature oil reservoir. *Petroleum Science and Technology*, vol. 30, n. 11, pp. 1091–1101.
- [22] Horowitz, B., Afonso, S. M. B., & de Mendonça, C. V. P., 2013. Surrogate based optimal waterflooding management. *Journal of Petroleum Science and Engineering*, vol. 112, pp. 206–219.
- [23] Silva, H. V. C., 2019. Método cooperativo assistido do enxame de partículas aplicado à otimização do controle das vazões dos poços em reservatórios de petróleo. Mestrado em engenharia civil, Universidade Federal de Pernambuco, Recife.
- [24] Pinto, J. W., 2014. Uso de otimização sequencial aproximada em problemas uni e multiobjetivos de gerenciamento de reservatórios. Mestrado em engenharia civil, Universidade Federal de Pernambuco, Recife.