

SISTEMA DE OTIMIZAÇÃO DO MODELO DE ALOCAÇÃO E CONTROLE DE VÁLVULAS INTELIGENTES SOB INCERTEZA TÉCNICA

RENATA GARCIA OLIVEIRA* LUCIANA FALETTI ALMEIDA* JUAN G. LAZO LAZO† LAERCIO BRITO GONÇALVES*

**Department of Electrical Engineering, Centro Federal de Educação Tecnológica Celso Suckow da Fonseca*

Avenida Maracanã, 229 Maracanã, CEP 20.271-110 - Rio de Janeiro, Brasil

*†Academic Department of Engineering, Universidad del Pacífico, Lima, Perú
Av. Salaverry 2020, Jesus Maria, Lima 11 - Perú*

Email: renata.garcia.eng@gmail.com lucianafaletti@gmail.com jg.lazo@up.edu.pe
laerciobrito74@gmail.com

Abstract— This paper presents a decision support system that is able to optimize both the allocation of valves, as well as their proactive control strategy (unwanted event forecasting) in smart oil fields. Due to the high costs associated with the technologies required to implement a smart oil field, a decision support system specific to the area is often necessary. Such system must be able to indicate not only the ideal positioning for the valves, but also a proactive control strategy, aiming to ensure the economic viability of the exploration project. To this end, an CCGA is utilized in order to suggest both the allocation spots for the valves in the wells, as well as the proactive control strategy for those valves, in order to maximize the net present value (NPV) for the following years of production. This algorithm is hybridized with the Monte Carlo Simulation technique and will perform a risk analysis for the proactive control strategy of the oil field's production, aiming to demonstrate how the technical uncertainties of the valves' eventual failure may or may not harm the project to the point of paralyzing it. In order to evaluate and validate the proposed and implemented model, a synthetic reservoir with geological characteristics that allow for a clear understanding of the results was created.

Keywords— Smart Oil Fields, Intelligent Systems, Cooperative Coevolution Genetic Algorithm, Technical Uncertainties, Intelligent Decision Support System

Resumo— Este artigo apresenta um sistema de apoio a decisão capaz de otimizar tanto a alocação de válvulas como a estratégia de controle proativa (previsão de evento indesejado) dessas válvulas em campos inteligentes de petróleo. Devido aos altos custos associados às tecnologias, que são necessárias para a implementação de um campo inteligente de petróleo, torna-se frequente a necessidade de sistemas que apoiem a tomada de decisão nesta área específica, apontando não só a alocação ideal de válvulas como uma estratégia de controle proativa visando um projeto de exploração economicamente viável. Com este propósito, um Algoritmo Genético Coevolucionário Cooperativo (AGCC) é utilizado para sugerir pontos de alocação das válvulas nos poços, além de uma estratégia de controle proativa para essas válvulas, de forma a maximizar o VPL (Valor Presente Líquido) para os próximos anos de produção. Esse algoritmo é hibridizado com a técnica de Simulação Monte Carlo, visando demonstrar a influência das incertezas técnicas de falha das válvulas a ponto de inviabilizar, ou não, o projeto, através da realização de uma análise do risco para a estratégia de controle proativo da produção do campo. Para avaliar e validar o modelo proposto e implementado, foi criado um reservatório sintético com características geológicas que permitem a interpretação clara dos resultados.

Palavras-chave— Campos de Petróleo Inteligentes, Sistemas Inteligentes, Algoritmo Genético Coevolucionário Cooperativo, Incertezas Técnicas, Sistema de Apoio à Decisão Inteligente

1 Válvulas de Controle Inteligente na Indústria de Petróleo

Dentre as novas tecnologias encontradas nos Campos Inteligentes (CI) estão as Válvulas de Controle Inteligente (VCI) que compõem os chamados Poço Inteligente (PI) (Almeida, 2010). A VCI pode ser definida como um sistema capaz de coletar, analisar e transmitir dados para o acionamento remoto de dispositivos de controle de fluxo com o objetivo de otimizar a produção de óleo do reservatório. Entretanto, esta tecnologia tem um alto custo associado, além de ser relativamente recente. Também não há muitos dados relativos à sua confiabilidade ou melhor forma de utilização. Há, assim, receio em aprovar sua implantação, especialmente por não existir, ainda, uma metodologia padronizada para o cálculo de seus benefícios.

Segundo Sampaio (2012), CI têm aplicações restritas a poucos campos de óleo. Em muitos deles, são usados em fase de teste ou na tentativa de solucionar problemas específicos. Barreto (2014) apresentou o uso de VCI na melhoria da extração de óleo, no aumento do lucro e na redução do risco de uma produção antecipada de fluidos indesejados. Além de evitar intervenções desnecessárias em campos de petróleo.

A complexidade desse problema é alta, pois um CI pode ter vários poços com várias VCI instaladas, sejam poços produtores ou injetores. Sendo assim, é notável a necessidade de se ter uma metodologia capaz de simular cenários de alocação e controle dessas válvulas visando o máximo desempenho do campo. A complexidade do problema, atrelado a necessidade do uso de um simulador de

reservatórios, inviabiliza o uso de métodos tradicionais de otimização.

Alguns trabalhos demonstram o investimento no uso de métodos de otimização para buscar uma metodologia que apoie essa problemática. Em Almeida (2010), foi apresentado um sistema suporte a decisão usando Algoritmo Genético (AG) e métodos de tratamento de incertezas técnicas e geológicas que visava o controle proativo das válvulas. Já em Barreto (2014), foi apresentado um processo rápido de otimização dinâmico utilizando indicadores técnicos e econômicos. No seu trabalho subsequente com Sampaio (2015), foi criado um método de otimização assistido, que, através de um AG, realiza a localização e a otimização de válvulas em poços produtores.

Neste trabalho, é proposto um sistema de apoio a decisão, baseado em Algoritmo Genético Coevolucionário Cooperativo (AGCC) capaz de propor a localização e estratégia de controle proativo de válvulas inteligentes em uma alternativa de desenvolvimento de campo inteligente, contendo poços injetores e produtores. O algoritmo é híbrido com a técnica de Simulação Monte Carlo, visando o tratamento de incertezas técnicas, ou seja, possibilidade de falhas nas válvulas. A partir dos resultados, o especialista obtém subsídios para decidir em quais completações utilizar VCI em um projeto de produção petrolífera, além de obter as características de um possível cenário de controle otimizado e um estudo do risco da alternativa de produção.

Este artigo está descrito em quatro seções adicionais. A seção 2 descreve a modelagem do Sistema de Otimização sob Incertezas e análise de risco. A seção 3 apresenta o estudo de caso e a seção 4 as conclusões.

2 Sistema de Otimização do Modelo de Alocação e Controle das Válvulas

O sistema é composto por um módulo de otimização (AGCC), um módulo de função objetivo, que contém um simulador de reservatórios (CMG, 2000) e o cálculo de VPL, e um módulo de tratamento de incerteza, conforme a figura 1. Adicionalmente, a solução obtida é submetida a uma análise de risco.

2.1 Algoritmo Genético Coevolutivo

Ao aplicar algoritmos evolucionários em problemas com grande complexidade, deve-se ter o compromisso de ter uma modelagem que represente critérios relevantes para a busca de uma solução ótima com a capacidade de manter a modelagem eficiente. Potter and De Jong (2000) propõe a modelagem explícita de coevolução de espécies cooperativas, ou seja, divisão do problema em subcomponentes, permitindo: espaços evolutivos in-




Figura 1: Componentes do Sistema.

dependentes; aumento da pressão seletiva; e entrega de indivíduos ótimos de cada subpopulação compoem a avaliação da solução final. Esse modelo é conhecido como Algoritmo Genético Coevolucionário Cooperativo e para sua instanciação é importante definir a modelagem do problema e a política de avaliação (Wiegand et al., 2001). Este trabalho possui como contribuição a modelagem das subcomponentes para representação do problema proposto, descrito na seção 2.2. A política de avaliação considera a seleção do mais apto para cooperação na avaliação da outra subpopulação.

2.2 Módulo de Otimização da Localização e Controle das Válvulas

Esse módulo implementa o modelo AGCC com duas subpopulações. Em uma subpopulação, é modelada a localização das Válvulas de Controle Inteligente (VCI). Isto é, define quais completações dos poços existentes no campo receberão VCI. Na outra, é modelada a estratégia de controle proativa das VCI ao longo do ciclo de vida do reservatório.

É importante frisar a versatilidade que essa abordagem apresenta, pois diferente de Barreto (2014) e Sampaio (2015) não há passos subsequentes nem tentativa de redução do espaço de busca. Nessa abordagem, ambas as decisões (localização e controle) são tomadas de forma dinâmica e contínua. Isso permite a busca pela solução ótima global no espaço de busca, embasada na capacidade de convergência do AGCC.

A solução de localização otimiza a quantidade e posição das VCI. Sua composição é binária e o espaço de busca representa 2^{n_c} , sendo n_c quantidade de completações. Caso a completação receba a VCI a variável assume o valor binário 1, caso não, assume o valor binário 0.

A modelagem do controle proativo das VCI segue os seguintes critérios:

- Para a atuação do controle proativo das vál-

vulas são realizadas 10 intervenções de controle (i_c) nas VCI, pois o ciclo de vida do reservatório é de 20 anos e a intervenção para controle ocorrerá a cada 2 anos;

- Cada cromossomo possui a configuração de operação de controle proativo para todas as possíveis VCI em todos os intervalos de tempo de intervenção do reservatório;
- Caso o poço tenha no mínimo uma válvula, ele é considerado um Poço Inteligente (PI), caso não tenha VCI é considerado um Poço Convencional (PC). Essas definições são importantes no momento de considerar o custo implantação de cada poço;
- Cada variável de controle pode assumir os valores reais no intervalo de $[0,1]$ com uma casa decimal. Assim os valores assumidos são 1.0 para totalmente aberta, 0.0 para totalmente fechada e 9 posições intermediárias de funcionamento da válvula; e
- O espaço de busca para a previsão de controle das válvulas é definido por $11^{i_c * n_c}$, sendo i_c a quantidade de intervenções definidas e n_c a quantidade de completações que recebem válvulas.

Os operadores utilizados na população binária (localização) foram crossover de um e dois pontos e mutação binária. Já os operadores utilizados na população real (controle proativo), conforme Michalewicz (1996), foram cruzamentos aritmético simples e mutação uniforme.

2.3 Função de Avaliação

A medida de avaliação dos indivíduos da população é o VPL, pois possui vasto uso na literatura (Almeida, 2010; Barreto, 2014; Sampaio, 2015). Para obter o VPL é necessário decodificar o indivíduo de localização e o indivíduo de controle em informação de modelagem dos poços do reservatório no formato que serve de entrada para o simulador de reservatórios (CMG, 2000). Após a simulação é calculado o VPL com os dados do modelo de poços e de válvulas e com os dados gerados de produção de óleo e de água ao longo do ciclo de vida do reservatório. A equação 1 descreve VPL como sendo a diferença entre o Valor Presente (VP) — fluxo de caixa descontado — e o Custo de Desenvolvimento das Válvulas (D_v).

$$VPL = VP - D_v \quad (1)$$

A equação 2 apresenta a fórmula do D_v do reservatório e a tabela 1 apresenta o custo de cada componente: a Válvula; o *Packer*, isolante no poço; o *Flat Packer*, cabo de transmissão de dados; e a unidade de Potência Elétrica (HPU), que

gera potência para acionar as válvulas. É interessante notar que o custo do reservatório aumenta conforme aumenta a quantidade de válvulas inteligentes, assim como seus custos de manutenção em caso de pane no equipamento, ressaltando a relevância da otimização da operação das válvulas para aumento do lucro.

$$D_v = (C_v + C_p) * n_v + C_{FP} * n_p + C_{HPU}, \text{ em que } \begin{cases} n_v = \text{quantidade de válvulas inteligentes; e} \\ n_p = \text{quantidade de poços inteligentes.} \end{cases} \quad (2)$$

Potência Elétrica (C_{HPU})	\$200.000/reservatório
<i>Flat Packer</i> (C_{FP})	\$117.000/poço
<i>Packer</i> (C_p)	\$80.000/válvula
Válvula (C_v)	\$100.000

Tabela 1: Custo de Desenvolvimento do Reservatório Inteligente

O Valor Presente (VP) é composto pela diferença entre o somatório do Valor da Receita (V_R) e do C_{op} (Custo Operacional) descontado a uma taxa de juros ($\rho = 0.1$), representando o valor atual de pagamentos futuros, conforme equação 3. O V_R é a multiplicação da produção de óleo ($Q(t_i)$) e do preço do petróleo (P_{oil}). Já para o cálculo do C_{op} , considera o custo de água produzida (C_w), ou seja da água separada do óleo extraído, multiplicado pelo fluxo de água ($W(t_i)$). Esses valores são medidos ao longo tempo de produção (t_i), até o seu fim, em que T é igual 20 anos.

$$VP = \sum_{i=1}^T [Q(t_i) * P_{oil} - W(t_i) * C_w] * e^{-\rho * t_i} \quad (3)$$

2.4 Módulo de Tratamento de Incerteza de Falhas

As válvulas presentes em poços inteligentes não são totalmente confiáveis, assim a análise do risco é necessária devido à incerteza de falha nas válvulas. Os casos de falhas das válvulas podem tornar inviável a produção de petróleo, o que mudaria a decisão de usar Poço Inteligente (PI) em um projeto.

Nesse trabalho, as falhas são modeladas através da distribuição de probabilidade Weibull. Desta distribuição são sorteados cenários de funcionamento (normal ou com falha) das válvulas em função do tempo de uso no reservatório de petróleo (Almeida, 2010). Foram utilizadas técnicas de amostragem baseadas em sequências de baixa discrepância — que se empregadas na simulação Monte Carlo são conhecidas como Quase

Monte Carlo (Wang, 2001) — em que a seleção dos valores da amostra é controlada. Dessa forma, consegue-se amostrar adequadamente uma distribuição de probabilidade com um número menor de amostras, acelerando a convergência, diminuindo o custo computacional das simulações e melhorando a eficiência.

Nesta modelagem, supõe-se que após a ocorrência de uma falha em um determinado intervalo, a válvula permanece em falha nesse intervalo, sendo colocada no estado de aberta e não sendo reparada. A figura 1, ilustra de forma mais detalhada a inserção da incerteza de falha no algoritmo coevolucionário.

O VPL (Valor Presente Líquido) da solução obtida na otimização com a simulação Monte Carlo para a estratégias de produção representa a média da distribuição dos VPL. Sendo o risco a possibilidade de perda, que está relacionado com o tamanho do investimento e probabilidade de ocorrência.

Neste trabalho, foram empregadas como métricas de risco o *value-at-risk* (VaR) que define a perda máxima esperada ao fim de um período para um determinado grau de confiança dado (Jorion, 2006), e o *Conditional Value At Risk* (CVaR), que representa o excesso de perda médio (Uryasev, 2000). Assim, se ocorrem perdas, o montante das perdas poderá ter um valor significativo.

O VaR é calculado de forma não paramétrica, derivando a distribuição de probabilidade do VPL da estratégia de produção obtida da simulação Monte Carlo e constroem-se o histograma e a função de distribuição acumulada dos VPL, definindo o nível de confiança de 95%. O CVaR é obtido pela média das perdas superiores ao valor em risco (VaR).

$$CVaR = \sum_{i=1}^N (Probab. * VPL_{abaixo\ do\ VaR}) \quad (4)$$

3 Estudo de Caso

O sistema será testado utilizando um reservatório sintético, criado com características que tornam clara a atuação das válvulas no campo. O reservatório consiste em uma malha de 40 x 11 x 3 blocos, nas direções i, j, k ; cujas dimensões são de aproximadamente 50,0 x 50,0 x 10,0 metros. Os valores geológicos do reservatório são os seguintes:

- Permeabilidade:
 - 500,0 (md) nas direções i, j 1º camada;
 - 800,0 (md) nas direções i, j 2º camada;
 - 1200,0 (md) nas direções i, j 3º camada;
 - 50,0 (md) na direção k da 1º camada;
 - 70,0 (md) na direção k da 2º camada; e

120,0 (md) na direção k da 3º camada.

- Porosidade: 0,20.

A característica principal deste modelo é a existência de três camadas com permeabilidades diferentes que são isoladas por barreiras de folhelhos. A alternativa de poços utilizada nos testes realizados nesse reservatório é composta de poços verticais que perfuram as 3 zonas, sendo um poço injetor na posição $i, j = (1, 6)$ e um poço produtor em $i, j = (40, 6)$, conforme a figura 2.




Figura 2: Modelo de Reservatório e Alternativa utilizada nos testes.

3.1 Teste 1 - Sem Incerteza de Falhas

Esse teste realiza a otimização do modelo de operação das VCI no reservatório sintético. A tabela 2 apresenta os parâmetros do AGCC. Esses valores são baseados no trabalho de Almeida (2010).

Parâmetros do AGC	Teste 1
Número de gerações	150
Número de indivíduos	70
Número de rodadas	1
Steady State	0,4
Taxa de <i>crossover</i> inicial	0,65
Taxa de mutação inicial	0,08
Total de Simulações	10.500

Tabela 2: Teste 1 - Parâmetros do AGCC.

Tabela 3: Teste 1 - Configuração do Controle Proativo Otimizado

Tempo (Anos)	Válvula 1 (Injetor) Camada do meio	Válvula 2 (Injetor) Última Camada
0-2	Fechada	0,2
2-4	0,6	Fechada
4-6	Fechada	0,6
6-8	0,5	Fechada
8-10	0,3	0,9
10-12	0,6	Fechada
12-14	0,3	0,5
14-16	0,2	0,7
16-18	0,2	Fechada
18-20	0,2	0,4

Após a otimização, o poço produtor manteve-se um Poço Convencional (PC) e o poço injetor

tornou-se um Poço Inteligente (PI). Nesse último, as duas últimas completações receberam VCI e a sua configuração de abertura é apresentada na tabela 3. É muito importante notar que as VCI localizaram-se nas camadas de maior permeabilidade (maior facilidade ao fluxo de fluidos através do meio poroso). Posição em que há necessidade de controle da injeção de água, que serve para empurrar o óleo, formando uma frente vertical de água, nas 3 zonas que não se comunicam devido aos folhelhos.

Os VCI atuaram no controle do fluxo de água, evitando o avanço abrupto. Esse comportamento é mais facilmente verificado quando na comparação da figura 3 e 4. No caso controlado, o avanço da frente de água é mais uniforme, do que o caso base, que é formado apenas por Poços Convencionais (PC) sem válvulas. A tabela 4 apresenta os resultados dessa otimização, em que há o aumento na produção de óleo e gás e menor produção de água em comparação ao caso base.




Figura 3: Condição do Campo - Caso Base




Figura 4: Condição do Campo - Caso Controlado

Tabela 4: Teste 1 - Caso Base vs Caso Controlado.

Caso	VPL (US\$)	Óleo Ac. (m ³)	Água Ac. (m ³)
Base	128.412.195	2.025.580	740.300
Controlado	133.892.511	2.138.620	613.279
Aumento %	4,3	5,6	-17,2

3.2 Teste 2 - Com Incerteza de Falhas

A tabela 5 apresenta os parâmetros do AGCC do Teste 2.

Tabela 5: Teste 2 - Parâmetros do AGCC.

Parâmetros	Valor
Número de gerações	30
Número de indivíduos	20
Número de rodadas	1
Steady State	0,4
Taxa de <i>crossover</i> inicial	0,65
Taxa de mutação inicial	0,08
Número de interações Monte Carlo	500

Conforme análise da seção 3.1, as VCI são localizadas nas duas últimas completações do poço injetor. A tabela 6 apresenta a configuração de controle das válvulas encontradas.

Tabela 6: Teste 2 - Configuração do Controle Proativo Otimizado considerando Incerteza de Falha.

Tempo (Anos)	Válvula 1 (Injetor) Camada do meio	Válvula 2 (Injetor) Última Camada
0-2	0,3	fechada
2-4	0,3	0,1
4-6	aberta	aberta
6-8	aberta	aberta
...	...	...
18-20	aberta	aberta

A tabela 7 apresenta a diferença percentual de VPL, Óleo Acumulado e Água Acumulada entre os casos base e controlado, sendo o caso base formado por poços convencionais, sem válvulas. Mesmo considerando falhas o caso controlado teve um aumento no VPL, na produção de óleo e menor produção de água comparado com o caso base.

Tabela 7: Teste 2 - Caso Base vs Caso Controlado com Incerteza de Falha.

Caso	VPL (US\$)	Óleo Ac. (m ³)	Água Ac. (m ³)
Base	128.412.195	2.025.580	740.300
Controlado	130.959.546	2.117.400	636.790
Aumento %	2,0	4,5	-14,0

A figura 5 ilustra o histograma dos VPL do caso controlado, obtidos da simulação Monte Carlo durante processo de otimização. Verifica-se que todos os VPL são positivos com valores acima de 122 milhões, o que comprova a viabilidade do projeto, mesmo considerando as incertezas de falha nas válvulas e o não reparo em caso de falha.

A tabela 8 apresenta as estatísticas da distribuição de VPL e as métricas de risco (VaR e




Figura 5: Histograma dos VPL do caso controlado.

CVaR) para um intervalo de confiança de 95%. Observa-se que o uso de poços inteligentes não apresenta risco significativo com respeito ao caso base.

Tabela 8: Estatísticas da Distribuição de VPL e Métricas de Risco.

Métrica	(MM US\$)
VPL médio	130,96
Desvio Padrão VPL	2,95
VaR (95%)	125,33
CVaR	124,25

4 Conclusão

Neste trabalho, foi realizada a modelagem e desenvolvimento de um sistema de otimização de localização, quantidade e controle de válvulas de poços inteligentes sob incertezas de falha. Empregou-se Algoritmo Genético Coevolucionário Cooperativo (AGCC) para modelar o processo de otimização junto com simulação Monte Carlo para o tratamento das incertezas. O sistema é capaz de dar suporte à tomada de decisão pelo uso ou não de poços inteligentes sob incerteza e otimizar uma estratégia proativa de controle de válvulas, existentes em poços inteligentes, de uma certa alternativa.

Os resultados encontrados indicam de forma expressiva que as técnicas de computação evolucionária podem tornar-se uma boa ferramenta de apoio à decisão para viabilizar o uso de poços inteligentes em um dado reservatório, confirmando o objetivo deste estudo. Os valores obtidos nos testes indicam ganhos significativos do uso da completação inteligente através do aumento no fator de recuperação do campo, da redução dos volumes de água produzida e do prolongamento da vida dos poços e do reservatório sem apresentar um risco significativo.

Agradecimentos

Agradecemos ao CEFET-RJ e a FAPERJ (FAPERJ N° 41/2013 e FAPERJ N° 15/2015) pelos incentivos financeiros que permitiram a execução desse trabalho. Além do Centro de Pesquisas e Desenvolvimento (Cenpes) da Petrobrás que forneceu a descrição do campo para pesquisa.

Referências

- Almeida, L. F.; Vellasco, M. P. M. (2010). Optimization system for valve control in intelligent wells under uncertainties, *Journal of Petroleum Science and Engineering* **73**(1-2): 129–140.
- Barreto, C. E. A. G.; Schiozer, D. J. (2014). Optimal placement design of inflow control valve using a dynamic optimization process based on technical and economic indicators, *Journal of Petroleum Science and Engineering* **125**: 117–127.
- CMG (2000). *IMEX Advanced Oil/Gas Reservoir Simulator Version 2000 User's Guide*.
- Jorion, P. (2006). *Value at Risk: The New Benchmark for Managing Financial Risk, 3rd Edition*, McGraw-Hill.
- Michalewicz, Z. (1996). *Genetic Algorithms + Data Structures = Evolution Programs (3rd Ed.)*, Springer-Verlag, London, UK, UK.
- Potter, M. A. and De Jong, K. A. (2000). Cooperative coevolution: An architecture for evolving coadapted subcomponents, *Evol. Comput.* **8**(1): 1–29.
- Sampaio, M. A.; Barreto, C. E. A. G. S. D. J. (2012). Optimization of Proactive Control Valves of Producer and Injector Smart Wells under Economic Uncertainty.
- Sampaio, M. A.; Barreto, C. E. A. G. S. D. J. (2015). Assisted optimization method for comparison between conventional and intelligent producers considering uncertainties, *Journal of Petroleum Science and Engineering* **133**: 268–279.
- Uryasev, S. (2000). Conditional value-at-risk: optimization algorithms and applications, pp. 49–57.
- Wang, X. (2001). Variance reduction techniques and quasi-monte carlo methods, *Journal of Computational and Applied Mathematics* **132**(2): 309 – 318.
- Wiegand, R. P., Liles, W. C. and Jong, K. A. D. (2001). An empirical analysis of collaboration methods in cooperative coevolutionary algorithms, pp. 1235–1242.