

OTIMIZAÇÃO DE ESTRATÉGIA DE PRODUÇÃO DE PETRÓLEO UTILIZANDO ALGORITMO EVOLUCIONÁRIO E MODELOS SUBSTITUTOS

Samuel Arimatéia de Souza, samuel.arimateia@gmail.com¹

Leonardo Correia de Oliveira, leonardo.cdo@gmail.com¹

Silvana Maria Bastos Afonso, smb@ufpe.br¹

Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Avenida Acadêmico Hélio Ramos, s/n, 50740-530, Recife, Pernambuco, Brasil¹,

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 pelo 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 para construção de modelos substitutos objetivando uma resposta computacional rápida, porém com precisão aferida. 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 no problema de injeção de água em reservatórios de Petróleo.

Palavras-chave: Otimização, Modelos Substitutos, Engenharia Reservatórios

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 and Eberhart, 1995). Este algoritmo é baseado no comportamento de revoada visto em muitas espécies de pássaros e não faz uso do cálculo de gradientes. 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 meta modelos (ou modelos substitutos) está cada vez mais sendo empregada. 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 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. FORMULAÇÃO MATEMÁTICA

Matematicamente, em um problema de otimização qualquer, deseja-se encontrar um conjunto de n variáveis de projeto contidas num vetor \mathbf{x} , que:

Minimize (ou maximize): $f(\mathbf{x})$

Sujeito à:

$$g_i(\mathbf{x}) \leq g_i \quad (i = 1, 2, 3, \dots, m_1) \quad (1)$$

$$h_j(\mathbf{x}) = h_j \quad (j = 1, 2, 3, \dots, m_2) \quad (2)$$

$$\mathbf{x}_k^l \leq \mathbf{x}_k \leq \mathbf{x}_k^u \quad (k = 1, 2, 3, \dots, n) \quad (3)$$

onde x são as variáveis de projeto. A função $f(x)$ é a meta do problema. As funções $g_i(x)$ e $h_j(x)$ representam, respectivamente, as restrições de desigualdade e de igualdade. As restrições geométricas estão representadas pela Eq. (3).

3. 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 and 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 dos 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.

$$p_{t+1}^i = p_t^i + v_{t+1}^i \Delta t \quad (4)$$

Como visto na Eq. (4), 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 é mostrada a seguir (Shi and Eberhart, 1998).

$$v_{t+1}^i = wv_t^i + c_1r_1(pbest^i - p_t^i) + c_2r_2(gbest - p_t^i) \quad (5)$$

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.

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.

4. UTILIZAÇÃO DE MODELOS SUBSTITUTOS: USO DA TÉCNICA DE KRIGAGEM

A teoria de Kriging foi desenvolvida pelo matemático francês Georges Matheron a partir dos trabalhos de Daniel G. Krige (Valente, 1982). Muito usado em geostatística, parte do princípio que os pontos em um dado espaço de projeto são correlacionados. Faz uso de um estimador do tipo BLUE (Best Linear Unbiased Estimator), sendo este linear porque as suas estimativas são combinações lineares ponderadas dos dados existentes, não viciada pois procura que a média dos erros seja nula e é a melhor porque os erros de estimação apresentam uma variância (variância de estimação) mínima.

Na literatura de krigagem (Jones *et al.*, 1998), a verdadeira função pode ser escrita como:

$$f(\mathbf{x}) = \sum_{j=1}^k \beta_j N_j(\mathbf{x}) + Z(\mathbf{x}) \quad (6)$$

Na equação acima a primeira parte é uma regressão linear dos dados com k regressores, e $Z(\mathbf{x})$ (o erro) é uma função aleatória (em geral segue uma distribuição gaussiana normal), com média zero, variância σ^2 , e covariância não nula.

O primeiro termo é responsável pelo aspecto global ou tendência ao longo do espaço de projeto, ao passo que $Z(\mathbf{x})$ é responsável por criar um desvio 'localizado' em relação ao modelo global. A abordagem tradicional é chamada de krigagem ordinária em que uma função de ordem zero (constante) é empregada para o primeiro termo da Eq. (6).

A matriz de covariância $Z(\mathbf{x})$ é dada por:

$$\text{cov}[Z(\mathbf{x}^i), Z(\mathbf{x}^j)] = \sigma^2 \mathbf{R}(x^i, x^j) \quad (7)$$

\mathbf{R} é a matriz de correlação de ordem $m \times m$ com valores unitários ao longo da diagonal e $\mathbf{R}(x^i, x^j)$ é função de correlação entre qualquer dois dos m pontos de dados amostrados x^i e x^j . Diferentes formas de função de correlação podem ser empregadas, como: exponencial, exponencial generalizada, Gaussiana, entre outros.

Neste trabalho considerou-se uma função de correlação Gaussiana da forma:

$$R(x^i, x^j) = \exp\left(\sum_{k=1}^n \theta_k |x_k^i - x_k^j|^2\right) \quad (8)$$

Onde n é o número total de variáveis, θ_k os parâmetros de correlação utilizados para ajustar ao modelo. A expressão do preditor para este modelo é obtida através da minimização do erro médio quadrático, tal como apresentado em Afonso *et al.* (2008).

4.1 Geração de amostras para modelo substituto

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 como (Keane and Nair, 2005):

$$\Delta = \left(\sum_{i=1}^{m-1} \sum_{j=1}^m \frac{1}{(x_j - x_i)^2 + (y_j - y_i)^2} \right) \quad (9)$$

Onde m é o número total pontos da amostra. A amostra LHS que dá o valor máximo para Δ é a amostra selecionada.

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 último 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 está 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:

$$x_{p,t} = \frac{q_{p,t}}{\sum q_{P,t}} \quad (10)$$

onde $q_{p,t}$ é a vazão do poço p no intervalo de tempo t e P representa o grupo dos poços produtores. Diferentemente de Souza *et al.* (2009), foi admitido o funcionamento "não topado" das linhas de injeção e produção. Logo, tais linhas podem ou não operar na sua capacidade máxima. Assim, podemos formular o problema como:

$$\text{Maximizar } VPL = \sum_{\tau=0}^T \left[\frac{1}{(1+d)^\tau} F_\tau(x_{p,t}, \mathbf{u}) \right] \quad (11)$$

Sujeito a:

$$\sum_{p \in P} x_{p,t} \leq 1 \quad t = 1 \dots n_t \quad (12)$$

$$\sum_{p \in I} x_{p,t} \leq 1 \quad t = 1 \dots n_t \quad (13)$$

$$\sum_{p \in P} x_{p,t} \leq \sum_{p \in I} x_{p,t} \leq 1.1 \sum_{p \in P} x_{p,t} \quad t = 1 \dots n_t \quad (14)$$

$$x_{p,t}^l \leq x_{p,t} \leq x_{p,t}^u \quad t = 1 \dots n_t \quad (15)$$

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, como já mencionado no presente trabalho. 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) nos pontos amostrais previamente selecionados. 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. EXEMPLOS

Como exemplo, foi utilizado o Caso1 encontrado em Oliveira (2006). O reservatório, indicado na Fig. (1), 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.

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 $30 \text{ m}^3/\text{dia}$. Outras características do reservatório estudado são apresentadas na Tab. (1).

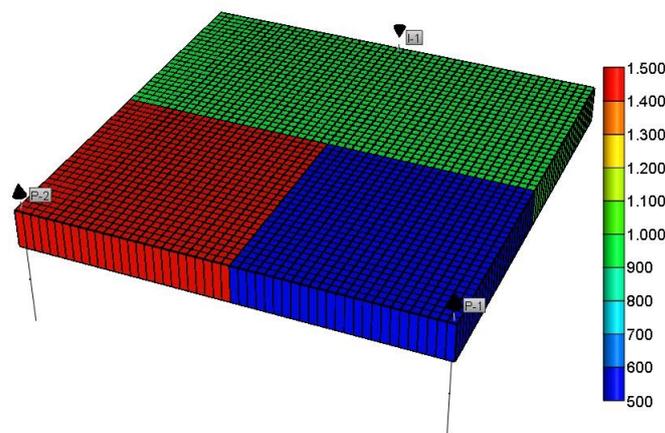


Figura 1. Malha do Reservatório do Caso1

Tabela 1. Características do Reservatório do Caso1

Malha de Simulação	51(510m)x51(510m)x1(4m)
Porosidade	30%
Porosidade vertical k_v	10% de k_h
Compressibilidade da rocha @ 200 kgf/cm	$5 \cdot 10^{-5} (\text{kgf}/\text{cm}^2)^{-1}$
Contatos entre Fluidos	Sem contatos WOC e GOC
Pressão de saturação (P_{sat})	$273 \text{ kgf}/\text{cm}^2$
Viscosidade @ T_{res}, P_{sat}	0.97 cP
Razão Gás-Óleo de Formação (RGOF)	$115.5 \text{ m}^3/\text{m}^3 \text{ std}$

A função objetivo utilizada será o VPL, como indicado na Eq. (11). As variáveis de projeto são os rateios de vazão relacionados a cada poço, produtor ou injetor, em um certo intervalo de tempo. O valor do preço do óleo considerado foi de R\$ 25,00/m³. Para a situação abordada neste trabalho, os poços podem tanto ser fechados quanto operar na sua capacidade máxima. Foram adotados 3 ciclos de controle (intervalos de tempo) como mostrado na Fig. (2), o que resulta num total de 9 variáveis de projeto para o problema.

Foram gerados 40 modelos substitutos diferentes, ou seja, cada um feito com base em uma amostra LHS diferente. Para geração de cada amostra, 10 amostras iniciais eram geradas e a melhor entre elas selecionadas utilizando a Eq. (9), sendo cada amostra composta de 60 pontos.

Em cada modelo gerado, o PSO realizou um total de 15000 iterações. Foram testadas duas configurações do PSO quanto ao valor da inércia. Na primeira, denominada PSO_{wfix} , foi considerada a inércia $w = 0.7$, com esse valor fixo durante todo o processo. A segunda configuração, PSO_{wvar} , utilizou o critério de atualização da inércia descrito em Oliveira (2008), com valor inicial de 1.2. Foram testados também os dois critérios para lidar com as restrições. Logo, a

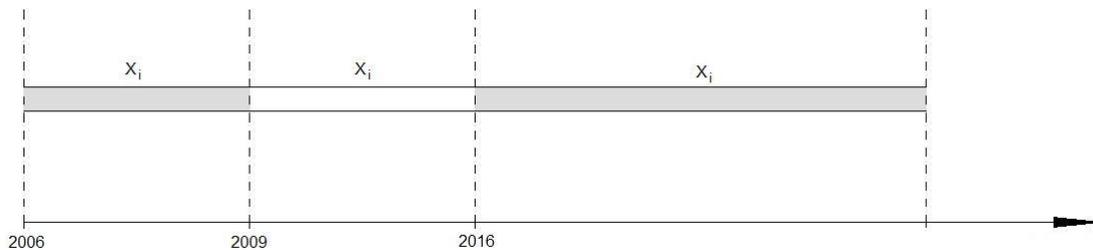


Figura 2. Ciclos de Controle Adotados

primeira configuração do PSO, PSO_{wfix} , utilizando função de penalidade é denominado como PSO_{wfix}^p , enquanto ao utilizar o segundo critério é denominado PSO_{wfix}^i . O PSO_{wvar} é nomeado de forma semelhante, totalizando assim 4 configurações distintas do PSO.

Na Tabela (2) são mostrados os melhores e piores valores encontrados enquanto na Tab. (3) são mostrados a média $\mu(f(x^*))$ e o desvio padrão $\sigma(f(x^*))$ dos resultados obtidos.

Tabela 2. Melhores e piores valores encontrados pelo modelo substituto via krigagem

	Melhores ($\times 10^6$)	Piores ($\times 10^6$)
PSO_{wfix}^p	1.7367	0.9386
PSO_{wfix}^i	1.7666	1.0751
PSO_{wvar}^p	1.7404	0.9685
PSO_{wvar}^i	1.7330	0.9613

Tabela 3. Média $\mu(f(x^*))$ e o desvio padrão $\sigma(f(x^*))$ dos resultados

	$\mu(f(x^*))$ ($\times 10^6$)	$\sigma(f(x^*))$
PSO_{wfix}^p	1.5041	0.1707
PSO_{wfix}^i	1.5586	0.1652
PSO_{wvar}^p	1.5133	0.1588
PSO_{wvar}^i	1.4765	0.2108

O melhores valores encontrados pelo PSO, considerando o valores obtidos com os modelos substitutos, foram superiores ao encontrado por Horowitz *et al.* (2009), onde é utilizada uma estratégia de otimização sequencial juntamente com a técnica de krigagem (*Sequential Approximate Optimization - SAO*). Nesta referência, o valor encontrado foi de $VPL=1.7246 \times 10^6$. Os valores das variáveis de projeto obtidos para o melhor resultado utilizando o PSO juntamente com aquele reportado em Horowitz *et al.* (2009) estão apresentados na Tab. (4), sendo T_i os ciclos de controle adotados no problema, com $i=1,2,3$. Destaca-se mais uma vez que as variáveis de projeto estão normalizadas com relação ao valor máximo dos fluidos produzidos. Observa-se a partir da Tab. (4) que na solução via SAO o campo todo é fechado no último ciclo de controle, enquanto a solução via o PSO indica o fechamento apenas do poço produtor P-2.

Tomando a solução obtida via PSO_{wfix}^i e conduzindo uma simulação utilizando o modelo de alta fidelidade, obteve-se como resposta para o VPL o valor de 1.5807×10^6 , o que corresponde a uma diferença de 11,7%. Tal diferença é justificada pelo fato de as soluções via PSO com o modelo substituto apresentarem elevada produção de água até o final do período de concessão tal como apresentado na Tab. (4) e ilustrado graficamente na Fig. (3). Nesta figura estão plotadas as curvas da produção acumulada de óleo e de água obtidos da otimização via as quatro configurações investigadas do PSO e a solução via a técnica SAO.

Como visto na Fig. (3), os resultados encontrados pelo PSO conseguem obter uma produção acumulada de óleo próxima da encontrada pelo SAO, exceto o resultado encontrado pelo PSO_{wvar}^p . No entanto, todas as curvas de produção acumulada de água encontradas pelo PSO estão acima da encontrada pelo SAO. Com isso, ao se realizar a simulação no modelo de alta fidelidade com as vazões obtidas pelo PSO, o VPL é menor que o valor encontrado pelo SAO. Porém, a utilização do modelo de krigagem se justifica pelo grande número de avaliações de função necessárias pelo PSO, o que poderia inviabilizar o uso deste algoritmo para este problema. Objetivando melhorar a solução do PSO + Krigagem como um todo, pretende-se como continuidade desse estudo, utilizar um esquema do PSO adaptativo onde modelos de krigagem

Tabela 4. Comparação das soluções encontradas pelo PSO_{wfix}^i e pelo SAO

Ciclo de controle	PSO_{wfix}^i			SAO		
	P-1	P-2	I-1	P-1	P-2	I-1
T ₁	0.7500	0.2500	1.1000	0.451	0.549	1.015
T ₂	0.3739	0.0712	0.4451	0.306	0.076	0.382
T ₃	0.7500	0	0.7510	0	0	0

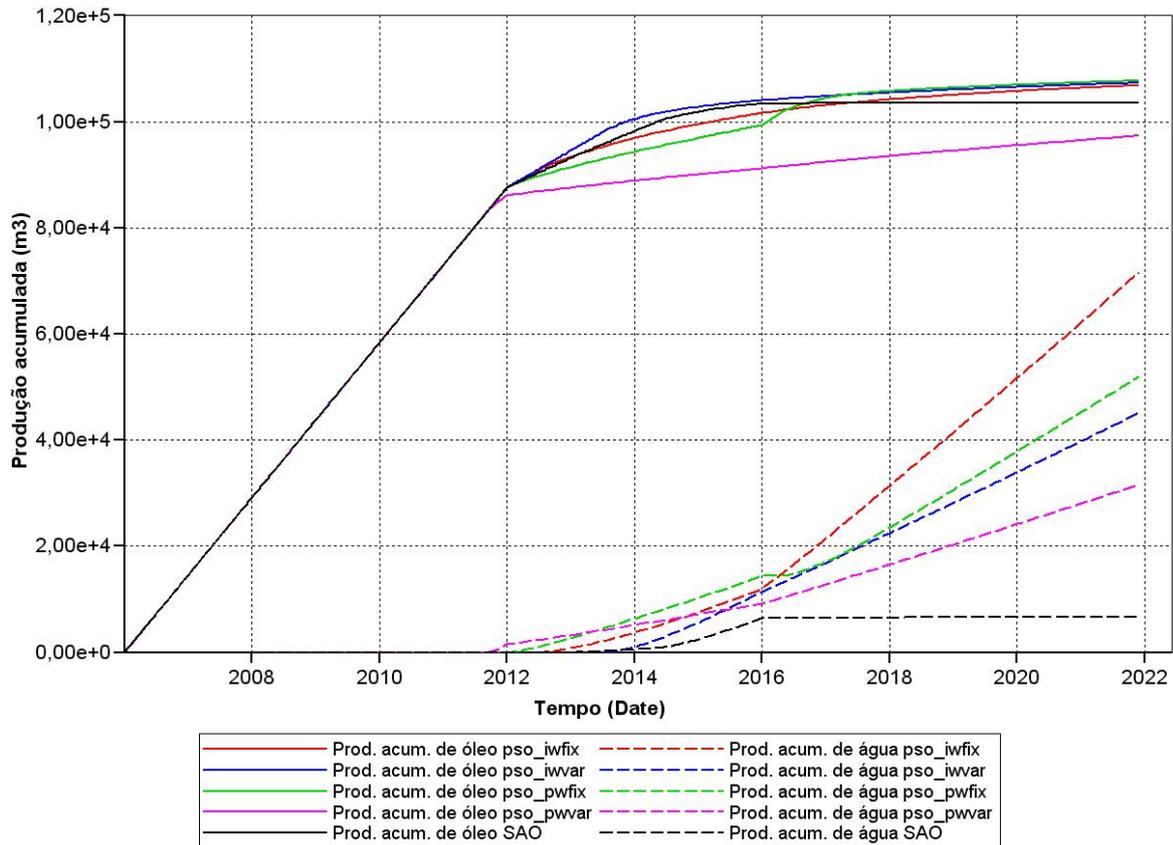


Figura 3. Curvas de Produção Acumulada de Óleo e Água

hierárquicos serão construídos ao longo de todo o processo da otimização global.

7. CONCLUSÕES

O problema de injeção de água sob a condição de gerenciamento não topado foi estudado neste artigo. Na busca de uma solução para tal problema, foi utilizado o algoritmo de busca global PSO. Objetivando a redução do custo computacional, modelos substitutos utilizando a técnica de krigagem foram construídos de forma que o otimizador opera diretamente nos mesmos. Os resultados obtidos foram comparados com o esquema local SAO. Os resultados encontrados pelo PSO, em termos de VPL, apresentaram valores superiores aos encontrados pelo SAO. Porém, quando as soluções otimizadas via PSO foram aferidas no modelo de alta fidelidade observou-se uma diferença percentual média no valor do VPL de 10%. Neste sentido, novos estudos estão sendo conduzidos objetivando reduzir o erro devido ao uso do modelo substitutos.

8. REFERÊNCIAS

- Afonso, S.M.B., Horowitz, B. and Willmersdorf, R., 2008. "Comparative study of surrogate models for engineering problems". In *ASMO-UK/ISSMO International Conference on Engineering Design Optimization*.
- Cagnina, L.C., Esquivel, S.C. and Coello, C.A.C., 2008. "Solving engineering optimization problems with the simple

- constrained particle swarm optimizer”. In *Third International Conference on Bioinspired Optimization Methods and their Applications - BIOMA 2008*. Ljubljana, Slovenia, Jozef Stefan Institute, pp. 107–120.
- CMG, 2006. *IMEX: User's Guide*. Computer Modeling Group LTD, Calgary - Canadá.
- Forrester, A., Sobester, A. and Keane, A., 2008. *Engineering Design Via Surrogate Modelling: A Practical Guide*. Wiley.
- Giunta, A.A., 2002. “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.
- Horowitz, B., Afonso, S.M.B. and Mendonça, C.V.P., 2009. “Rate control optimization of waterflooding management”. In *XXX Congresso Ibero-Latino-Americano de Métodos Computacionais em Engenharia*. Búzios, Rio de Janeiro, Brasil.
- Jones, D.R., Scgonlau, M. and Welch, W.J., 1998. “Efficient global optimization of expensive black-box functions”. *Journal of Global Optimization*, pp. 455–492.
- Keane, A.J. and Nair, P.B., 2005. *Computational Approaches for Aerospace Design: The pursuit of Excellence*. Wiley.
- Kennedy, J. and Eberhart, R.C., 1995. “Particle swarm optimization”. In *Proceedings of the IEEE International Conference on Neural Networks*. Perth, Austrália, pp. 1942–1948.
- Oliveira, D.F.B., 2006. *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.
- Oliveira, L.C., 2008. *Otimização Estrutural Utilizando o Algoritmo do Enxame de Partículas*. Mestrado, Universidade Federal de Pernambuco - UFPE, Recife, PE.
- Pomeroy, P., 2003. “An introduction to particle swarm optimization”. Dez. 2005 <<http://www.adaptativeview.com/articles/ipsoprnt.html>>.
- Shi, Y. and Eberhart, R.C., 1998. “A modified particle swarm optimizer”. In *Proceedings of the 1998 IEEE International Conference on Evolutionary Computation*. Anchorage, Alasca.
- Souza, S.A., Oliveira, L.C. and Afonso, S.M.B., 2009. “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.

9. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material impresso incluído neste trabalho.

OPTIMIZATION OF OIL PRODUCTION STRATEGY USING EVOLUTIONARY ALGORITHM AND SURROGATE MODELS

Samuel Arimatéia de Souza, samuel.arimateia@gmail.com¹

Leonardo Correia de Oliveira, leonardo.cdo@gmail.com¹

Silvana Maria Bastos Afonso, smb@ufpe.br¹

Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Avenida Acadêmico Hélio Ramos, s/n, 50740-530, Recife, Pernambuco, Brasil¹,

Abstract: The optimization of the control production and injection rates is a subject of great importance for reservoir Engineering. During this process commonly reservoir simulation are performed to model its behavior to help the definition of strategies to be used. In this work, the optimization will be conducted by a Particle Swarm Optimization (PSO) algorithm. This algorithm is based on birds fly behavior and does not consider gradient calculations. However, a large number of function evaluations is necessary, which for the type of problem tackled here, each evaluation means a complete reservoir simulation, that could demand a high computational cost to obtain an optimum design. In response to this drawback, kriging technique will be used to build a metamodel with the aim to obtain fast computational responses, with accuracy checks. In the combination of the proposed strategies, the functions evaluations required by the optimizer will be performed directly on the metamodels. In this work a rate control management for different control cycles in the waterflooding optimization problem is analysed.

Keywords: Optimization, Surrogate Models, Reservoir Engineering