



POSICIONAMENTO DE MANIFOLDS SUBMARINOS DE PRODUÇÃO PARA MINIMIZAÇÃO DO CUSTO DE DUTOS NO DESENVOLVIMENTO DE CAMPOS DE PETRÓLEO

Adolfo Emmanuel Correa López^a

Marcelo Danenberg Marsili

Carl Horst Albrecht^a

Juliana Souza Baioco^{a,b}

Beatriz de Souza Leite Pires de Lima

Breno Pinheiro Jacob^a

adolfo.correa.lopez@gmail.com

marcelomarsili@gmail.com

carl@lamcs.coppe.ufrj.br

jsbaioco@lamcs.coppe.ufrj.br

bia@coc.ufrj.br

breno@coc.ufrj.br

^aLAMCSO - Laboratório de Métodos Computacionais e Sistemas Offshore.

COPPE/UFRJ - Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia.

Cidade Universitária - Ilha do Fundão, Av. Pedro Calmon S/N, CEP 21941-596, Rio de Janeiro, RJ, Brasil.

^bTEQ/E.Engenharia/UFF – Departamento de Engenharia Química e Petróleo - Escola de Engenharia – Universidade Federal Fluminense, Rua Passo da Pátria, 156, S 305, Bloco D, Campus Praia Vermelha, São Domingos, Niterói RJ, Brasil.

Abstract. *O presente trabalho visa a implementação e análise de desempenho de dois algoritmos de otimização baseados na natureza aplicados a um problema de localização de manifolds submarinos para o desenvolvimento de campos de petróleo. O problema consiste na busca do melhor posicionamento de coletores submarinos (manifolds) para o desenvolvimento da*

produção de 20 poços de petróleo com exportação dos fluidos para um ponto de recebimento fixo. A função-objetivo é representada pelo volume total de aço utilizado nos dutos que, por sua vez, é função das distâncias totais das linhas submarinas utilizadas. Os algoritmos selecionados para este estudo foram a Evolução Diferencial e a Otimização por Enxame de Partículas por serem robustos e simples e por já terem sido utilizados em aplicações semelhantes.

Palavras-Chave: *Petróleo e Gás, Equipamentos Submarinos, Manifolds, Otimização, Evolução Diferencial, PSO*

1 INTRODUÇÃO

O sistema submarino de coleta da produção de poços de petróleo compõe uma grande parcela dos investimentos de um projeto de desenvolvimento de um campo *offshore*. Em ordem de grandeza de dispêndio, compara-se apenas ao custo de construção dos próprios poços e ao custo da plataforma para recebimento, processamento e exportação da produção. A **Figura 1** ilustra o arranjo submarino do Campo de Frade, localizado no norte da Bacia de Campos, 120 km a leste do Cabo de São Tomé, em lâmina d'água de 1.330 metros. O sistema de coleta da produção é composto por 12 poços conectados individualmente através de linhas de 6 polegadas a uma unidade flutuante de produção, armazenamento e transferência (FPSO). Ainda, são utilizados no desenvolvimento do campo 7 poços injetores de água, abastecidos pelo FPSO através de um duto estendido no leito marinho na forma de um anel. O sistema de dutos submarinos contempla linhas individuais de produção de petróleo, linhas de injeção de água e linhas de injeção de *gas lift* nos poços, além das linhas de serviço para controle e injeção de produtos químicos nos poços (ANP, 2007). O exemplo do Campo de Frade destaca a complexidade e quantidade de linhas submarinas envolvidas no desenvolvimento de um campo de petróleo.

Os *manifolds* são equipamentos usualmente considerados nos arranjos submarinos para redução de custos através da redução da quantidade e tamanho de dutos requeridos para fazer as conexões hidráulicas necessárias à produção de um reservatório de petróleo ou gás. O *manifold* submarino de produção é um equipamento com comandos eletro-hidráulicos que recebe e agrupa o fluxo de fluidos de diversos poços de produção e os direciona através de uma linha única para o ponto de entrega desejado. Desta forma, faz-se possível a economia de diversos quilômetros de linhas de produção, onde os dutos que seriam ligados individualmente dos poços a um ponto de recebimento (Castiñeira, P, 2014), podem ser conectados a um *manifold* de produção através de linhas mais curtas e a conexão com o ponto de recebimento (trecho usualmente mais longo) passa a ser feita através de uma linha única mais robusta.

A **Figura 2** ilustra o arranjo submarino do Campo de Tambaú, localizado no norte da Bacia de Campos, 140 km a sul da cidade do Rio de Janeiro, em lâmina d'água de 1.000 metros. O sistema de coleta da produção consiste em poços produtores de gás conectados a dois *manifolds* de produção (ligados em série), com a produção sendo direcionada para o FPSO Cidade de Santos, compartilhado com o campo de Uruguá, afastado cerca de 10 km de Tambaú. O gás tratado pelo FPSO é então direcionado através de um duto de 18 polegadas e 178 km de extensão para a plataforma do Campo de Mexilhão, onde são novamente agrupados em um outro *manifold* para entrega da produção em uma estação de processamento em terra (ANP, 2009a).

Este trabalho tem como objetivo estudar a aplicação de algoritmos heurísticos de otimização baseados na natureza ao posicionamento de *manifolds* submarinos de produção para a otimização dos custos envolvidos em um desenvolvimento integrado acadêmico de 20 poços produtores de petróleo. Para a minimização da função objetivo são aplicados dois algoritmos de otimização baseados na natureza: Otimização por Enxame de Partículas (PSO – *Particle Swarm Optimization*) e Evolução Diferencial (DE – *Differential Evolution*). São apresentadas as comparações dos resultados otimizados pelos métodos testados, destacando a confiabilidade dos algoritmos para a solução do problema e o custo computacional envolvido. Também, é apresentada a comparação do resultado obtido com uma solução por Algoritmos Genéticos codificada no excel.




Figura 1: Arranjo submarino do Campo de Frade localizado no norte da Bacia de Campos e operado pela Chevron. Fonte: FMC Technologies, 2015a.




Figura 2: Arranjo submarino do Campo de Tambaú localizado na Bacia de Santos e operado pela Petrobras. Fonte: FMC Technologies, 2015b.

2 DESCRIÇÃO DO PROBLEMA

O cenário de estudo é composto por um conjunto de vinte poços submarinos de petróleo, que deve ser conectado a um ou mais pontos de coleta através de *manifolds* que, por sua vez, conduzirão a produção de seus poços a um ponto fixo pré-definido em terra. A **Tabela 1** apresenta a lista dos poços e suas posições relativas ao ponto de chegada em terra.

Devido a questões operacionais de garantia de escoamento da produção e perda de carga nas tubulações, há uma distância máxima (R) de atuação que restringe a ligação de um poço a um coletor de produção. Esta distância é considerada 30 km como caso base, embora seja utilizada também como parâmetro de sensibilidade. Esta distância é considerada uma interligação longa (*tieback*) (Offshore Magazine, 2014) para poços produtores de óleo. No entanto, há casos já implementados de *tiebacks* de até 69,8 km para poços de óleo e 143 km para poços de gás,

Tabela 1: Lista dos poços produtores e suas posições para a otimização do sistema submarino de coleta.
Fonte: (ANP, 2009b)

Número do Poço	Posição X (km) *	Posição Y (km) *	Produção de Óleo (bbl/d)	Produção de Gás (Mm^3/d)
1	138.751	0.995	166	1
2	187.156	25.743	503	6
3	197.313	36.619	4,859	68
4	145.329	-52.870	2,097	11
5	178.221	125.254	6,520	52
6	97.243	-41.177	97	1
7	177.130	-5.496	1,314	14
8	175.168	-1.806	5,071	84
9	202.492	46.063	1,480	18
10	152.483	25.432	82	0
11	223.442	280.097	111	107
12	235.506	252.505	7,269	48
13	234.636	258.677	3,240	27
14	262.611	315.199	303	927
15	-107.142	-353.671	23,338	988
16	-95.561	-335.720	13,123	369
17	-110.401	-349.530	28,863	1,028
18	-94.533	-197.643	18	83
19	-104.795	-350.713	26,378	1,333
20	-105.873	-346.995	15,414	540

* Posição relativa ao ponto de chegada em terra das linhas de produção

conforme apresentado na **Figura 3**.

A partir da posição dos poços de produção e do ponto de chegada na terra propõe-se determinar a quantidade e posição de *manifolds* que minimizem o custo total das linhas submarinas (poço-*manifold* e *manifold*-terra). Assume-se como premissa que o custo das linhas é diretamente proporcional ao volume de aço utilizado. Na **Tabela 2** estão especificadas as linhas a serem consideradas para os trechos poço-*manifold* e *manifold*-terra. Estes valores são típicos e comumente encontrados em projetos de óleo e gás, embora a especificação precisa dependa de diversos outros fatores, como distância total da tubulação, pressão disponível, vazão de fluidos, entre outros.

Tabela 2: Especificações dos dutos e área transversal com aço

Linha	Diâmetro, D	Espessura, t	Área Transversal com Aço, A_t	A_t em m^2
Poço-Manifold	$10^{3/4}$ pol	$5/8$ pol	19.880 pol^2	0.013 m^2
Manifold-Costa	22 pol	$1/2$ pol	33.772 pol^2	0.022 m^2




Figura 3: Marcos e recordes mundiais de distâncias de *tiebacks* em campos de petróleo e gás. Fonte: Offshore Magazine, 2014

Além da premissa previamente descrita, a proposição do problema recorre a algumas simplificações conforme listado a seguir:

- São considerados apenas os custos relativos ao volume de aço utilizado nas tubulações (não estão incluídos os custos dos *manifolds* em si, custos de instalação, entre outros);
- O fundo do mar é considerado plano e horizontal;
- Não há limitação de número máximo de poços por *manifold*;
- Todo poço é interligado a um *manifold*, mesmo quando interligado sozinho.

3 METODOLOGIA

A metodologia proposta visa encontrar a quantidade e as posições de *manifolds* que satisfaçam as restrições do problema e minimizem o volume total de aço utilizado pelas linhas de coleta através de algoritmos computacionais inspirados na natureza. Com este objetivo, foram empregados dois algoritmos:

- Evolução Diferencial (DE); e
- Otimização por Enxame de Partículas (PSO).

3.1 Evolução Diferencial (DE)

A idéia principal da evolução diferencial é gerar novos indivíduos a partir de uma amostragem inicial de N_p indivíduos realizada aleatoriamente com uma função de distribuição uniforme dentro do espaço de busca D , onde a cada iteração cada indivíduo X dos N_p tem três indivíduos

diferentes, escolhidos aleatoriamente para aplicação dos operadores (Monteiro, B. D. F. et al., 2011).

O algoritmo de Evolução Diferencial utilizado é do tipo DE/rand/1/bin (**Eq. (1)**), ou seja, o vetor base mutado é selecionado aleatoriamente, a perturbação do vetor base é feita com uma só diferença e o esquema de cruzamento é o binomial (Storn & Price, 1995).

Para cada target vector $x_{i,G}, i = 1, \dots, NP$, um novo vetor é gerado por meio da seguinte relação:

$$DE/rand/1/bin \quad \nu_{i,G+1} = x_{r1,G} + F \cdot (x_{r3,G} - x_{r2,G}) \quad (1)$$

$r_1, r_2, r_3 \in 1, 2, \dots, NP$ são índices mutuamente distintos e também diferentes do índice i .

F é uma constante real $\in [0, 2]$ que determina o tamanho do passo a ser dado na direção definida pelo vetor diferença $x_{r3,G} - x_{r2,G}$.

Configurações do algoritmo:

- NP: 40 indivíduos;
- Critério de parada: tolerância $< 0,001 m^3$;
- F (fator diferencial): 0,6; e
- CR (taxa de crossover): 0,9.

3.2 Otimização Por Enxame De Partículas (PSO)

Esse método implementa uma metáfora do comportamento social de um grupo de pássaros que procuram o alimento ou um lugar para construir o ninho.

A trajetória de cada indivíduo no espaço de busca é ajustada alterando dinamicamente a velocidade de cada partícula, de acordo com sua velocidade atual, sua própria experiência (componente cognitivo) e o progresso das outras partículas no espaço de busca (componente social) (Monteiro, B. D. F. et al., 2011). Analogamente no algoritmo, uma partícula irá se mover em uma determinada direção que é função da posição atual da partícula $x_i(t)$, de uma velocidade $v_i(t)$, da posição p_i da partícula que levou ao seu melhor desempenho até o momento, e do melhor desempenho global do sistema até o momento p_g .

O algoritmo de otimização por enxame de partículas utilizado é um PSO Clássico (**Eq. (2)** e **(3)**) disponibilizado no site do CEC 2014 para MATLAB. O PSO é do tipo Modelo Completo (constantes e dos termos cognitivo e social > 0), conforme descrito pela **Eq. (2)** (Kennedy & Eberhart, 1995).

A velocidade da partícula será dada por:

$$v_i(t+1) = v_i(t) + \phi_1 \cdot rnd_1 \frac{(p_i - x_i(t))}{\Delta t} + \phi_2 \cdot rnd_2 \frac{(p_g - x_i(t))}{\Delta t} \quad (2)$$

Primeiro atualiza-se a velocidade e depois a posição:

$$x_i(t+1) = x_i(t) + v_i(t+1)\Delta t \quad (3)$$

Configurações do algoritmo:

- NP: 40 indivíduos;
- Critério de parada: tolerância $< 0,001 \text{ m}^3$;
- Constantes de aceleração ϕ_1 e $\phi_2 = 2$.

3.3 Função Objetivo

A função-objetivo é a função que representa o desempenho no sistema e é objeto de otimização (minimização) através dos algoritmos de DE e PSO. No caso deste trabalho é o cálculo do volume total de aço necessário para realizar todas as conexões entre poços, *manifolds* e ponto de recebimento. A **Figura 4** apresenta a fórmula da função-objetivo, onde x e y representam os valores de posição nas coordenadas cartesianas e c_{ij} é uma variável binária que indica a existência de conexão entre o poço i e o *manifold* j .

$$FUNÇÃO \text{ Volume_total_aço} = A_{t(poço-manifold)} \sum_{j=1}^M \sum_{i=1}^P c_{ij} \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} + A_{t(manifold-Pt.fixo)} \sum_{j=1}^M c_{ij} \sqrt{(x_j)^2 + (y_j)^2}$$

Função a ser minimizada

Soma das distâncias das conexões entre poço e manifold

Soma das distâncias das conexões entre manifold e costa

Figura 4: Função-objetivo do problema proposto.

A seguinte listagem apresenta cada um dos passos que formam a função objetivo programada:

1. Define um número máximo de *manifolds* (M) – não necessariamente todos precisam ser utilizados;
2. Cada *manifold* (M) é identificado por um valor de X_M e Y_M (problema de dimensão $2 \times M$):
 - Vetor indivíduo do tipo $(X_1, Y_1, X_2, Y_2, \dots, X_M, Y_M)$;
3. Inicializa um indivíduo aleatoriamente no domínio;
4. Para cada poço (P), calcula a distância entre este poço e todos os *manifolds* — Matriz $P \times M$;
5. Para cada poço, mantém a conexão com o *manifold* mais próximo e zera os demais valores — Matriz de distâncias conectadas $P \times M$:
 - Se a conexão mais próxima violar a condição do raio máximo (30 km), atribuir uma penalização;
 - A penalização usada é a soma da distância entre o poço e todos os *manifolds*;
6. Multiplica a matriz de distâncias conectadas pela área da seção transversal das tubulações poço-*manifold* e calcula a soma (volume total de aço nas linhas poço-*manifold*);
7. Calcula a distância entre o ponto de chegada em terra $(0, 0)$ e os *manifolds* — Matriz $1 \times M$

8. Multiplica a matriz de distâncias pela área da seção transversal das tubulações *manifold*-terra e calcula a soma (volume total de aço nas linhas *manifold*-terra)
9. Soma o volume total de aço das linhas poço-*manifold* com volume total de aço das linhas *manifold*-terra (função para minimização)

Nota-se que os *manifolds* não utilizados terão distância virtualmente zero para todos os poços e a otimização dos algoritmos tenderá a levar estes *manifolds* para a origem de forma a minimizar a distância entre estes *manifolds* (sem nenhuma conexão com poços) e o ponto de chegada (0, 0). Desta forma, ao fim da otimização sabe-se quantos *manifolds* foram realmente utilizados.

3.4 Condição de Parada

A condição de parada contém dois critérios:

1. Número máximo de avaliações, sendo este um valor grande o suficiente para assegurar a convergência da solução; e
2. Tolerância ao erro: o erro no resultado deve ser menor ou igual a uma tolerância escolhida segundo as necessidades do problema.

A implementação do primeiro critério não apresenta problema. Porém, a implementação do segundo critério no problema estudado apresenta a dificuldade de que não é conhecido o valor ótimo do problema. Para este caso existe um critério comumente utilizado que avalia a proximidade entre a média e o ótimo da população de uma geração e atribui-se uma diferença aceitável para que a otimização se encerre. Mas estudando os gráficos de desempenho (**Figura 5**) é possível ver que esse critério seria utilizável apenas com o algoritmo de evolução diferencial, pois esses dois valores realmente chegam a convergir no período estudado. Porém, com o algoritmo de otimização por enxame de partículas esse critério nunca seria atingido no período estudado.

Os gráficos expostos na **Figura 6** e na **Figura 7** ilustram melhor as diferenças que se verificam entre a média e os ótimos para cada geração segundo os algoritmos DE e PSO, respectivamente. Assim pode-se ver que no algoritmo DE a diferença chega a ser inferior a 1, mas no PSO a diferença mínima é de 78.000, o que inviabiliza o critério de parada que avalia a diferença entre a média e o ótimo.

Por este motivo se decide elaborar um outro critério aplicável aos dois algoritmos (DE e PSO). Para esse fim se estuda o comportamento dos algoritmos quando os mesmos se aproximam à resposta.

É possível notar que ao se aproximar do valor ótimo as diferenças entre os valores ótimos de uma geração e outra são cada vez menores. Aproveitando essa característica poderia se aplicar uma tolerância a essa diferença. Mas, às vezes, de uma geração para outra não existem mudanças (quando os algoritmos não evoluem entre gerações) mesmo ainda distantes do ótimo global. Então essa condição é necessária, mas não suficiente. Por esse motivo é preciso estudar outras quantidades que mudam à medida que o programa se aproxima do ótimo global.

Estudando o histórico das diferenças de ótimos ao longo das gerações pode-se perceber que esse valor vai diminuindo conforme se aproxime do ótimo, mas às vezes de uma geração para outra ela atinge valores realmente baixos ou nulos, mas logo recuperam a tendência que




Figura 5: Gráfico de desempenho de uma rodada padrão de DE e PSO.




Figura 6: Diferença entre a média e o ótimo da população ao longo da execução do algoritmo DE.

mantinham antes dessa mudança abrupta. Portanto, tirando a diferença de duas diferenças entre ótimos consecutivos pode se identificar as mudanças abruptas que causam a parada do ciclo iterativo.

Desse modo as condições necessárias e suficientes ficam determinadas, pois quando a variação do ótimo de uma geração para outra é pouca ($< tolerancia_1$) e a variação dessa quantidade é baixa ($< tolerancia_2$) o algoritmo encontrou o valor ótimo. A Tabela 3 resume as tolerâncias utilizadas nos algoritmos.




Figura 7: Diferença entre a média e o ótimo da população ao longo da execução do algoritmo PSO.




Figura 8: DE versus PSO. Diferença entre a média e o ótimo da população ao longo da execução.

4 RESULTADOS E DISCUSSÕES

A **Tabela 4** resume os resultados e estatísticas de 51 execuções de cada algoritmo (DE e PSO) considerando como caso base uma população com 40 indivíduos e raio de influência dos *manifolds* de 30 km. A escolha do número de execuções igual a 51 se deve ao fato de ser

Tabela 3: Tabela dos Limites para o critério de parada

Quantidade Avaliada	Limite	Descrição
Número de Avaliações	100.000*D	<i>Número máximo de avaliações da função objetivo, em função do número de dimensões do problema D.</i>
Tolerância 1	0,001 m ³	<i>Tolerância do melhor em unidade de metro cúbico.</i>
Tolerância 2	0,001 m ³	<i>Tolerância que limita a variação máxima das diferenças entre ótimos de geração em geração.</i>

um número comumente utilizado para avaliar algoritmos por ser uma amostra representativa e por ter uma mediana contida na mesma. O critério de parada utilizado for o descrito na seção anterior.

Tabela 4: Tabela Comparativa DE vs PSO para R=30km e Pop=40 (volume de aço em m³).

	DE			PSO		
	Vol Aço	No. de Avaliações	No. de Gerações	Vol Aço	No. de Avaliações	No. de Gerações
Média	46.211,6	127.491	3.186	202.589,7	719.803	17.996
Mediana	46.211,6	124.040	3.100	46.783,2	767.960	19.200
Máximo	46.211,6	164.040	4.100	1.668.111,6	1.019.960	25.500
Mínimo	46.211,6	100.040	2.500	45.991,9	223.960	5.600
Desvio Padrão	0,0011	15.799,13	395	351798	182.624,35	4.566
Soluções Viáveis	51 soluções (100%)			40 soluções (78%)		

Percebe-se que, para uma população de 40 indivíduos e 51 execuções do algoritmo, a evolução diferencial apresenta 100% de soluções viáveis, com todos os valores convergindo para o valor do mínimo de 46.211,6 m³. Já no PSO, 78% das soluções foram consideradas viáveis dentro das restrições do problema, com pelo menos a metade das execuções convergindo para um valor próximo do mínimo encontrado (45.991,9 m³). Devido ao tratamento da violação da restrição do raio de influência através de função de penalização, as soluções não viáveis assumem valores de função-objetivo muito altos, mesmo se estiverem próximas de uma solução viável. Desta forma, os números muito altos nos valores médios e máximo são apenas um indicativo de presença de soluções não viáveis dentro das 51 execuções do PSO. A ordem de grandeza de soluções próximas do mínimo pode ser inferida pelo valor da mediana.

O custo computacional da otimização por PSO é muito superior ao custo da otimização pelo DE (5,5 vezes maior em termos de número de avaliações da função-objetivo). Em contrapartida, o PSO conseguir otimizar para um valor mínimo ligeiramente inferior ao conseguido pelo DE. De forma sucinta, é possível afirmar que, para os parâmetros de algoritmo utilizados, o DE tem maior confiabilidade e menor custo computacional do que o PSO. Uma otimização realizada para o mesmo problema e com as mesmas restrições e parâmetros através do “Evo-

lutionary Solver” do Microsoft Excel – uma ferramenta de algoritmo genético – chega em um resultado mínimo da função-objetivo de $46.213,1 m^3$, estando de completo acordo com os valores encontrados pelos algoritmos testados neste trabalho.

É possível ver na **Figura 9** o gráfico de desempenho de ambos os algoritmos para uma rodada arbitrária representativa. Vale salientar que o PSO demorou muito mais que o DE para atingir o valor ótimo e que, no intervalo estudado, a curva da média e do ótimo não conseguem convergir (ver **Figura 5**).




Figura 9: Gráfico de desempenho de uma rodada padrão de DE e PSO.

A **Figura 10**, apresenta visualmente e lado a lado as soluções dos algoritmos DE e PSO para a melhor solução encontrada nas 51 execuções de cada algoritmo. Os círculos tracejados indicam o raio de influência de cada *manifold*, estando cada um (e seus poços conectados indicados por pontos) representado por uma cor. Os valores dos eixos estão em unidades de quilômetros. Note que ambas as soluções são extremamente similares, com otimização para 8 *manifolds* e uma pequena diferença de configuração apenas para os *manifolds* representados nas cores laranja e amarelo.

4.1 Sensibilidade ao Raio de Influência

Para estudar a resposta dos algoritmos a outras situações foi realizada uma análise de sensibilidade ao raio de influência dos *manifolds*. Com os resultados obtidos foi construída a **Tabela 5** com os valores estatísticos de 51 execuções de cada algoritmo para os diferentes raios avaliados (20, 30, 50 e 90 km). A **Figura 11** demonstra em mapa os arranjos de desenvolvimento para os diferentes casos estudados.

O aumento do raio de influência dos *manifolds* acarreta uma diminuição do volume de aço utilizado, visto que o número de *manifolds* necessários para atender ao problema diminui e, consequentemente, o comprimento total de linhas de coleta também se reduz. Em termos de




Figura 10: Comparativo visual da solução mínima de cada algoritmo.

desempenho do algoritmo, percebe-se uma deterioração do número de soluções viáveis com a diminuição do raio de influência. Isto é decorrência da diminuição do domínio viável do problema. Para o algoritmo de DE, esta deterioração é mais sutil, tendo grande efeito apenas para o caso de $R = 20$ km. Ambos os algoritmos encontram mínimos compatíveis para todos os raios estudados. De qualquer forma, o DE apresenta-se sempre mais confiável de acordo com o número de soluções viáveis encontradas (à exceção do caso de $R = 20$ km) e com número de avaliações bastante inferior em comparação com o PSO.

4.2 Sensibilidade ao Tamanho da População

A Tabela 6 apresenta os resultados do desempenho dos algoritmos de DE e PSO em 51 execuções para diferentes tamanhos de população e para um raio de influência dos *manifolds* fixo de 30 km.

O algoritmo de evolução diferencial demonstra ter um resultado ótimo para a população com 40 indivíduos. Para valores menores há a ocorrência de algumas simulações com soluções inviáveis, enquanto que valores maiores não apresentam melhora em nenhum dos parâmetros estatísticos calculados. Ainda, nota-se um crescimento relativo elevado do número de avaliações com o aumento do tamanho da população: 11,9% por unidade adicional de indivíduo na população, ou seja, aumento de 476,8% no número de avaliações médio com o aumento da população de 20 para 60 indivíduos.

O algoritmo de otimização por enxame de partículas demonstra ter uma melhora do resultado aumentando-se o número de indivíduos na população desde 20 até 140, onde 98% das




Figura 11: Comparativo visual de soluções viáveis para os diferentes raios de influência.

soluções encontradas são viáveis. Ou seja, necessita de uma população bastante superior à do algoritmo DE para atingir o mesmo nível de confiabilidade. Peculiarmente, destaca-se que o aumento da população no algoritmo PSO provoca uma pequena melhora no resultado otimizado da função-objetivo, atingindo valores até 1% menores do que o mínimo encontrado pelo DE. Embora o número de avaliações via PSO seja muito superior ao DE, o aumento relativo do custo computacional com o aumento da população é baixo: 1,77% por unidade adicional de indivíduo

Tabela 5: Sensibilidade ao raio de influência (volume de aço em m^3).

	Vol Aço	Número de Avaliações	Número de Gerações	Vol Aço	Número de Avaliações	Número de Gerações
	DE Raio 20 km			PSO Raio 20 km		
Média	659.800,8	175.805	4.394	784.588,4	696.823	17.422
Mediana	889.857,8	176.040	4.400	750.387,5	715.960	17.900
Máximo	890.097,2	220.040	5.500	2.400.211,4	1.247.960	31.200
Mínimo	51.468,1	148.040	3.700	51.315,2	255.960	6.400
Desvio Padrão	3,78E+05	16.246,34	406	734.221	212.487,46	5.312
Soluções Viáveis	14 27%			19 37%		
	DE Raio 30 km			PSO Raio 30 km		
Média	46.211,6	127.491	3.186	202.589,7	719.803	17.996
Mediana	46.211,6	124.040	3.100	46.783,2	767.960	19.200
Máximo	46.211,6	164.040	4.100	1.668.111,6	1.019.960	25.500
Mínimo	46.211,6	100.040	2.500	45.991,9	223.960	5.600
Desvio Padrão	1,10E-03	15.799,13	395	351.798	182.624,35	4.566
Soluções Viáveis	51 100%			40 78%		
	DE Raio 50 km			PSO Raio 50 km		
Média	35.231,8	105.373	2.633	50.635,6	711.254	17.782
Mediana	35.186,2	104.040	2.600	35.661,7	747.960	18.700
Máximo	37.514,2	144.040	3.600	480.131,1	1.115.960	27.900
Mínimo	35.186,2	84.040	2.100	35.186,4	255.960	6.400
Desvio Padrão	3,26E+02	13.544,99	339	62.313	263.510,71	6.588
Soluções Viáveis	51 100%			50 98%		
	DE Raio 90 km			PSO Raio 90 km		
Média	31.836,2	101.609	1.129	35.002,8	681.764	7.575
Mediana	31.870,1	100.040	1.112	31.871,9	767.960	8.533
Máximo	33.121,2	132.040	1.467	48.524,4	995.960	11.066
Mínimo	31.239,8	76.040	845	31.239,8	235.960	2.622
Desvio Padrão	3,80E+02	14.817,90	165	4.487	273.332,40	3.037
Soluções Viáveis	51 100%			51 100%		

na população, ou seja, aumento de 70,8% no número médio de avaliações com o aumento da população de 20 para 60 indivíduos (comparado aos 476,8% do DE).

5 CONCLUSÕES

Foi estudado o problema de localização de *manifolds* submarinos para coleta de produção de 20 poços com o objetivo de minimizar o custo dos dutos, representado pelo volume total de aço utilizado. Para a solução deste problema foram utilizados dois algoritmos baseados na natureza: Evolução Diferencial (DE) e Otimização por Enxame de Partículas (PSO). Os resultados do desempenho dos algoritmos foram estudados à luz dos mesmos parâmetros de critério de parada (tolerância $< 0,001m^3$), número de indivíduos na população (40) e raio de influência dos *manifolds* (30 km).

Ambos os algoritmos convergem para a mesma solução ótima: 8 *manifolds* com posições praticamente idênticas e valor da função minimizada de $46.211 m^3$. Em média, a quantidade de avaliações da função no PSO em relação ao DE é 5,5 vezes maior para atingir o mínimo dentro de uma mesma tolerância. Para 51 avaliações de cada algoritmo, o DE tem 100% de soluções viáveis, enquanto que o PSO tem 78%, mantendo-se o número da população em 40

Tabela 6: Sensibilidade ao Tamanho da População (volume de aço em m³).

	Vol Aço	Número de Avaliações	Número de Gerações	Vol Aço	Número de Avaliações	Número de Gerações
	DE POP = 20			PSO POP = 20		
Média	176.894,6	61.471	3.073	179.734,5	652.098	32.606
Mediana	46.212,5	58.020	2.900	48.078,3	659.980	33.000
Máximo	879.253,2	102.020	5.100	849.484,4	861.980	43.100
Mínimo	45.976,7	34.020	1.700	45.986,2	269.980	13.500
Desvio Padrão	3,06E+05	16.483,10	824	254.970	122.097,94	6.105
Soluções Viáveis	43 84%			39 76%		
	DE POP = 40			PSO POP = 40		
Média	46.211,6	127.491	3.186	202.589,7	719.803	17.996
Mediana	46.211,6	124.040	3.100	46.783,2	767.960	19.200
Máximo	46.211,6	164.040	4.100	1.668.111,6	1.019.960	25.500
Mínimo	46.211,6	100.040	2.500	45.991,9	223.960	5.600
Desvio Padrão	1,10E-03	15.799,13	395	351.798	182.624,35	4.566
Soluções Viáveis	51 100%			40 78%		
	DE POP = 60			PSO POP = 60		
Média	46.213,1	293.119	4.884	213.765,0	881.469	14.692
Mediana	46.211,6	288.060	4.800	46.284,1	881.940	14.700
Máximo	46.284,8	468.060	7.800	1.755.879,6	1.337.940	22.300
Mínimo	46.211,6	216.060	3.600	45.788,2	299.940	5.000
Desvio Padrão	1,02E+01	39.932,65	666	381.223	269.687,40	4.495
Soluções Viáveis	51 100%			43 84%		
	DE POP = 100			PSO POP = 100		
Média	-	-	-	148.977,2	1.145.978	11.461
Mediana	-	-	-	46.212,1	1.279.900	12.800
Máximo	-	-	-	1.254.222,7	1.699.900	17.000
Mínimo	-	-	-	45.773,1	379.900	3.800
Desvio Padrão	-	-	-	301.052	335.482,21	3.355
Soluções Viáveis	-			47 92%		
	DE POP = 140			PSO POP = 140		
Média	-	-	-	66.794,9	1.385.585	9.898
Mediana	-	-	-	45.980,3	1.399.860	10.000
Máximo	-	-	-	1.103.378,7	1.651.860	11.800
Mínimo	-	-	-	45.774,9	489.860	3.500
Desvio Padrão	-	-	-	148.054	180.127,07	1.287
Soluções Viáveis	-			50 98%		

indivíduos. Os seja, para os parâmetros adotados de configuração de cada algoritmo, conclui-se que a solução do problema em questão possui maior confiabilidade e menor custo computacional via evolução diferencial.

O estudo de sensibilidade ao tamanho da população mostrou que, para atingir um mesmo nível de confiabilidade dos resultados de DE, a solução por PSO deve considerar um número de indivíduos na população de pelo menos 140, enquanto que o DE tem confiabilidade de 100% para apenas 40 indivíduos. Embora a discrepância de custo computacional seja incontestável, nota-se que o aumento proporcional de avaliações com o aumento da população é muito menor para o PSO.

O estudo de sensibilidade ao raio de influência dos *manifolds* mostrou que os algoritmos são pouco confiáveis para raios menores do que 20 km, devendo-se então aumentar o tamanho da população para ter uma melhor robustez na busca pela melhor solução. Mantendo-se o número

da população em 40 indivíduos, a solução por PSO passa a ter boa confiabilidade apenas para raios superiores a 50 km.

Como sugestão para trabalhos futuros, recomenda-se um estudo paramétrico das configurações dos algoritmos de forma a buscar o conjunto de parâmetros que otimize o número de avaliações dos algoritmos mantendo a confiabilidade de 100% das soluções viáveis em um conjunto de 51 execuções.

REFERÊNCIAS

ANP-Agência Nacional do Petróleo, Gás Natural e Biocombustíveis, 2007. *Sumário Executivo do Campo de Frade*.

ANP-Agência Nacional do Petróleo, Gás Natural e Biocombustíveis, 2009a. *Sumário Executivo do Campo de Tambau*.

ANP-Agência Nacional do Petróleo, Gás Natural e Biocombustíveis, 2009b. *Banco de dados de Exploração e produção*.

Castiñeira, P, 2014. *Otimização do Posicionamento de Manifolds Submarinos Através de Algoritmos Genéticos*. Dissertação de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

CEC-2014, Congress on Evolutionary Computation, 2014. *Special Session Competition on Real-Parameter Single Objective (Expensive) Optimization*, PR-China, 6-11 July 2014.

FMC Technologies, 2015a. Chevron Frade BV. Disponível em: <http://www.fmctechnologies.com/SubseaSystems/GlobalProjects/South%20America/Brazil/ChevronFrade.aspx?tab={5665D640-B679-4BCC-83FC-F83F5AD2A7F5}>

FMC Technologies, 2015b. Petrobras Tambau.

Disponível em: <http://www.fmctechnologies.com/SubseaSystems/GlobalProjects/South%20America/Brazil/PetrobrasTambau.aspx?tab={B86E8245-B9F9-4805-9DE8-9FBB8C2F4144}>

Kennedy & Eberhart, 1995. *Neural Networks*. Proceedings., IEEE International Conference on (Volume:4). Piscataway, NJ:1942–1948, 1995.

Monteiro, B. D. F. & Lima Junior, M. H. A. & Albrecht, C. H. & Lima, B. L. P. & Jacob, B. P., 2011. *Differential Evolution and Particle Swarm Optimization Methods for the Optimization of Mooring Systems for Floating Production Platforms*. CILAMCE 2011.

Offshore Magazine, 2014. *Deepwater Solutions Records for Concept Selection*, WoodGroup Mustang, maio de 2014. Disponível em: <http://www.offshore-mag.com/maps-posters.html>

Storn & Price, 1995. *Differential Evolution - A simple and efficient adaptive scheme for global optimization over continuous space*. Technical Report TR-95-012, International Computer Science Institute, Berkeley, mar.1995.