

GERENCIAMIENTO ÓTIMO DA PRODUÇÃO DE PETRÓLEO UTILIZANDO O ALGORITMO DO ENXAME DE PARTÍCULAS E MODELOS SUBSTITUTOS ADAPTATIVOS

Samuel A. Souza, Silvana M. B. Afonso e Bernardo Horowitz

Departamento de Engenharia Civil, Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Avenida Acadêmico Hélio Ramos, s/n, 50740-530, Recife, Pernambuco, Brasil

Palavras Chave: Enxame de Partículas, Modelos Substitutos, Reservatório de Petróleo.

Resumo. A otimização das vazões de produção e injeção dos poços é uma área de grande interesse na Engenharia de Reservatórios. Durante este processo, é comum a utilização de simuladores de reservatório para modelagem de seu comportamento e assim auxiliar na definição das estratégias a serem utilizadas. Neste trabalho, a otimização será conduzida utilizando uma estratégia global através do algoritmo do enxame de partículas (Particle Swarm Optimization - PSO). Este algoritmo é baseado no comportamento de revoada dos pássaros e não faz uso do cálculo de gradientes. Porém, um grande número de avaliações de função é necessário, e para o tipo de problema abordado, cada avaliação necessita de uma simulação completa do reservatório, o que pode demandar um alto custo computacional para obtenção do projeto ótimo. Como resposta a este inconveniente, será utilizada a técnica de Krigagem bem como o procedimento de redes neurais artificiais para construção de modelos substitutos objetivando uma resposta computacional rápida, porém com precisão aferida. Neste sentido, um esquema adaptativo de inclusão de pontos amostrais é implementado na estratégia PSO, visando a obtenção de soluções ótimas compatíveis com o modelo de alta fidelidade. Na combinação das estratégias propostas, as avaliações de função, antes realizadas com o simulador, serão realizadas com a utilização do modelo substituto. Neste trabalho, será analisado um caso de gerenciamento das vazões em diferentes ciclos de controle, e condições distintas de gerenciamento, sendo estes com tempo fixo ou variando, no problema de injeção de água em reservatórios de Petróleo.

1 INTRODUÇÃO

A otimização dinâmica das vazões de produção e injeção dos poços é uma área de grande interesse na Engenharia de Reservatórios. Neste trabalho, é estudada a técnica de injeção de água como recuperação secundária visando obter uma produção de óleo maior que aquela que seria encontrada se apenas a energia natural do reservatório fosse utilizada. Na intenção de melhorar a eficiência da aplicação da injeção de água, é realizada a otimização dinâmica das vazões de produção e injeção dos poços.

Para o processo de otimização será utilizado o algoritmo evolucionário do enxame de partículas (*Particle Swarm Optimization - PSO*) (Kennedy e Eberhart, 1995). Este algoritmo é baseado no comportamento de revoada visto em muitas espécies de pássaros e não faz uso do cálculo de gradientes. Outras aplicações do PSO no campo da Engenharia de Petróleo podem ser vistas em Onwunalu e Durlofsky (2010) e Kathrada (2009). Porém, devido as características desse algoritmo, o projeto ótimo de problemas reais quase sempre se torna bastante demorado devido ao fato do algoritmo realizar um grande número de simulações, uma vez que cada avaliação de função está ligada a uma simulação.

Como resposta a este inconveniente, a utilização de métodos aproximados objetivando a construção de modelos substitutos, Forrester et al. (2008) está cada vez mais sendo empregada nos mais variados campos da Engenharia Keane e Nair (2005), inclusive na Engenharia de reservatórios (Sasena, 2002; Horowitz et al., 2010c; Carrero et al., 2007). O grande desafio científico nesta área é a geração de um modelo substituto o mais preciso possível, utilizando-se o menor número possível de avaliações do modelo de alta fidelidade. Para a maioria dos problemas, a natureza da verdadeira função não é conhecida a priori, por isso não é claro qual modelo substituto será mais preciso. Aqui será utilizada a técnica de ajuste de superfícies por krigagem e por redes neurais artificiais para construção de modelos substitutos para o problema de engenharia de reservatório em estudo. Dessa forma, as avaliações da função objetivo requeridas no processo de otimização serão substituídas pelo modelo criado via krigagem a partir do ajuste de soluções obtidas com o uso do simulador IMEX (CMG, 2006) em pontos amostrais previamente considerados.

2 OTIMIZAÇÃO VIA ENXAME DE PARTÍCULAS

O algoritmo do PSO (*Particle Swarm Optimization*) foi originalmente desenvolvido por um psicólogo e um engenheiro elétrico em 1995 (Kennedy e Eberhart, 1995) e foi inspirado no comportamento de revoada visto em muitas espécies de pássaros.

No modelo proposto (Pomeroy, 2003), os pássaros são atraídos para uma área de pouso, um poleiro. Na simulação, os pássaros começariam a explorar o ambiente sem um destino em particular e espontaneamente uma revoada estaria formada até que um deles encontre uma área de pouso. As regras que modelam o comportamento dos pássaros são simples: os pássaros escolhem a direção e a velocidade do voo (essencialmente, cada pássaro tenta permanecer próximo aos outros enquanto também tenta não colidir com os mesmos); um dos pássaros se desvia do restante do bando com o intuito de pousar num poleiro, o que acarreta num movimento dos pássaros mais próximos para a mesma direção; quando esses pássaros descobrem um poleiro, eles pousam conduzindo o restante do bando para o mesmo local.

Encontrar um poleiro é análogo a encontrar uma solução em um campo de possíveis soluções, e a maneira que uma das aves influencia seus vizinhos em direção a ele, aumentando a probabilidade dos mesmo encontrá-lo, está ligada a cognição social da mente (a mente e portanto a inteligência, é social) (Oliveira, 2008).

Logo, o PSO busca um equilíbrio entre a individualidade e a socialização (características que influenciam o comportamento). De maneira ideal, se quer que os indivíduos, aqui chamados de partículas, prefiram ser individualistas (semelhante ao pássaros que não querem colidir uns aos outros) e também queiram saber onde boas soluções têm sido encontradas pelos outros, então se pode "aprender com o que o outros fizeram".

No PSO, cada partícula, candidata a solução do problema, é representada por um ponto no espaço de projeto e uma velocidade. Durante o processo iterativo, esta velocidade é atualizada fazendo com que a partícula se mova dentro do espaço de projeto, sendo este processo de atualização influenciado por decisões individuais (da partícula) e sociais (do enxame). A atualização da posição, mostrada a seguir, segue um esquema baseado na equação cinemática da função horária do espaço em um movimento uniforme.

$$p_{t+1}^i = p_t^i + v_{t+1}^i \Delta t \quad (1)$$

Como visto na Eq. (1), a posição p da partícula i na iteração $t + 1$ é atualizada a partir da sua posição na iteração anterior, t , somada a sua velocidade v na iteração $t + 1$. O fator Δt representa o tempo, que no PSO é representado pelas iterações, o que torna o valor de Δt unitário. A formulação para obtenção da velocidade v_{t+1}^i (Shi e Eberhart, 1998) é mostrada a seguir.

$$v_{t+1}^i = wv_t^i + c_1r_1(pbest^i - p_t^i) + c_2r_2(gbest - p_t^i) \quad (2)$$

Onde v_t^i é a velocidade da partícula i na iteração t , $pbest^i$ representa a melhor posição já encontrada pela partícula i , $gbest$ é a melhor posição encontrada pelo enxame, r_1 e r_2 são números randômicos entre 0 e 1. O parâmetro w é denominado inércia e influencia fortemente no comportamento do algoritmo: valores altos facilitam um comportamento mais global enquanto valores baixos um comportamento mais local. Os termos c_1 e c_2 são denominados parâmetros de confiança e representam quanta confiança a partícula tem nela mesma e na população, respectivamente. Valores típicos para esses parâmetros são $c_1 = c_2 = 2$ (Oliveira, 2008).

A consideração de restrições no problema é feita de duas formas. Na primeira, é adotado o uso de uma função de penalidade como descrito em Oliveira (2008). Nesta situação, uma penalização é aplicada naquela partícula que violou alguma restrição. Na segunda situação (Cagnina et al., 2008), as partículas são capazes de reconhecer posições violadas e dão preferência a soluções viáveis. Neste segundo esquema, as partículas são comparadas seguindo os seguintes critérios:

- Se duas partículas são viáveis, escolhemos a que tenha o melhor valor da função objetivo;
- Entre uma partícula viável e outra inviável, escolhemos sempre a viável;
- Se duas partículas estão inviáveis, escolhemos aquela com o menor índice de inviabilidade.

Esta técnica é utilizada na seleção de $pbest$ e $gbest$. Cada partícula calcula um índice de inviabilidade que identifica o quão inviável a partícula está. Caso a mesma se encontre em uma posição viável, o valor do índice é 0. O índice de inviabilidade utilizado neste trabalho foi a mesma função utilizada para o cálculo da penalização (Oliveira, 2008).

3 CONSTRUÇÃO DE MODELOS SUBSTITUTOS

O primeiro passo para a construção de um modelo substituto baseado no ajuste de dados é a geração de uma amostra de pontos. Estes são locais no espaço de projeto em que os valores da resposta dos modelos de alta fidelidade (no nosso caso simulações numéricas via o simulador de reservatórios) serão calculados para construir o modelo aproximado. A seleção da amostra é uma etapa muito importante uma vez que para casos onde a avaliação da função requer um alto custo computacional deve-se procurar um plano de amostragem eficaz, o que significa o número mínimo de pontos que garantirão um modelo substituto com boa precisão.

Neste trabalho a amostra foi gerada utilizando Hipercubo Latino (*Latin Hypercube Sampling - LHS*) (Forrester et al., 2008; Giunta, 2002).

A aleatoriedade inerente ao processo significa que existe mais de uma possibilidade do arranjo de amostragem atender aos critérios do LHS (Forrester et al., 2008). Como a amostragem LHS é de natureza estocástica, é aconselhável executar tal programa várias vezes e selecionar a melhor amostra para uso. Para selecionar a melhor amostra LHS, é determinado para cada amostra o parâmetro Δ (Keane e Nair, 2005) como :

$$\Delta = \left(\sum_{i=1}^{m-1} \sum_{j=1}^m \frac{1}{(x_j - x_i)^2 + (y_j - y_i)^2} \right) \quad (3)$$

Onde m é o número total pontos da amostra. A amostra LHS que dá o valor máximo para Δ é a amostra selecionada para a geração do modelo a partir de um dos esquemas aqui utilizados: krigagem e Redes Neurais Artificiais.

A técnica de krigagem foi desenvolvida pelo matemático francês Georges Matheron a partir dos trabalhos de Daniel G. Krige (Valente, 1982). Muito usado em geoestatística, parte do princípio que os pontos em um dado espaço de projeto são correlacionados. Maiores detalhes sobre a formulação da mesma podem ser encontrados em Afonso et al. (2008).

As Redes Neurais Artificiais (RNA) (Haykin, 2001) consistem em uma simulação do comportamento do cérebro humano, sendo este tratado como um computador altamente complexo, não-linear e paralelo. Assim como o cérebro humano, suas unidades fundamentais de processamento são os neurônios. RNAs são aplicadas para diversos fins, entre eles reconhecimento de padrões, controle de processos e aproximação de funções.

4 UTILIZAÇÃO DO PSO JUNTAMENTE COM MODELOS SUBSTITUTOS

Um primeiro estudo sobre a utilização conjunta do PSO com a técnica de krigagem aplicado em um problema de Engenharia de Reservatório foi desenvolvido em Souza et al. (2009) e Souza et al. (2010). Porém, embora os valores da função objetivo fornecidos pelo modelo substituto como solução ao final do processo de otimização fossem próximos do valor de referência (Mendonça et al., 2009; Horowitz et al., 2010a), ao se testar as variáveis de projeto desta solução no modelo de alta fidelidade, utilizando o simulador IMEX (CMG, 2006), uma considerável discrepância entre os valores da função objetivo foi notado.

Para lidar com este problema, foi idealizado um esquema de adição de pontos à amostra em um procedimento iterativo onde uma sequência de soluções via o PSO são conduzidas. O esquema consiste em rodar PSOs mais simples, com menor número de iterações, e caso a resposta encontrada pelo mesmo apresente uma diferença maior que uma tolerância pré-determinada pelo usuário em relação ao modelo de alta fidelidade, esta solução é adicionada à amostra. O processo é continuado até que o critério acima seja atendido. Também foi utilizado um esquema de adição de pontos aleatórios de forma que o ponto a ser adicionado estivesse com a

maior distancia media e o menor desvio padrão da distancia em relação aos pontos já existentes da amostra. A adição de pontos aleatórios tem probabilidade de 30% de ser utilizada.

Com isso, espera-se que ao final deste processo a amostra final, e consequentemente o modelo substituto, apresentem pontos bem espalhados em todo o domínio de projeto e uma concentração maior de pontos na região próxima ao ótimo.

5 OTIMIZAÇÃO DE RESERVATÓRIOS DE PETRÓLEO

Há três grandes linhas de estudo dentro do contexto da otimização na produção de petróleo, como descrito em Oliveira (2006), são elas:

- Operação dos Campos de petróleo, relacionada aos equipamentos e instalações de produção e de poços;
- Desenvolvimento de Campos de petróleo, no que concerne à quantidade e distribuição dos poços de desenvolvimento (não exploratórios);
- Gerenciamento de Campos de petróleo através da alocação dinâmica das vazões de produção e injeção.

Este trabalho se encontra dentro deste ultimo contexto, mais especificamente no caso da injeção de água como método de recuperação secundária.

A injeção de água é o principal método de recuperação secundária devido ao baixo custo associado ao uso da água, que é abundante, bem como à maior estabilidade do processo se comparado com o uso de gás. Esse mecanismo de produção se aplica com dois propósitos: no deslocamento do óleo para os poços produtores e na manutenção de pressão do reservatório que energiza o sistema.

No que se refere ao deslocamento do óleo na direção dos produtores, a razão de mobilidade dos fluidos, as heterogeneidades e a segregação são os três fatores que governam a eficiência de recuperação do óleo.

Quanto à manutenção da pressão, essa prática apresenta algumas vantagens. Um primeiro ponto se refere à energia do sistema, representada pela pressão do reservatório. Um outro ponto diz respeito à manutenção do estado de sub-saturação do reservatório, pois isso evita a liberação de gás associado e o aumento rápido da razão gás-óleo (RGO) dos produtores. Em casos de elevada sub-saturação ou em óleos muito viscosos, é interessante permitir alguma queda da pressão do reservatório, obtendo ganhos no fluxo.

5.1 Formulação do problema

Para este tipo de problema, a função objetivo comumente esta relacionada a produção propriamente dita ou a economia do projeto. Quando o foco está na produção de petróleo, pode-se tomar como objetivo a maximização da produção acumulada de óleo, por exemplo. Já do ponto de vista da economia do projeto, a lucratividade é normalmente escolhida como indicador, onde se pode buscar a maximização do valor presente líquido (VPL) ou de algum outro índice econômico.

Neste trabalho foi utilizado o VPL como função objetivo. As vazões nos poços em diferentes tempos ao longo da simulação são as variáveis de controle idealizadas para o problema. Para isso, o controle da vazão dos poços a cada intervalo de tempo é feito através do rateio em relação

à capacidade de produção do grupo onde os poços estão ligados. Logo, temos como variáveis:

$$x_{p,t} = \frac{q_{p,t}}{\sum q_{P,t}} \quad (4)$$

onde $q_{p,t}$ é a vazão do poço p no intervalo de tempo t e P representa o grupo dos poços produtores.

Neste trabalho, são consideradas duas condições de funcionamento quanto as linhas de produção e injeção, sendo elas: topado e não topado. No primeiro caso é considerado que as linhas operam sempre na sua capacidade máxima, enquanto no segundo elas podem ou não operar na capacidade máxima. Assim, a formulação do problema de otimização para o caso topado é dada por:

$$\begin{aligned} \text{Maximizar } VPL &= \sum_{\tau=0}^T \left[\frac{1}{(1+d)^\tau} F_\tau(x_{p,t}, \mathbf{u}) \right] \\ \text{Sujeito a: } \sum_{p \in P} x_{p,t} &= 1 \quad t = 1 \dots n_t \\ \sum_{p \in I} x_{p,t} &= 1 \quad t = 1 \dots n_t \\ x_{p,t}^l &\leq x_{p,t} \leq x_{p,t}^u \quad t = 1 \dots n_t \end{aligned} \quad (5)$$

Onde \mathbf{u} são as variáveis de estado; d é a taxa de desconto, F_τ é o fluxo de caixa, T é o tempo total de operação, P e I representam o grupo de poços produtores e injetores, respectivamente, n_t o número de ciclos, $x_{p,t}^l$ e $x_{p,t}^u$ os limites inferiores e superiores de rateio entre os poços.

Por esta formulação, o problema topado apresenta uma redução no número de variáveis de projeto uma vez que como o grupo produz ou injeta a capacidade máxima deste, o rateio de um dos poços torna-se dependente dos demais e pode ser obtido diretamente. Foram estudados casos com 2, 4 e 12 ciclos de controle. Sendo o número de variáveis ndv descrito por:

$$ndv = (n_P + n_I - 2)n_t \quad (6)$$

Onde n_P é o número de poços produtores e n_I o número de poços injetores. Para o problema não topado temos a seguinte formulação:

$$\begin{aligned} \text{Maximizar } VPL &= \sum_{\tau=0}^T \left[\frac{1}{(1+d)^\tau} F_\tau(x_{p,t}, \mathbf{u}) \right] \\ \text{Sujeito a: } \sum_{p \in P} x_{p,t} &\leq 1 \quad t = 1 \dots n_t \\ \sum_{p \in I} x_{p,t} &\leq 1 \quad t = 1 \dots n_t \\ \sum_{p \in P} x_{p,t} &\leq \sum_{p \in I} x_{p,t} \leq 1.1 \sum_{p \in P} x_{p,t} \quad t = 1 \dots n_t \\ x_{p,t}^l &\leq x_{p,t} \leq x_{p,t}^u \quad t = 1 \dots n_t \end{aligned} \quad (7)$$

Para este caso, foram adotados 3 ciclos de controle, como mostrado na Fig. 1. Nesta situação, o numero de variáveis do problema é dado por:

$$ndv = (n_P + n_I)n_t \quad (8)$$




Figura 1: Ciclos de controle do caso não topado

Outra opção estudada neste trabalho foi a utilização de ciclos de controle variáveis, dando assim maior flexibilidade a estratégia de produção adotada. Como pode ser visto na Fig. 2, definimos um intervalo de tempo para cada ciclo de controle, exceto o ultimo, assim as variáveis referentes ao tempo podem ser formuladas da seguinte forma:




Figura 2: Ciclos de controle com tempo variando do caso topado

$$x_{\Delta t,k} = \frac{\Delta t_k}{T} \quad k = 1 \dots n_t - 1 \tag{9}$$

Logo, o problema de otimização para o caso topado com tempo variando pode ser formulado como:

$$\begin{aligned} \text{Maximizar } VPL &= \sum_{\tau=0}^T \left[\frac{1}{(1+d)^\tau} F_\tau(x_{p,t}, \mathbf{u}) \right] \\ \text{Sujeito a: } &\sum_{p \in P} x_{p,t} = 1 \quad t = 1 \dots n_t \\ &\sum_{p \in I} x_{p,t} = 1 \quad t = 1 \dots n_t \\ &\sum_{k=1}^{n_t-1} x_{\Delta t,k} \\ &x_{p,t}^l \leq x_{p,t} \leq x_{p,t}^u \quad t = 1 \dots n_t \\ &x_{\Delta t,k}^l \leq x_{\Delta t,k} \leq x_{\Delta t,k}^u \quad k = 1 \dots n_t - 1 \end{aligned} \tag{10}$$

E o número total de variáveis é dado por:

$$ndv = (n_P + n_I - 2)n_t + n_t - 1 \quad (11)$$

Os valores da função objetivo (VPL) são calculados utilizando o modelo substituto construído a partir de simulações numéricas usando o simulador IMEX da CMG (2006). No IMEX, após a simulação, é gerado um arquivo contendo todas as informações sobre o reservatório, de onde são coletados os dados referentes às vazões dos poços necessárias para o cálculo do VPL.

6 RESULTADOS E DISCUSSÃO

A ferramenta aqui construída, baseada na integração de modelos substitutos construídos a partir de simulação numérica do código computacional IMEX com estratégia de otimização global através do algoritmo PSO é aqui apresentada para uma aplicação simples reportada na literatura (Oliveira, 2006; Mendonça et al., 2009; Horowitz et al., 2010b) para efeito de validação.

Como exemplo, foi utilizado o Caso1 encontrado em Oliveira (2006). O reservatório, indicado na Fig. 3, possui dois poços produtores e um poço injetor. Por apresentar características simples, o caso estudado proporciona um melhor entendimento dos aspectos do problema de otimização, sendo possível destacar peculiaridades que não estariam evidentes em problemas de maior complexidade.




Figura 3: Ciclos de controle com tempo variando do caso topado

A permeabilidade horizontal k_h vale 500mD próximo ao poço P-1, 1500mD próximo ao poço P-2 e 1000mD na região do poço I-1. O Injetor tem vazão máxima de $44 \text{ m}^3/\text{dia}$ enquanto grupo produtor tem vazão máxima de $40 \text{ m}^3/\text{dia}$, sendo a vazão máxima de cada poço produtor de $30 \text{ m}^3/\text{dia}$. A vazão máxima de produção de cada poço foi de $30 \text{ m}^3/\text{dia}$, logo, as variáveis de projeto podem assumir valores no intervalo $0.25 \leq x_{p,t} \leq 0.75$. As variáveis de tempo foram adotadas no intervalo $0.1 \leq x_{\Delta t,k} \leq 0.4$. O valor do preço do óleo considerado foi de R\$ 25,00/m³. A RNA utilizada foi do tipo multicamada feed-forward, contendo uma única camada oculta de 20 neurônios. Seu treino foi realizado utilizando com o algoritmo de Levenberg-Marquardt (Demuth et al., 2010).

Para o caso topado com tempo constante, cada variável representa o rateio de vazão do poço P-1 em um ciclo de produção. Foram rodados os casos onde se consideraram 2, 12 e 24 variáveis. Cada caso foi rodado 10 vezes, onde para construção de cada modelo inicial eram

geradas 10 amostras LHS. Para o caso de 2 variáveis, o tamanho da amostra utilizada foi de $10n$, onde n é o número de variáveis. Porém, para casos com um maior número de variáveis, a utilização desse critério para o tamanho da amostra não seria viável. Sendo assim, para os casos de 12 e 24 variáveis foram utilizadas amostras com tamanho $4n$. Para o esquema de adição de pontos na amostra, foi considerado como número máximo de pontos duas vezes o tamanho inicial da amostra.

Nas Tabelas 1 e 2 são apresentados os resultados para a otimização encontrados com o PSO utilizando a técnica de krigagem e RNAs, respectivamente. São mostrados os valores médios $\mu(f(x^*))$ e desvio padrão $\sigma(f(x^*))$ dos valores ótimos da função VPL assim como os melhores e piores valores encontrados avaliando a solução final no modelo de alta fidelidade. São apresentados também o número médio de pontos NPT_{med} utilizados na amostra final.

ndv	$\mu(f(x^*)) \times 10^6$	$\sigma(f(x^*))$	Melhores $\times 10^6$	Piores $\times 10^6$	NPT_{med}
2	1.492446	5.551432×10^{-5}	1.492491	1.492373	24.5
12	1.492891	3.200038×10^{-4}	1.493074	1.491680	54.8
24	1.491790	5.487439×10^{-4}	1.492564	1.491508	102.3

Tabela 1: Resultados encontrados utilizando a técnica de krigagem para o caso topado com tempo constante.

ndv	$\mu(f(x^*)) \times 10^6$	$\sigma(f(x^*))$	Melhores $\times 10^6$	Piores $\times 10^6$	NPT_{med}
2	1.494047	1.653456×10^{-3}	1.492429	1.474359	46.4
12	1.493349	7.503929×10^{-4}	1.492608	1.490001	90
24	1.492985	4.194574×10^{-4}	1.492652	1.491137	127.9

Tabela 2: Resultados encontrados utilizando RNAs para o caso topado com tempo constante.

Como visto, para os casos com um menor número de variáveis a técnica de krigagem mostrou uma melhor aproximação. Para os casos com um maior número de variáveis, as duas técnicas utilizadas na construção de modelos substitutos mostraram-se mais próximos. Também podemos notar que a krigagem utilizou um número médio de pontos menor na amostra final. Também podemos ver boas aproximações no valor do VPL, resultados estes melhores que os encontrados em Souza et al. (2009).

Este problema também foi estudado em Mendonça et al. (2009), onde uma estratégia de otimização local sequencial foi empregada juntamente com a técnica de krigagem. Nesta referência, os valores do VPL obtidos foram: 1.4925×10^6 , 1.4935×10^6 e 1.4936×10^6 , para os casos de 2, 12 e 24 variáveis, respectivamente. Como pode ser observado na tabela acima os resultados aqui obtidos para tais situações correspondem aos reportados, validando dessa maneira a ferramenta aqui construída.

Para o problema não topado com tempo constante, foram adotados 3 ciclos de controle, totalizando assim 9 variáveis. Para este caso, as variáveis de projeto podem assumir valores no intervalo $0 \leq x_{p,t} \leq 0.75$. Para cada técnica de construção de modelo substituto, este caso foi rodado 40 vezes com cada critério de consideração de restrições (função de penalização ou critério de comparação), utilizando modelos iniciais de 60 pontos iguais para ambas as técnicas de modelos substitutos. Nas Tabelas 3 e 4 são mostrados os resultados obtidos de maneira semelhante a apresentada nas Tabelas 1 e 2.

Restrição	$\mu(f(x^*)) \times 10^6$	$\sigma(f(x^*))$	Melhores $\times 10^6$	Piores $\times 10^6$	NPT_{med}
Penalização	1.571124	2.036341×10^{-1}	1.723783	0.821318	113.7
Comparação	1.520768	3.208738×10^{-1}	1.720388	0.287919	114.6

Tabela 3: Resultados encontrados utilizando krigagem para o caso não topado.

Restrição	$\mu(f(x^*)) \times 10^6$	$\sigma(f(x^*))$	Melhores $\times 10^6$	Piores $\times 10^6$	NPT_{med}
Penalização	1.544106	1.478478×10^{-1}	1.694459	1.077355	118.2
Comparação	1.524333	1.891091×10^{-1}	1.687576	0.661396	119.3

Tabela 4: Resultados encontrados utilizando RNAs para o caso não topado.

Os resultados encontrados pelo PSO para este problema estão próximos do obtido por Horowitz et al. (2009) e se comparados com os resultados presentes em Souza et al. (2010) um considerável ganho no valor do VPL, quando avaliado no modelo de alta fidelidade, foi observado. As duas técnicas para consideração de restrições apresentaram bons resultados. O número de pontos utilizado pela RNA é ligeiramente superior ao utilizado pela krigagem, no entanto, outros estudos sobre como criar uma RNA com características mais apropriadas para o problema em questão ainda serão realizados.

Para o problema topado com tempo variando foram utilizados 5 ciclos de controle, totalizando assim 9 variáveis. Também foram utilizadas amostras iniciais de 45 pontos e foram rodados um total de 40 casos em que a amostra inicial era igual para as duas técnicas de construção de modelos substitutos. Na Tabela 5 são mostrados os resultados obtidos de maneira semelhante a apresentada nas Tabelas 1 e 2.

Modelo Substituto	$\mu(f(x^*)) \times 10^6$	$\sigma(f(x^*))$	Melhores $\times 10^6$	Piores $\times 10^6$	NPT_{med}
Krigagem	1.490371	3.102933×10^{-3}	1.493221	1.475002	88.3
RNA	1.487478	7.083199×10^{-3}	1.492963	1.450280	90

Tabela 5: Resultados encontrados utilizando krigagem e RNAs para o caso topado com tempo variando.

O valor de referência para este problema é de $VPL = 1.4932 \times 10^6$ Horowitz et al. (2010a). As duas técnicas apresentaram resultados bem próximos, com uma pequena superioridade observada para a técnica de krigagem. Assim como no caso anterior, podemos observar que a krigagem utilizou um número menor de pontos que a RNA.

7 CONCLUSÕES

Neste trabalho, uma metodologia automática para o gerenciamento automático da produção de reservatórios de petróleo considerando a estratégia global de otimização utilizando o algoritmo PSO foi apresentada. Objetivando um custo computacional viável, modelos substitutos via Krigagem e redes neurais artificiais foram construídos para serem usados no procedimento de otimização. Um estudo de caso reportado na literatura foi conduzido.

Diferentemente das abordagens tradicionais de PSO no contexto de uso do mesmo em combinação com modelos substitutos, um esquema adaptativo de inclusão de pontos amostrais foi incluído na presente metodologia. Com relação ao caso estudado, a utilização de um esquema de adição de pontos ao modelo substituto mostrou-se uma excelente alternativa tanto para dar uma maior precisão ao modelo na região próxima ao ótimo, quanto para dar a amostra maiores informações sobre a função a ser aproximada.

A técnica de krigagem merece destaque por sua capacidade de gerar bons modelos. Outros estudos sobre a utilização da RNA ainda se fazem necessários, seja na aplicação de outras formas de treinamento ou de outras topologias de rede.

Com relação ao caso estudado, o PSO ainda pode ser testado para o caso não topado com o tempo variando em trabalhos futuros. Estudos sobre sua aplicação utilizando o modelo de alta fidelidade para avaliar a função objetivo considerando um número pequeno de avaliações de função e a sua aplicação na construção de algoritmos híbridos também serão conduzidos.

Embora a aplicação usada como exemplo seja de natureza simples, este foi importante para validar a ferramenta computacional implementada, a partir do confronto com resultados disponíveis reportados na literatura para tal reservatório. Como a mesma é integrada ao simulador IMEX, casos de reservatório mais complexos podem ser facilmente testados. Tais estudos estão em andamento.

REFERÊNCIAS

- Afonso S.M.B., Horowitz B., e Willmersdorf R. Comparative study of surrogate models for engineering problems. In *ASMO-UK/ISSMO International Conference on Engineering Design Optimization*. 2008.
- Cagnina L.C., Esquivel S.C., e Coello C.A.C. Solving engineering optimization problems with the simple constrained particle swarm optimizer. In *Third International Conference on Bioinspired Optimization Methods and their Applications - BIOMA 2008*, páginas 107–120. Ljubljana, Slovenia, Jozef Stefan Institute, 2008.
- Carrero E., Queipo N.V., Pintos S., e Zerpa L.E. Global sensitivity analysis of alkali-surfactant-polymer enhanced oil recovery processes. *Journal of Petroleum Science and Engineering* 58, páginas 30–42, 2007.
- CMG. *IMEX: User's Guide*. Computer Modeling Group LTD, Calgary - Canadá, 2006.
- Demuth H., Beale M., e Hagan M. *Neural Network ToolboxTM 6 User's Guide*. The Mathworks, Inc., 2010.
- Forrester A., Sobester A., e Keane A. *Engineering Design Via Surrogate Modelling: A Practical Guide*. Wiley, 2008.
- Giunta A.A. Use of data sampling, surrogate models, and numerical optimization in engineering design. In *Proceedings of the 40th AIAA Aerospace Sciences Meeting and Exhibit*. Reno, NV, 2002.
- Haykin S. *Redes Neurais: princípios e prática*. Bookman, 2001.
- Horowitz B., Afonso S.M.B., e Mendonça C.V.P. Rate control optimization of waterflooding management. In *XXX Congresso Ibero-Latino-Americano de Métodos Computacionais em Engenharia*. Búzios, Rio de Janeiro, Brasil, 2009.
- Horowitz B., Afonso S.M.B., e Mendonça C.V.P. Using control cycle switching times as design variables in optimum waterflooding management. In *2^ª International Conference on Engineering Optimization*. Lisbon, Portugal, 2010a.
- Horowitz B., Afonso S.M.B., Mendonça C.V.P., e Willmersdorf R.B. Rate control optimization of waterflooding management. *International journal of modeling and simulation for the petroleum industry*, 2010b.
- Horowitz B., Guimarães L.J.N., Dantas V., e Afonso S.M.B. A concurrent efficient global optimization algorithm applied to polymer injection strategies. *Journal of Petroleum Science & Engineering* v.71, páginas 195–204, 2010c.
- Kathrada M. *Uncertainty Evaluation of Reservoir Simulation Models using Particle Swarms and Hierarchical Clustering*. Doutorado, Heriot-Watt University, 2009.

- Keane A.J. e Nair P.B. *Computational Approaches for Aerospace Design: The pursuit of Excellence*. Wiley, 2005.
- Kennedy J. e Eberhart R.C. Particle swarm optimization. In *Proceedings of the IEEE International Conference on Neural Networks*, páginas 1942–1948. Perth, Austrália, 1995.
- Mendonça C.V.P., Carvalho N.F.P., Afonso S.M.B., e Horowitz B. Estratégia local para otimização do gerenciamento de injeção de Água. In *5º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás*. Fortaleza, Ceará, Brasil, 2009.
- Oliveira D.F.B. *Técnicas de Otimização da Produção para Reservatórios de Petróleo - Abordagens sem o uso de Deivadas para Alocação Dinâmica das Vazões de Produção e Injeção*. Mestrado, Universidade Federal de Pernambuco - UFPE, Recife, PE, 2006.
- Oliveira L.C. *Otimização Estrutural Utilizando o Algoritmo do Enxame de Partículas*. Mestrado, Universidade Federal de Pernambuco - UFPE, Recife, PE, 2008.
- Onwunalu J.E. e Durlflosky L.J. Application of a particle swarm optimization algorithm for determining optimum well location and type. *Computational Geosciences 14*, páginas 183–198, 2010.
- Pomeroy P. An introduction to particle swarm optimization. Dez. 2005 <<http://www.adaptativeview.com/articles/ipsoprint.html>>, 2003.
- Sasena M.J. *Flexibility and Efficiency Enhancements for Constrained Global Design Optimization with Kriging Approximations*. Tesis de Doutorado, University of Michigan, Ann Arbor, 2002.
- Shi Y. e Eberhart R.C. A modified particle swarm optimizer. In *Proceedings of the 1998 IEEE International Conference on Evolutionary Computation*. Anchorage, Alasca, 1998.
- Souza S.A., Oliveira L.C., e Afonso S.M.B. Aplicação de modelos substitutos na otimização de estratégias de produção de petróleo utilizando o algoritmo do enxame de partículas. In *XXX Congresso Ibero-Latino-Americano de Métodos Computacionais em Engenharia*. Búzios, Rio de Janeiro, Brasil, 2009.
- Souza S.A., Oliveira L.C., e Afonso S.M.B. Otimização de estratégias de produção de petróleo utilizando algoritmo evolucionário e modelos substitutos. In *VI Congresso Nacional de Engenharia Mecânica*. Campina Grande, Paraíba, Brasil, 2010.