



PONTIFÍCIA UNIVERSIDADE CATÓLICA  
DO RIO DE JANEIRO



André Andrade Costa

## **Otimização do Gas Lift Contínuo com Restrições por Algoritmo Genético**

Monografia apresentada ao Departamento de Engenharia Elétrica da  
PUC/Rio como parte dos requisitos para a obtenção do título de  
Especialização em *Business Intelligence*.

Orientadores:  
Marco Aurélio Cavalcanti Pacheco  
Marley Maria B. Rebuszi Vellasco

Rio de Janeiro  
10/12/2009



## RESUMO

Um dos principais objetivos em plantas que operam com *gas lift* contínuo é a definição das vazões de injeção de gás de cada poço que permitirão produzir a vazão ótima de óleo do sistema. Quando não há limitações de planta, é relativamente simples distribuir o gás total disponível para o nó de injeção entre os poços de forma ótima. Entretanto, se, além da restrição total de gás, a planta apresenta limitação da vazão bruta que pode ser produzida, as técnicas convencionais não conseguem atingir a solução ótima ou exigem um custo computacional inviável para tal.

Esse trabalho apresenta uma solução que utiliza algoritmos genéticos para calcular a vazão de injeção de gás de cada poço de uma planta de forma que a vazão de óleo total produzida seja a máxima possível. Além de conseguir atingir a solução quase ótima ou até mesmo ótima, essa abordagem permite que o especialista defina vários tipos de restrições como limitação de vazão bruta, limitação de produção de gás total e definições operacionais específicas para cada poço do nó. Flexibilidade será o principal diferencial desse trabalho uma vez que os engenheiros poderão escolher o modelo de poço mais apropriado como também o critério de otimização.

Soluções de otimização que utilizam algoritmos genéticos geralmente requerem um tempo considerável de processamento uma vez que a maior parte dos cenários gerados não obedece às restrições do problema. Uma grande vantagem dessa solução é que o algoritmo genético desenvolvido nesse trabalho gera sempre soluções no espaço definido pelas restrições, ou seja, todas as soluções geradas são viáveis. Dessa forma, o tempo de convergência para a melhor solução é bastante reduzido.

O modelo desenvolvido será apresentado, assim como os resultados dos experimentos e comparações com outras técnicas de otimização, considerando o custo computacional, a robustez dos aplicativos e a solução obtida.

## SUMÁRIO

1.	INTRODUÇÃO .....	4
1.1.	MOTIVAÇÃO.....	4
1.2.	OBJETIVOS DO TRABALHO.....	5
1.3.	DESCRIÇÃO DO TRABALHO .....	6
1.4.	ORGANIZAÇÃO DA MONOGRAFIA.....	6
2.	DESCRIÇÃO DO PROBLEMA .....	8
3.	ESTADO DA ARTE .....	13
4.	ARQUITETURA DO SISTEMA PROPOSTO.....	16
4.1.	REPRESENTAÇÃO DO PROBLEMA .....	16
4.2.	FUNÇÃO DE AVALIAÇÃO .....	17
4.3.	RESTRICÇÕES.....	18
4.4.	OPERADORES GENÉTICOS .....	20
4.5.	EXPERIMENTOS.....	24
5.	RESULTADOS .....	26
5.1.	AVALIAÇÕES .....	26
5.2.	DISCUSSÃO.....	30
6.	CONCLUSÕES E TRABALHOS FUTUROS .....	31
	REFERÊNCIAS BIBLIOGRÁFICAS .....	33

# 1. INTRODUÇÃO

Na produção de petróleo, quando o reservatório possui pressão suficiente, os fluidos são elevados sem a necessidade de estímulos externos e os poços podem produzir por surgência. Entretanto, quando a pressão é baixa, é necessário aplicar métodos artificiais para elevar os fluidos à superfície, como, por exemplo, o bombeio mecânico ou a injeção de gás (Thomas, 2001). Em campos *offshore*, o *gas lift* contínuo é um método de elevação artificial amplamente usado atualmente.

O *gas lift* contínuo utiliza a energia contida em gás comprimido para elevar fluidos como óleo e água para a superfície. Este método baseia-se na injeção contínua de gás a uma alta pressão na coluna de produção com o objetivo de gaseificar o fluido desde o ponto de injeção até a superfície. O gás é injetado na coluna de produção de forma contínua e o controle da vazão é feito através de um regulador de fluxo (Thomas, 2001). Dessa forma, a vazão de produção diária do poço será determinada pela quantidade de gás injetado na sua coluna de produção.

As plantas de produção por *gas lift* contínuo possuem um nó de injeção que distribui o gás disponível na planta entre os poços conectados à plataforma. Assim, a forma como o engenheiro aloca o gás total entre os poços definirá a produção de óleo total da plataforma.

Este trabalho trata do problema da alocação ótima de gás em um nó de *gas lift* contínuo que possui restrições operacionais de produção.

## 1.1. MOTIVAÇÃO

Em (Petrobras, 2007) foi desenvolvida uma metodologia para calcular a eficiência de um nó de injeção de *gas lift* contínuo. Neste trabalho, foi criada uma forma analítica de determinar o ponto ótimo de operação de cada poço considerando que a curva de eficiência  $Q_{gi} \times Q_o$  (vazão de gás x vazão de óleo) poderia ser representada por uma função do segundo grau. De uma maneira geral,

o método proposto define que para um conjunto de  $n$  poços operando na condição ótima, o valor da derivada ( $dQ_o/dQ_{gi}$ ) é igual para todos os poços. É comprovado no artigo que, dado que o nó de injeção de *gas lift* possui um limite de gás total inferior ao necessário para que os poços possam operar em seus pontos máximos ( $dQ_o/dQ_{gi} = 0$ ) o ponto ótimo de cada poço pode ser determinado igualando as derivadas.

Em algumas situações, a planta de produção possui restrições operacionais como vazão de líquido ( $Q_l$ ), vazão de gás total ( $Q_{gt}$ ) ou vazão de água ( $Q_w$ ) que podem ser produzidas. Nesses casos, além de ser necessário distribuir a vazão total de gás disponível no nó, os limites existentes na plataforma devem ser considerados. Entretanto, respeitar essas restrições implica em reduzir a produção total de óleo. São nesses cenários que a técnica atual de otimização de *gas lift* consegue indicar apenas soluções sub-ótimas uma vez que, para atender as restrições, utiliza-se uma derivada superior à ótima.

Assim, torna-se necessário uma nova técnica que além de respeitar as restrições impostas pela planta, distribua o gás entre os poços de forma a produzir o máximo de óleo possível.

## **1.2. OBJETIVOS DO TRABALHO**

Este trabalho visa oferecer uma ferramenta baseada em algoritmos genéticos que auxilie o engenheiro de elevação e escoamento a definir os pontos de operação de cada poço de sua plataforma de forma a maximizar a produção total de óleo. Através dessa ferramenta, o engenheiro definirá as restrições operacionais da planta que devem ser respeitadas e qual o valor total de gás disponível para os poços. Além disso, as curvas de eficiência já existentes poderão ser utilizadas para o cálculo da otimização. A ferramenta permitirá também que o engenheiro possa definir restrições operacionais específicas para cada poço do nó de injeção.

A solução baseada em algoritmos genéticos será disponibilizada de forma integrada à solução já existente de otimização e será usada nos cenários que apresentam restrições operacionais.

### **1.3. DESCRIÇÃO DO TRABALHO**

Para se chegar à ferramenta final foram realizadas as etapas de modelagem da solução, codificação do modelo em MATLAB, ajustes de parâmetros e testes de avaliação.

Na etapa de modelagem, foi definida como seria a representação do problema (especificação do cromossomo), qual seria a função de avaliação, como seriam tratados as restrições e como seria a especificação dos operadores genéticos.

Na etapa de implementação, o modelo especificado (componentes da solução, operadores e fórmulas do problema) foi codificado utilizando o MATLAB em conjunto com *Genetic Algorithm Toolbox*.

Utilizando o modelo implementado no MATLAB, foram realizados alguns testes de avaliação da solução. O objetivo desta etapa foi determinar se os resultados obtidos pelo algoritmo genético satisfazem as restrições impostas ao mesmo tempo em que maximiza o valor da função de avaliação.

### **1.4. ORGANIZAÇÃO DA MONOGRAFIA**

Esta monografia está dividida em cinco capítulos adicionais, descritos a seguir:

O capítulo 2 apresenta a descrição do problema de otimização de *gas lift* contínuo com restrições operacionais. Os tipos de restrições possíveis do

problema serão apresentados assim como a forma como é calculada a função objetivo.

O capítulo 3 descreve, de forma resumida, o que são algoritmos genéticos, para que tipos de problemas são aplicados e como se dá seu funcionamento. O objetivo é que o leitor adquira uma visão geral da técnica de algoritmos genéticos empregada neste trabalho.

O capítulo 4 apresenta a arquitetura da solução desenvolvida para o problema de otimização de *gas lift* com restrições. Serão descritos em detalhes os componentes que foram desenvolvidos e como o algoritmo genético da solução deve ser utilizado para realizar as otimizações.

O capítulo 5 irá detalhar os resultados obtidos com a solução nos testes de avaliação realizados.

Por fim, o capítulo 6 apresenta as conclusões do trabalho e indicar possíveis trabalhos futuros relacionados com esse tema.

## 2. DESCRIÇÃO DO PROBLEMA

Em um nó de injeção de *gas lift* contínuo, um dos principais desafios do engenheiro de elevação e escoamento é a definição das vazões de injeção de gás de cada poço que permitirão produzir a vazão ótima de óleo do sistema. Quando a planta de produção não apresenta limitações, é relativamente simples distribuir o gás total disponível para o nó de injeção entre os poços de forma ótima (Petrobras, 2007). Entretanto, se, além da restrição total de gás, a planta apresenta, por exemplo, limitação da vazão bruta que pode ser produzida, as técnicas convencionais não conseguem atingir a solução ótima ou exigem um custo computacional inviável para tal.

Em (Petrobras, 2007) é proposta uma técnica para determinar o ponto ótimo de cada poço de um nó de injeção de *gas lift* contínuo. A metodologia está alicerçada no fundamento de que para um conjunto de  $n$  poços de *gas lift* operando na condição ótima, as seguintes condições são atendidas:

$$\left(\frac{dQ_o}{dQ_{gi}}\right)_1 = \left(\frac{dQ_o}{dQ_{gi}}\right)_2 = \dots = \left(\frac{dQ_o}{dQ_{gi}}\right)_n,$$

e

$$(Q_{gi})_1 + (Q_{gi})_2 + \dots + (Q_{gi})_n = (Q_{gi}_{disp})$$

sendo:

$(Q_{gi})_i$  = Vazão de *gas lift* do poço  $i$ ;

$(Q_o)_i$  = Vazão de óleo do poço  $i$ ;

$(Q_{gi}_{disp})$  = Vazão total disponível para *gas lift*.

A representação matemática das curvas de desempenho dos poços é realizada através de um polinômio de segundo grau (na forma

$Q_o = a(Q_{gi})^2 + b(Q_{gi}) + c$ ) obtido via regressão linear pelo Método dos Mínimos Quadrados.

Nessa metodologia, para determinar o ponto ótimo de cada poço  $(Q_{gi_{ótima}})_i$  deve-se seguir os seguintes passos.

1. Determinar a curva de eficiência de cada poço. A figura a seguir representa duas curvas de eficiência de dois poços hipotéticos.

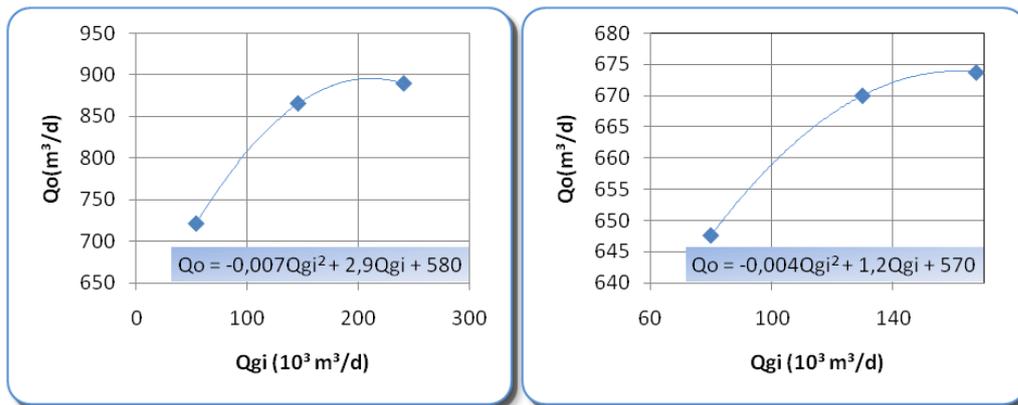
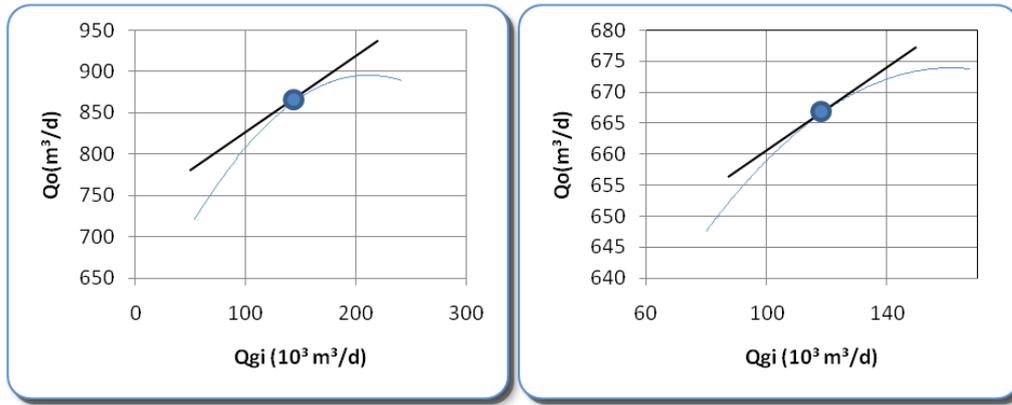


Figura 1 Exemplos de curvas de eficiência

2. Utilizando as curvas dos poços e a  $Q_{gi_{disp}}$  do nó, calcular o valor da derivada  $(dQ_o/dQ_{gi})$  unívoco que otimiza o conjunto de poços para a vazão de gás disponível como descrito em (Petrobras, 2007).
3. Com base no valor da derivada, calcular o valor de  $(Q_{gi})_i$  e, conseqüentemente,  $(Q_o)_i$  utilizando as curvas de eficiência dos poços. A figura a seguir demonstra a definição do ponto ótimo de dois poços hipotéticos utilizando a derivada ótima calcula para o nó.



**Figura 2 Cálculo do ponto ótimo**

Considerando que o gás total disponível no nó seja inferior à necessária para que todos os poços da planta operem no ponto máximo ( $dQ_o/dQ_{gi} = 0$ ), esta técnica consegue distribuir o gás de forma ótima e produzir o máximo de óleo possível.

Entretanto, em alguns cenários, a planta de produção possui limites operacionais que acabam restringindo a produção de alguma forma. Um exemplo de um limite operacional é o de vazão bruta total. Durante sua operação, o poço pode produzir líquido associado ao óleo (vazão bruta) que pode ser calculada pela vazão de óleo e pelo *BSW* (*Basic Sediments and Water*) do poço da seguinte forma:

$$Ql = \frac{Q_o}{1 - BSW}$$

Se, por exemplo, uma plataforma com cinco poços possui limitação de vazão bruta total de 6.000 m<sup>3</sup>/d e a capacidade de injeção de gás ( $Q_{gi\_disp}$ ) é de 700.300 m<sup>3</sup>/d a otimização convencional indicaria a seguinte solução:

**Tabela 1 Exemplo de otimização**

Poço	Derivada Operação	Valores Ótimos Calculados (m <sup>3</sup> /d)			Curva de Eficiência		
		Qgi	Ql	Qo	a	b	c
Poço 1	3,59E-04	173.305,20	1.921,20	816,51	-5,72E-09	2,34E-03	582,52
Poço 2	3,59E-04	109.501,31	768,44	622,43	-3,18E-09	1,05E-03	545,03
Poço 3	3,59E-04	137.216,04	1.672,05	1.581,75	-6,56E-09	2,16E-03	1.409,00
Poço 4	3,59E-04	157.216,65	1.177,24	668,67	-4,25E-09	1,69E-03	507,25
Poço 5	3,59E-04	123.058,07	1.638,75	245,81	-1,89E-09	8,25E-04	172,97
<b>Total</b>		<b>700.297,26</b>	<b>7.177,68</b>	<b>3.935,18</b>			

Para atender a restrição da planta utilizando a técnica das derivadas iguais, teria de ser calculada uma nova derivada de operação de valor maior que 3,59E-04, que resultará numa produção de óleo bem menor que 3.935,18 m<sup>3</sup>/d. Caso outros tipos de restrições existam na plataforma, a complexidade para achar a solução irá aumentar ainda mais.

Outros exemplos de restrições possíveis são:

- Restrição de vazão total de gás produzido no nó ( $Q_{gt}$ ): esta variável representa o gás que foi injetado (*gas lift*) em conjunto com o gás da formação. É calculado através da vazão de gás, da vazão de óleo e da razão gás-óleo do poço ( $RGO$ ):

$$Q_{gt} = Q_{gi} + (Q_o \times RGO)$$

- Restrição de vazão total de água produzida no nó ( $Q_w$ ): define a vazão de água produzida pelo poço durante sua operação. Esta vazão é calculada através da vazão bruta e do  $BSW$  :

$$Q_w = Q_l \times BSW$$

Além das restrições de capacidade de processamento da planta, a otimização deve ser capaz de permitir definições individuais para cada poço do nó como:

- Vazão mínima e máxima de injeção de *gas lift* por poço ( $Q_{gi_{min}}$  e  $Q_{gi_{max}}$ ): para modelar a produção do poço corretamente, são necessárias, além da curva de eficiência, as definições de vazão de gás de injeção mínima e máximo. A  $Q_{gi_{min}}$  é o valor mínimo necessário de gás para que o poço possa produzir por *gas lift* contínuo sem problemas operacionais como, por exemplo, intermitência. Já a  $Q_{gi_{max}}$  é o valor máximo de gás possível de ser injetado no poço que não comprometa o reservatório ou a coluna de produção. Graficamente, essas limitações poderiam ser representadas na figura a seguir:

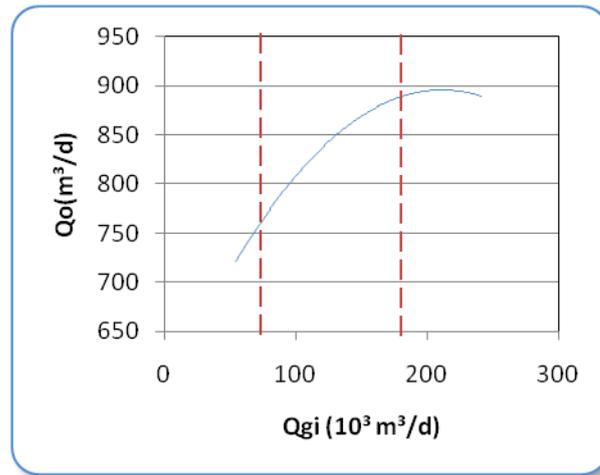


Figura 3 Exemplo de restrições de  $Q_{gi_{min}}$  e  $Q_{gi_{max}}$

- Produção por surgência ( $Q_{l_{sur}}$ ): Em algumas situações, há pressão suficiente na zona de produção para que o poço de um nó de *gas lift* produza sem a necessidade de injeção de gás. A otimização deve levar em conta a vazão de surgência dos poços para: não alocar gás para esses poços (segundo diretiva do engenheiro); ou decidir fechar o *gas lift* de um poço para atender á alguma restrição da planta. Em todo o caso, a vazão de óleo do poço deve ser contabilizada e pode ser calculada através da vazão bruta surgente e do *BSW* :

$$Q_o = \frac{Q_{l_{sur}}}{1 - BSW}$$

Apesar da técnica atual de otimização ser capaz de calcular os valores ótimos de injeção de gás de cada poço, percebe-se a necessidade de uma nova abordagem mais flexível capaz de lidar com essas restrições de operação. É preciso uma solução que permita ao engenheiro de elevação especificar quais restrições devem ser respeitadas e que calcule as vazões de injeção de gás de forma ótima.

### 3. ESTADO DA ARTE

Algoritmo genético é uma técnica de otimização e busca paralelizável baseada nos princípios da genética e da seleção natural (Wikipedia, Genetic Algorithm). Essa técnica permite que uma população composta de diversos indivíduos possa evoluir até que a melhor solução seja encontrada. As principais vantagens de desenvolver soluções de otimização baseadas em algoritmos genéticos são (Haupt, 2004):

- Possibilidade de tratar problemas de otimização de difícil formulação matemática e que possuem extenso espaço de busca;
- Poder tratar variáveis contínuas ou discretas;
- Permitir buscar em diferentes regiões do espaço de soluções de forma simultânea;
- Conseguir tratar problemas com diversas variáveis e restrições;
- Permitir usufruir de arquiteturas de processamento paralelo;
- Possibilidade de escapar de soluções sub-ótimas.

O princípio de funcionamento dos algoritmos genéticos é baseado na teoria da evolução darwiniana: os indivíduos mais aptos são privilegiados recebendo maior chance de reprodução, o que garante maior longevidade (Wikipedia, Evolutionary Computation). Nas soluções com algoritmos genéticos, há uma população de soluções para o problema, que evolui e se aprimora ao longo do tempo até que a melhor solução seja encontrada.

O desenvolvimento de soluções baseadas em algoritmos genéticos é, geralmente, dividido nas seguintes etapas (Pacheco, 1999):

1. Caracterização do problema: algoritmos genéticos são aplicados em problemas onde a solução analítica direta é bastante complexa ou inviável de ser modelada. Nesses casos, mesmo com um grande número de restrições e condições, é relativamente simples especificar o problema para ser resolvido por um algoritmo genético.

2. Representação da solução: a maneira de se chegar a uma solução ótima utilizando algoritmos genéticos é evoluindo uma população de soluções possíveis para o problema. A população é composta de indivíduos (também chamados de cromossomos) onde cada indivíduo representa uma possível solução para o problema a ser resolvido. Durante a evolução da população, o algoritmo genético irá recombinar e alterar esses indivíduos em busca de novas soluções para o problema. Assim, é necessário modelar a cromossomo de maneira que este possa representar uma possível solução para o problema.
3. Decodificação: como muitas vezes o cromossomo representa uma solução indireta para o problema é necessário decodificá-lo para o contexto que está sendo tratado. Com a decodificação, obtém-se do cromossomo os valores das variáveis que irão otimizar o problema em questão.
4. Função de Avaliação: a função de avaliação é o componente que o algoritmo genético utiliza para identificar quais as melhores soluções e se a população está convergindo para o ponto ótimo. Ela é definida de maneira à melhor representar o problema. Cada cromossomo da população é avaliado pela função de avaliação para que seu *fitness* possa ser calculado.
5. Seleção: durante a evolução de um algoritmo genético, a população evolui ao longo de diversas etapas chamadas de gerações. A cada geração, os indivíduos com melhores aptidões possuem mais chances de serem selecionados. A seleção propicia que os indivíduos mais aptos tenham mais chance de sobreviver de uma geração para outra e serem utilizados para gerarem novas soluções ou serem alterados. Para o processo de seleção, podem ser empregados diversos mecanismos com diferentes heurísticas que irão utilizar o *fitness* de cada indivíduo e aleatoriedade.
6. Operadores genéticos: um dos fundamentos dos algoritmos genéticos é a possibilidade de evolução das soluções a cada geração. Para que isso ocorra, é necessário criar novas soluções

baseadas nas já existentes ou modificá-las. Algoritmos genéticos utilizam dois tipos de operadores que realizam essa função: *crossover* e mutação. O operador de *crossover* serve para dar origem a novos indivíduos na população e acelerar o processo de busca. Independentes da heurística utilizada, no *crossover*, são utilizados partes do cromossomo de dois indivíduos para sejam criados um ou mais novos indivíduos que herdarão as características dos seus genitores. A mutação serve para explorar outras áreas do espaço de busca alterando partes do cromossomo do indivíduo.

7. Parâmetros de execução: A eficácia e o desempenho de um algoritmo genético são profundamente influenciados pela forma como os vários aspectos de sua execução são definidos. Tamanho da população, probabilidades de *crossover* e mutação, número de gerações, critérios e taxas de seleção dentre outros parâmetros irão definir a capacidade de convergir para a solução ótima e a velocidade dessa convergência.

Outra grande vantagem dos algoritmos genéticos é a possibilidade de incorporar diversas heurísticas (elitismo, *steady state*, etc.) que podem contribuir para um melhor desempenho na descoberta do melhor indivíduo (Yang, 2004).

Devido à sua eficácia e facilidade de modelagem de problemas altamente complexos, nos últimos anos percebe-se uma crescente utilização de algoritmos genéticos e outras técnicas baseadas na computação evolucionária aplicada a diferentes tipos de problemas relacionados à otimização (Michalewicz, 1996).

## 4. ARQUITETURA DO SISTEMA PROPOSTO

Como descrito no capítulo 2, o problema de alocação de *gas lift* consiste em, simultaneamente, maximizar a produção total de óleo e respeitar as restrições da planta de produção. Assim, este trabalho propõe um otimizador de *gas lift*, contínuo, baseado em algoritmos genéticos, flexível o suficiente para tratar as restrições definidas pelo engenheiro de elevação e escoamento.

### 4.1. REPRESENTAÇÃO DO PROBLEMA

Algoritmos genéticos são capazes de resolver problemas de otimização evoluindo uma população de possíveis soluções para o problema. Dessa forma, o primeiro passo no desenvolvimento desse trabalho foi definir a representação do problema na forma de um cromossomo. Isso significa modelar o formato da solução de uma maneira que o algoritmo genético consiga evoluí-la. O cromossomo desta solução foi definido de forma a permitir que o algoritmo genético indicasse para cada poço de um dado nó, os valores de  $Q_{gi}$  o estado do *gas lift* (aberto ou fechado) e o estado do poço (aberto ou fechado). Além dos atributos relacionados ao problema, foi acrescentada uma variável auxiliar que indica a ordem do poço durante a decodificação do cromossomo. A tabela a seguir ilustra o formato do cromossomo para este algoritmo genético.

**Tabela 2 Esquema do cromossomo**

Poço	GLC (aberto / fechado)	Estado (aberto / fechado)	$Q_{gi}$	Ordem
Poço-1	GLC-1	Estado-1	$Q_{gi-1}$	Ordem-1
Poço-2	GLC-2	Estado-2	$Q_{gi-2}$	Ordem-2
Poço-N	GLC-N	Estado-N	$Q_{gi-N}$	Ordem-N

Com o cromossomo nesse formato, o algoritmo genético pode tanto descobrir os valores de  $Q_{gi}$  que aplicados às curvas dos poços maximizem a

produção de óleo, como também pode sugerir que um poço produza por surgência ou passe a ser fechado para respeitar alguma restrição operacional. A função da variável auxiliar de ordem será descrita mais adiante onde é detalhado o algoritmo de decodificação do cromossomo. O domínio de cada um dos atributos é definido da seguinte forma:

- **GLC:** Indica se o *gas lift* do poço deve ser aberto (deve-se injetar gás no poço) ou fechado (não deve ser injetado gás e o poço deve produzir por surgência). Este atributo é do tipo *bit* onde o valor zero indica que o GLC deve ser fechado e o valor um que deve permanecer aberto;
- **Estado:** Indica se o poço deve permanecer aberto ou fechado. Este atributo é do tipo *bit* onde o valor zero indica que o poço está fechado (não produz) e o valor um indica que está aberto (produzindo por GLC ou por surgência);
- **$Q_{gi}$ :** Representa o valor normalizado da vazão de gás a ser injetada no poço. Este atributo é numérico do tipo real e varia de zero a um. A normalização e desnormalização deste atributo utilizam os valores de  $Q_{gi_{min}}$  e  $Q_{gi_{max}}$  do poço correspondente;
- **Ordem:** Este atributo é numérico do tipo inteiro e varia de um ao total de poços do nó de injeção. O valor deste atributo indica a ordem com que o poço será decodificado no Decodificador de Cromossomo.

## 4.2. FUNÇÃO DE AVALIAÇÃO

Durante a execução do algoritmo genético, a cada geração, as soluções que dão os melhores resultados possuem mais chance de continuar evoluindo e podem contribuir para a criação de novas soluções. Para classificar as soluções que compõe a população do algoritmo genético, é necessário especificar a Função de Avaliação do problema. A Função de Avaliação é o componente que o algoritmo

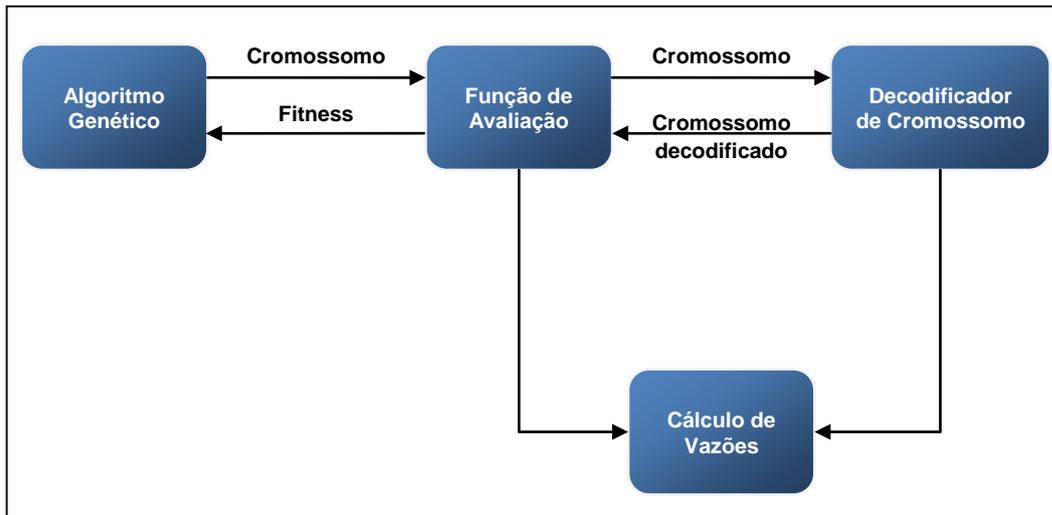
genético utiliza para identificar quais as melhores soluções e se a população está convergindo para o ponto ótimo. Ela é definida de maneira à melhor representar o problema. Cada cromossomo da população é avaliado pela Função de Avaliação para que seu *fitness* possa ser calculado. Considerando que se deseja maximizar a produção de óleo, a Função de Avaliação foi definida da seguinte forma:

$$Fitness = \sum_{i=1}^{n-pocos} (Qo)_i$$

Dessa forma, o cromossomo que, ao final da execução, resultar na maior vazão total de óleo será a melhor solução encontrada. A função de avaliação definida nesse trabalho foi desenvolvida para ser flexível o suficiente para utilizar qualquer tipo de função matemática como modelo de curva. Essa abordagem permite que o engenheiro defina o modelo matemático mais adequado para o seu cenário.

### 4.3. RESTRIÇÕES

Uma vez definida a função objetivo que se deseja maximizar, deve-se especificar no algoritmo genético as restrições que o problema apresenta. Para que as soluções geradas estejam sempre dentro do espaço das restrições, foi incorporado ao algoritmo genético um Decodificador de Cromossomo. O esquema da solução utilizando esse componente pode ser ilustrado na figura a seguir:



**Figura 4 Arquitetura da solução**

Nessa arquitetura, a cada geração, o algoritmo genético irá executar os seguintes passos:

1. O algoritmo genético gera os cromossomos e os passa para a Função Objetivo para obter o *fitness* de cada um;
2. A Função Objetivo, antes de calcular a vazão total de óleo, repassa os cromossomos para o Decodificador de Cromossomo para obter um cromossomo válido que não viole nenhuma das restrições definidas pelo engenheiro;
3. Um cromossomo válido é retornado pelo Decodificador de Cromossomo para a Função Objetivo para que esta calcule o *fitness* deste indivíduo;
4. O algoritmo genético recebe o *fitness* do cromossomo e prossegue com sua execução.

O Decodificador de Cromossomos permite que qualquer heurística de garantia de restrições possa ser utilizada. O algoritmo implementado para decodificar o cromossomo tenta, iterativamente, reduzir o valor de  $Q_{gi}$  dos poços até que as restrições sejam atendidas. Este algoritmo pode ser resumido na seguinte forma:

```

Obter ordem dos poços a partir do cromossomo;
Enquanto restrições não atendidas
  Obter próximo poço da ordem;
  Obter Estado e GLC do poço no cromossomo;
  Se Poço está aberto e GLC está aberto
    Se  $Q_{giPoço} - Decremento > 0$ 
       $Q_{giPoço} = Q_{giPoço} - Decremento;$ 
    Se não
       $GLCPoço = Fechado;$ 
    Fim se;
  Se não
     $EstadoPoço = Fechado;$ 
  Fim se;
Fim enquanto;

```

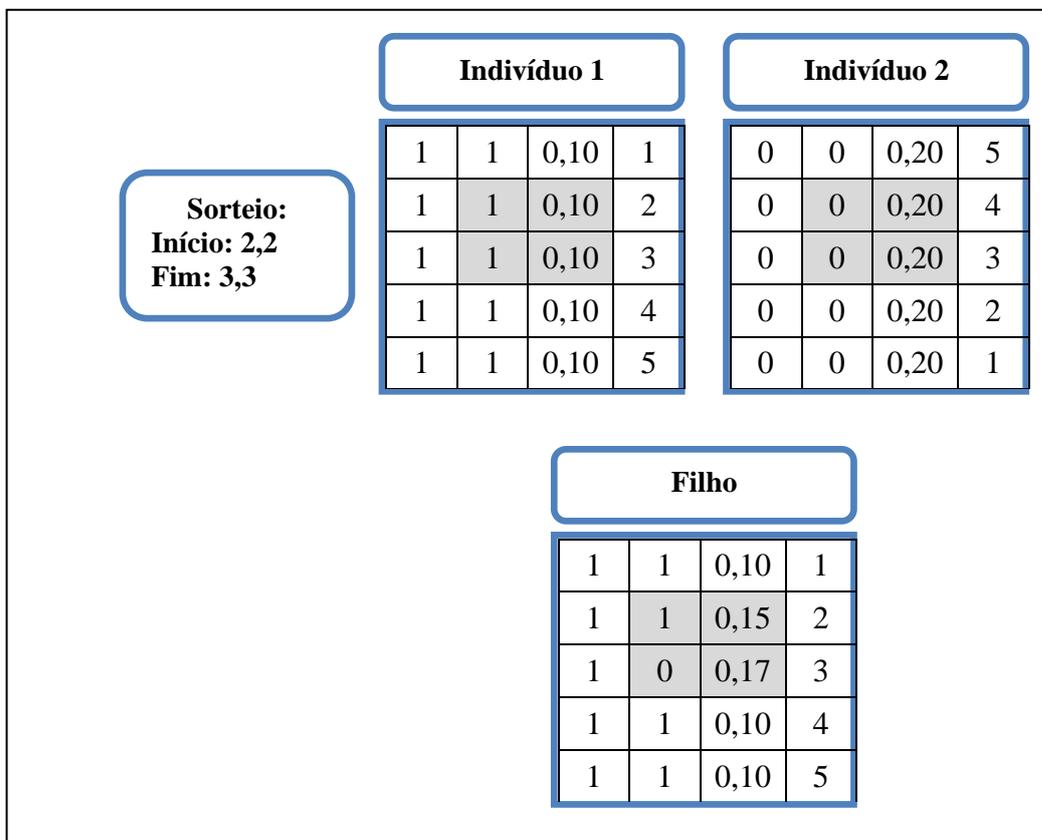
Para os limites de  $Q_{gi_{min}}$  e  $Q_{gi_{max}}$  foi utilizada uma técnica de normalização juntamente com definição no algoritmo genético que a coluna correspondente ao  $Q_{gi}$  variasse somente entre zero e um. Assim, utilizando o Decodificador de Cromossomo e a normalização do valor do  $Q_{gi}$ , há garantia de que todas as soluções geradas pelo algoritmo genético durante sua evolução são válidas para o problema. Essa abordagem aumenta de forma significativa a eficiência do algoritmo genético uma vez que este não desperdiça tempo computacional avaliando e gerando soluções inválidas para o problema.

#### 4.4. OPERADORES GENÉTICOS

Durante a evolução do algoritmo genético, novas soluções devem ser geradas a partir dos melhores cromossomos já existentes. A geração de novos cromossomos pode ser realizada através de cruzamento e alteração de cromossomos. No cruzamento, geralmente denominado de *crossover*, são selecionados dois cromossomos genitores e partes aleatórias de seus genes são utilizadas para gerar um ou mais cromossomos filhos. O objetivo do *crossover* é aproveitar a carga genética das soluções mais promissoras para gerar soluções possivelmente melhores. Na alteração de cromossomos, conhecida como mutação, são realizadas pequenas alterações aleatórias em partes do gene de um

cromossomo com o objetivo de explorar outras partes do espaço de busca. Neste trabalho foram criados operadores de *crossover* e mutação específicos para lidar com o formato matricial do nosso cromossomo: operadores de sub-matriz e operadores de linhas e colunas.

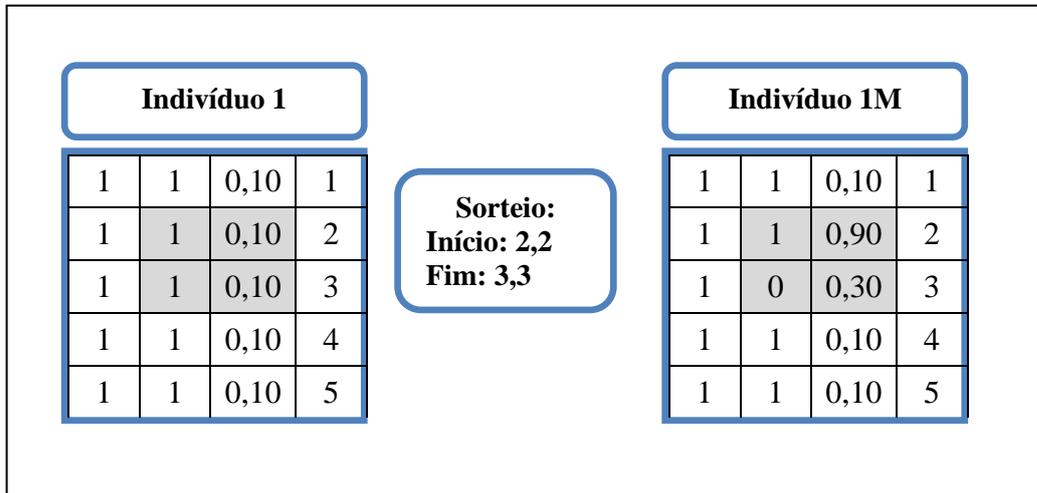
O *crossover* e a mutação de sub-matriz operam numa região contígua do cromossomo sorteando uma coordenada de início (Linha1, Coluna1) e uma coordenada de fim (Linha2, Coluna2). O funcionamento do *crossover* pode ser ilustrado pela figura a seguir:



**Figura 5 Crossover de sub-matriz**

Após o sorteio das coordenadas, os genes do cromossomo com melhor *fitness* são copiados para o filho. Em seguida, o operador combina os genes da região selecionada dos dois cromossomos genitores e os copia para o filho. Caso o gene seja do tipo *flag*, será escolhido aleatoriamente o valor do primeiro genitor ou do segundo. Caso o gene seja do tipo numérico, será escolhido um número aleatório entre os valores dos dois genitores.

A mutação de sub-matriz opera de forma similar ao *crossover* (ver figura a seguir). Após o sorteio das coordenadas, os genes da região poderão sofrer mutação (determinado pela taxa de mutação) de acordo com seu tipo.



**Figura 6** Mutação de sub-matriz

Além dos operadores de sub-matriz, foram criados o *crossover* e a mutação de linhas e colunas. No lugar de sortear uma região contígua do cromossomo, esses operadores sorteiam linhas e colunas distintas. A motivação para essa abordagem foi selecionar no cromossomo alguns poços (linhas) e alguns atributos desses poços (colunas). O funcionamento do *crossover* de linhas e colunas pode é ilustrado na figura a seguir:

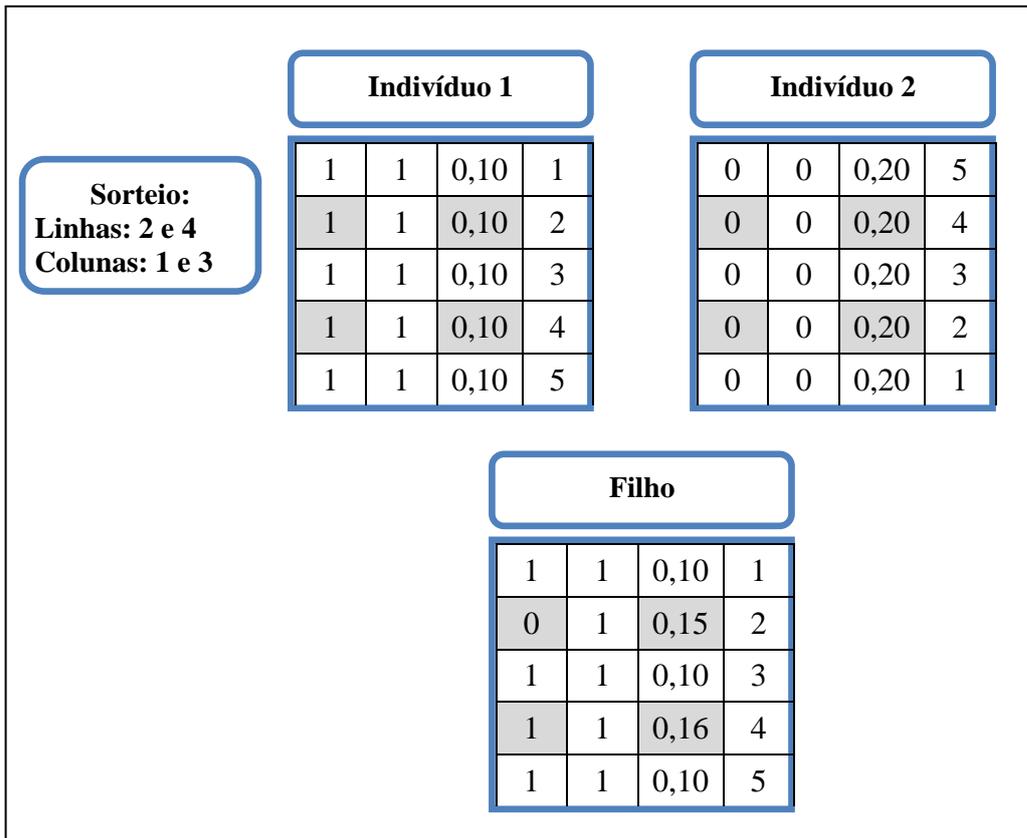


Figura 7 Crossover de linhas e colunas

A mutação de linhas e colunas foi desenvolvida de maneira similar à de submatriz, diferenciando apenas o modo de seleção de genes como ilustrado na figura a seguir.

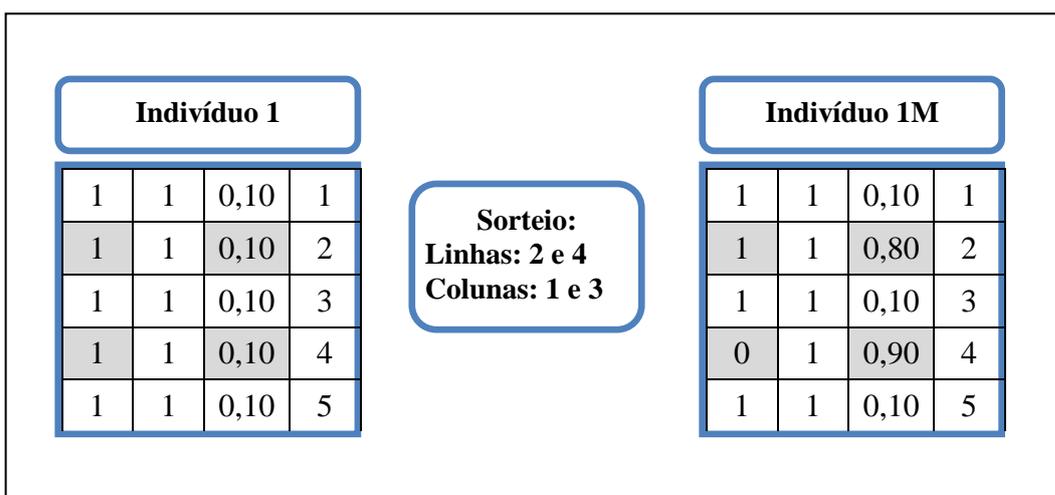


Figura 8 Mutação de linhas e colunas

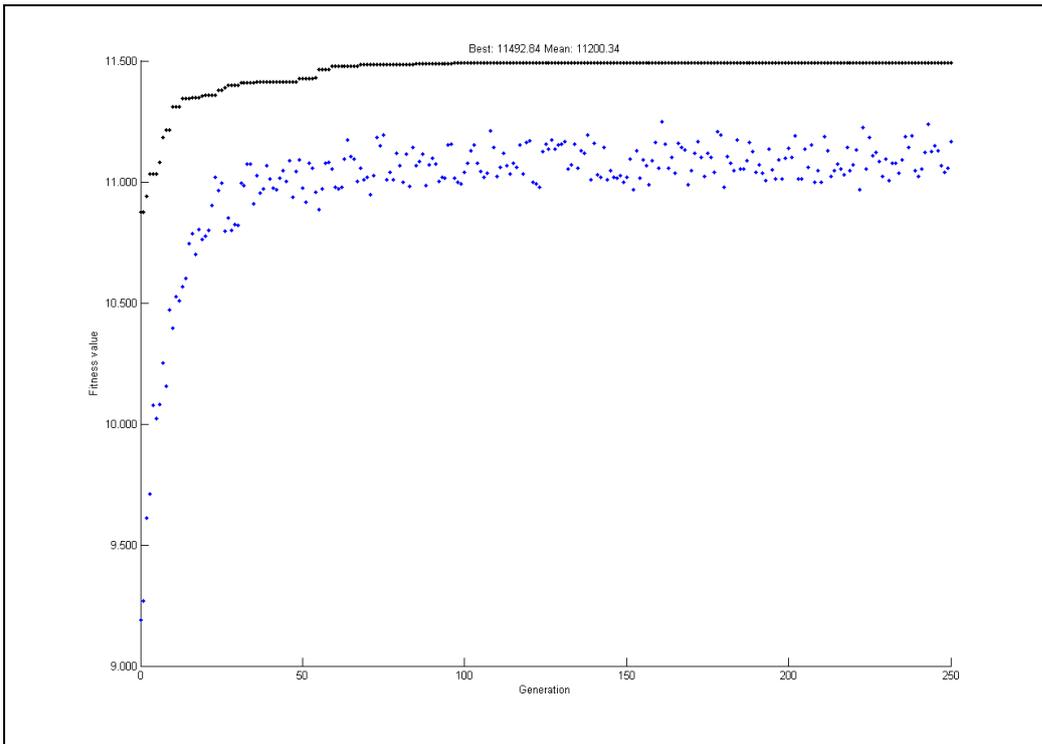
Com dois grupos de operadores, é possível executar o algoritmo genético com diferentes configurações (utilizar apenas um grupo ou intercambiar os grupos) e avaliar quais parâmetros apresentam os melhores resultados.

#### 4.5. EXPERIMENTOS

Para executar esta solução de otimização é necessário apenas:

- Definir, para cada poço, sua curva de eficiência no formato  $(Qo)_i = F[(Qgi)_i]$ , valores de BSW, RGO e vazão surgente;
- Especificar os valores de  $Qgi_{\min}$  e  $Qgi_{\max}$  ;
- Selecionar quais restrições (vazão bruta total, vazão de gás total, vazão de água, etc.) devem ser respeitadas.

Com os parâmetros da planta definidos, basta apenas executar o algoritmo genético e avaliar a melhor solução encontrada após as várias gerações. Na figura a seguir temos um gráfico da evolução da população do algoritmo genético após 250 gerações para uma otimização de uma plataforma com 16 poços e uma limitação de gás bem abaixo do máximo da planta. Neste gráfico, o eixo X indica a geração, o eixo Y o valor do *fitness*, a série de cor preta a melhor solução da geração e a série azul a média dos indivíduos da geração. Nota-se que a melhor solução é rapidamente encontrada e que a média da população, após 20 gerações, converge num patamar um pouco abaixo da melhor solução. Vale destacar que o tempo médio para a execução completa do algoritmo genético fica em torno de dois minutos.



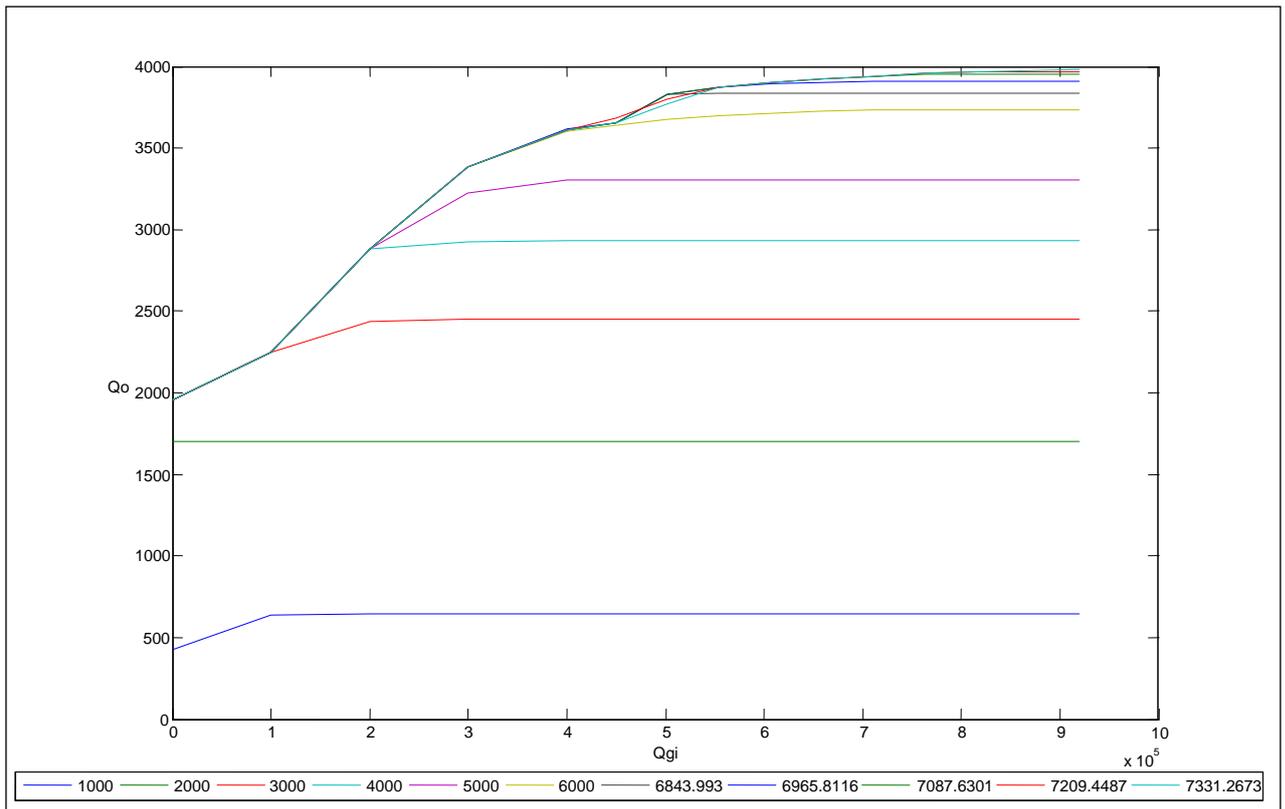
**Figura 9** Evolução do algoritmo genético

## 5. RESULTADOS

Neste capítulo serão apresentadas algumas avaliações realizadas e os resultados dos testes comparativos com outras técnicas.

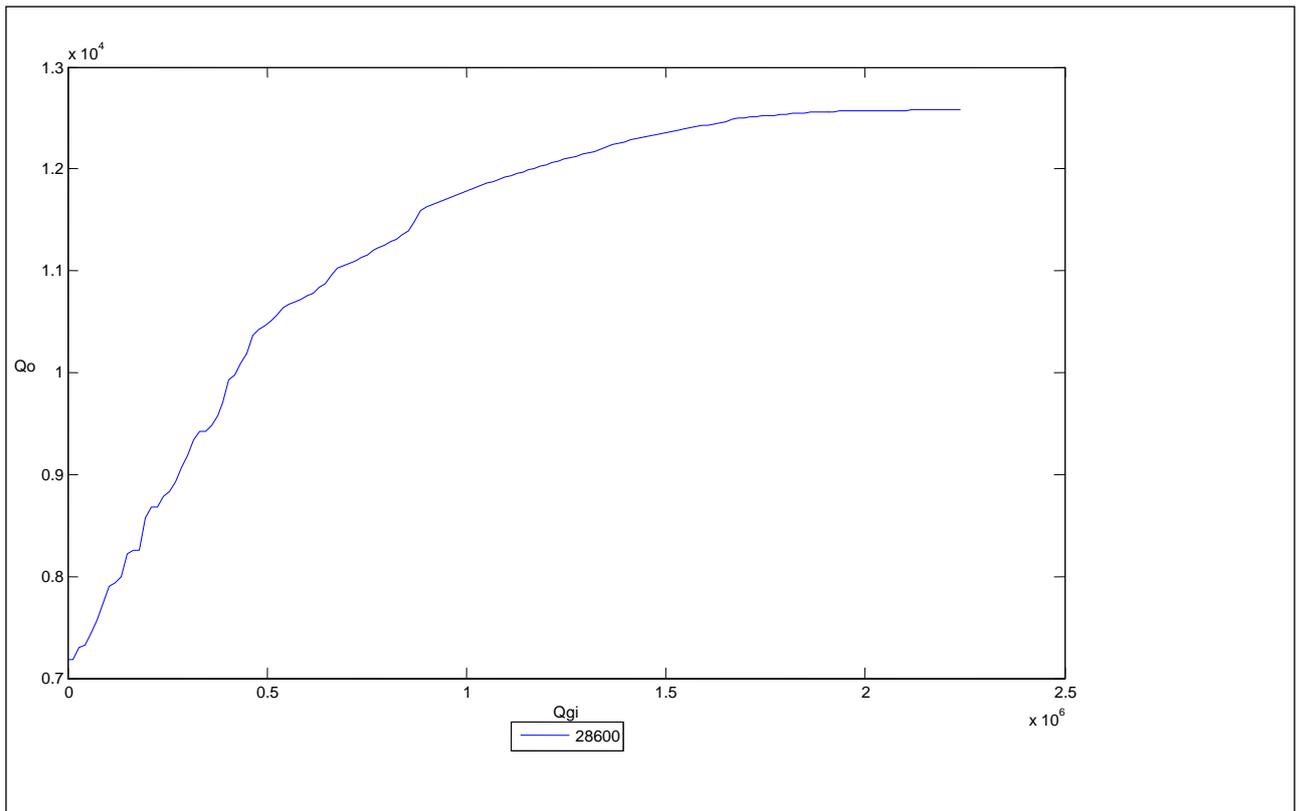
### 5.1. AVALIAÇÕES

Para avaliar se as respostas do algoritmo genético seriam compatíveis com o esperado na prática, foram realizados experimentos em que as restrições foram variando a cada execução do algoritmo genético. No primeiro experimento, numa planta com cinco poços, o valor da  $Q_{gi_{disp}}$  variou discretamente de 0 a 920.000 m<sup>3</sup>/d e a limitação da vazão bruta variou de 1.000 a 7.300 m<sup>3</sup>/d (ver figura a seguir). Ao analisar o gráfico podemos perceber que quanto maior a limitação da vazão bruta, menor a faixa de variação da vazão de gás injetado, saturando a vazão produzida. As grandes variações das inclinações na curva representam a abertura / fechamento de poços. Quando um poço é aberto ou fechado, o comportamento do conjunto é alterado. Quanto maior a influência de um poço, maior será a alteração.



**Figura 10** Experimento variando as restrições de  $Q_{gi}$  e  $Q_l$

No segundo experimento, foi utilizada uma plataforma com 16 poços, o valor da  $Q_{gi_{disp}}$  variou de 0 a 2.200.000 m<sup>3</sup>/d (aumento da discretização de  $Q_{gi}$ ) e a limitação da vazão bruta foi fixada em 28.600 (ver figura a seguir). Percebemos que quanto maior o número de poços do conjunto, menos evidentes ficam os eventos de abertura/fechamentos de poços.



**Figura 11 Experimento variando a  $Q_{gi}$**

Além das avaliações, foram realizados testes comparativos com duas outras abordagens de otimização para avaliar as soluções encontradas pelo algoritmo genético. No primeiro teste, comparou-se o resultado do algoritmo genético com o resultado obtido pelo otimizador implementado no aplicativo SOLAR (desenvolvido pela Petrobras). Neste caso, foi definido apenas o valor da  $Q_{gi_{disp}}$  em 700.000 m<sup>3</sup>/d numa plataforma com cinco poços. Apesar deste cenário não ser o indicado para se utilizar a solução com algoritmo genético (uma vez que a solução ótima pode ser diretamente calculada pelo aplicativo), foi um teste importante para medir o quão distante a solução proposta pelo algoritmo genético estaria da ótima teórica. Como pode ser visto na tabela a seguir, o algoritmo genético determinou uma solução que resultou numa diferença mínima da vazão total de óleo ótima.

**Tabela 3 Resultado de teste comparativo com o SOLAR**

Método	Qo (m <sup>3</sup> /d)	Diferença
SOLAR	3.935,10	0,001%
Algoritmo Genético	3935,07	

No segundo teste, o método utilizado para comparação foi a da busca exaustiva. Neste cenário, foi utilizada uma plataforma com somente quatro poços onde foi definida a  $Q_{gi_{disp}}$  em 400.000 m<sup>3</sup>/d e a limitação de vazão bruta total em 12.000 m<sup>3</sup>/d. A busca exaustiva tenta iterativamente encontrar os valores da  $Q_{gi}$  de cada poço que não violem as restrições e resultem na vazão máxima de óleo. O resultado do algoritmo genético acabou sendo superior ao da busca exaustiva (ver tabela a seguir) uma vez que o intervalo de variação da  $Q_{gi}$  de cada poço foi de 5.000 m<sup>3</sup>/d resultando num máximo local para a vazão de óleo. Como o tempo de processamento desta busca exaustiva já é elevado (3,5 horas), não foram utilizados outros intervalos para a  $Q_{gi}$ .

**Tabela 4 Resultado de teste comparativo com a busca exaustiva**

Método	Qo (m <sup>3</sup> /d)	Diferença
Busca Exaustiva	8.432,00	
Algoritmo Genético	8434,00	0,03%

## 5.2. DISCUSSÃO

Como se pode observar pelos testes realizados, a solução desenvolvida nesse trabalho apresenta resultados satisfatórios quando comparada com outras técnicas onde é possível o cálculo analítico. Na comparação com o aplicativo SOLAR, os resultados foram praticamente equivalentes, enquanto que na comparação com a busca exaustiva o resultado do algoritmo genético foi ligeiramente superior uma vez que a busca não cobre todo o espaço de soluções.

Já nos cenários de limitação operacional (onde não há solução analítica), foi possível constatar, após análise de alguns engenheiros de produção, que o comportamento das soluções geradas é compatível com o que ocorreria na prática caso os cenários testados ocorressem na planta de produção.

## 6. CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho foi apresentado uma solução para o problema de otimização de *gas lift* contínuo sob restrições operacionais utilizando algoritmos genéticos. Como demonstrado nos testes realizados, a solução desenvolvida apresenta bons resultados quando comparada com outras técnicas.

Uma grande vantagem deste otimizador é a flexibilidade: o engenheiro pode utilizar o modelo de desempenho de poço mais apropriado (curvas quadráticas, cúbicas, logarítmica, etc.) e é possível definir outro critério de otimização além da vazão total de óleo como, por exemplo, a tangente econômica.

Uma vez que na Petrobras já existe um otimizador de *gas lift* contínuo baseado no método das derivadas iguais, este trabalho propõe que o algoritmo genético desenvolvido seja integrado à ferramenta atual para ser utilizado nos casos em que a planta apresente restrições operacionais. Para verificar a viabilidade técnica dessa integração, foi realizada uma prospecção de bibliotecas de algoritmos genéticos em Java e a implementação do modelo da solução utilizando a biblioteca selecionada.

Após alguns testes realizados utilizando problemas clássicos de algoritmos genéticos, foi selecionada a biblioteca ECJ (*Evolutionary Computation for Java*) por ser um projeto maduro e oferecer os recursos necessários. Com o suporte dessa ferramenta, foi possível implementar todos os componentes da solução e obter os mesmos resultados apresentados pela implementação no MATLAB.

Com o algoritmo genético devidamente implementado em Java, a próxima etapa consistirá na integração com a ferramenta de otimização atualmente em uso. O algoritmo genético poderá ser disponibilizado em conjunto com a ferramenta de otimização sendo que será executado sempre que o engenheiro definir restrições operacionais de planta. Ou seja, caso a planta não possua restrições de produção, será utilizada a técnica convencional (derivadas iguais) para distribuir o *gas lift* de forma ótima.

Através da integração com a solução já existente e pela forma simplificada como a solução será disponibilizada, é possível prever uma melhoria na agilidade dos engenheiros de elevação na tomada de decisões diárias para solucionar e

corrigir os problemas operacionais, mantendo otimizada a produção das plataformas sobre influência do nó de injeção de *gas lift*.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Haupt, R. L. (2004). *Practical Genetic Algorithms*. Wiley-IEEE.
- Michalewicz, Z. (1996). *Genetic Algorithms + Data Structures = Evolution Programs*. Springer.
- Pacheco, M. A. (1999). *Algoritmos Genéticos: Princípios e Aplicações*. Notas de Aula. Rio de Janeiro.
- Petrobras. (2007). *CT-01-2007 - “Nova” metodologia para o cálculo do Indicador de Eficiência para Poços de Gas Lift Contínuo (IEGLC)*. Comunidade de Práticas da Petrobras. Rio de Janeiro.
- Thomas, J. E. (2001). *Fundamentos de Engenharia de Petróleo*. Rio de Janeiro: Interciência.
- Yang, C. T. Z (2004).. *Comparison of Steady State and Elitist Selection Genetic Algorithms*. Proceedings of the 2004 International Conference on Intelligent Mechatronics and Automation. Chengdu,China.
- [http://en.wikipedia.org/wiki/Genetic\\_algorithm](http://en.wikipedia.org/wiki/Genetic_algorithm). último acesso em 01/11/2009
- [http://en.wikipedia.org/wiki/Evolutionary\\_computation](http://en.wikipedia.org/wiki/Evolutionary_computation). último acesso em 01/11/2009