



PONTIFÍCIA UNIVERSIDADE CATÓLICA
DO RIO DE JANEIRO



Renato Kalman Gonçalves

Otimização de alocação de sondas para exploração off-shore de hidrocarbonetos por algoritmos genéticos

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

Prof.^a. Marley Maria Bernardes Rebuszi Vellasco, Ph.D.

Prof. Marco Aurélio Cavalcanti Pacheco, Ph.D.

Rio de Janeiro

10/12/2009



*À minha mãe Betty (in memoriam),
ao meu pai Alcides
e à minha irmã Helena.*

Agradecimentos

Agradeço à minha coordenadora, a analista de sistemas Luciane Pierri de Mendonça Nobre, por sua disposição e presteza em ajudar no que fosse necessário para o desenvolvimento deste trabalho.

Gostaria de agradecer também ao geólogo Luciano Arantes Rezende Costa e ao engenheiro de produção Régis Yuzo Mori Alves da Silva pelos conhecimentos transferidos sobre o problema.

Finalmente, gostaria de agradecer ao meu gerente, o geofísico Fernando da Silva Rodrigues, ao consultor Luiz Alberto Barbosa de Lima e à Petrobras por me proporcionarem a oportunidade de cursar a pós-graduação que me conduziu a este trabalho.

RESUMO

Com a demanda mundial por energia cada vez mais crescente, a indústria do petróleo encontra um grande desafio na alocação de recursos para encontrá-lo e produzi-lo. Atualmente, um recurso considerado escasso e de alto custo são as sondas de perfuração de poços para atividades de exploração *off-shore*, visando a descoberta de novos reservatórios de hidrocarbonetos em ambiente marítimo. Garantir a disponibilidade de tais recursos no tempo devido e ao menor custo possível é um dos objetivos do planejamento exploratório. Há, ainda, que se considerar as obrigações existentes com a agência reguladora e a responsabilidade ambiental. Dados estes fatores, torna-se complexa a atividade de realizar a melhor alocação de sondas de forma a se obter o maior retorno econômico no menor tempo possível. Este trabalho tem por objetivo desenvolver um sistema de apoio à decisão para auxílio nesta árdua tarefa. Para atingir este objetivo, será utilizada uma técnica de inteligência computacional conhecida como algoritmos genéticos para que a ferramenta seja capaz de sugerir uma alocação de sondas em um tempo computacional aceitável, considerando as complexidades envolvidas no problema. Posteriormente, os resultados obtidos pelo sistema são comparados com um cronograma real, feito sem ajuda de computadores, apenas com base na intuição dos planejadores.

ABSTRACT

With global demand for energy growing ever more, the oil industry has a major challenge in the allocation of resources to find it and produce it. Currently, a resource considered scarce and expensive are drilling rigs for off-shore exploration activities, aiming at the discovery of new reserves of hydrocarbons in the marine environment. Ensure the availability of such resources in due time and at the lowest possible cost is one of the goals of the exploratory planning. There is also important to consider the existing obligations to the regulatory agency and environmental responsibility. Given these factors, it is a complex activity to achieve the best allocation of drilling rigs in order to obtain the greatest economic return in the shortest time possible. This study aims to develop a decision support system to aid this difficult task. To achieve this goal, an artificial intelligence technique known as genetic algorithms will be used so that this system is able to suggest an allocation of the rigs in an acceptable computational time, considering the complexities involved in the problem. Later, the results obtained by the system are compared with an actual schedule, made without the aid of computers, just based on the intuition of the planners.

SUMÁRIO

1.	MOTIVAÇÃO	7
1.1.	DESCRIÇÃO DO TRABALHO	10
1.2.	ORGANIZAÇÃO DA MONOGRAFIA.....	10
2.	DESCRIÇÃO DO PROBLEMA	12
3.	ESTADO DA ARTE – ALGORITMOS GENÉTICOS	16
3.1.	BREVE HISTÓRICO	16
3.2.	NOMENCLATURA	17
3.3.	FUNCIONAMENTO.....	17
3.4.	ALGORITMO GENÉTICO HÍBRIDO	21
4.	ARQUITETURA DO SISTEMA PROPOSTO.....	22
4.1.	REPRESENTAÇÃO DO CROMOSSOMA.....	23
4.2.	RESTRICÇÕES.....	23
4.3.	DECODIFICAÇÃO DO CROMOSSOMA.....	24
4.3.1.	Exemplo	24
4.3.2.	Outras atividades da sonda	26
4.3.3.	Deslocamento da sonda	26
4.4.	AVALIAÇÃO.....	26
4.4.1.	Função de Avaliação	27
4.5.	OPERADORES.....	28
4.5.1.	<i>Crossover</i>	28
4.5.2.	Mutação.....	30
4.6.	TÉCNICAS.....	32
4.6.1.	Reprodução	32
4.6.2.	Inicialização da população.....	32
4.6.3.	Evolução adaptativa	32
5.	RESULTADOS	34
6.	CONCLUSÕES E TRABALHOS FUTUROS	39
	REFERÊNCIAS BIBLIOGRÁFICAS	41

1. MOTIVAÇÃO

Num mundo altamente competitivo e dinâmico como o que vivemos hoje, as empresas buscam cada vez mais maneiras de reduzir custos ou aumentar sua receita, de forma a serem eficientes e estarem a frente da concorrência. Sendo assim, as empresas têm cada vez mais investido na tecnologia da informação como uma forma de otimizar seus processos. Seus gestores necessitam tomar decisões rápidas e de melhor qualidade, nos momentos oportunos. O dinamismo do mercado causa mudanças rápidas e proporciona circunstâncias complexas, fazendo com que decisões velozes e precisas se tornem fundamentais para obter uma boa vantagem competitiva.

Todos estes fatores, somados à complexidade inerente encontrada nos problemas operacionais das empresas, fazem com que seja arriscado realizar seus planejamentos apenas com base na intuição. Além disso, as empresas se veem cada vez mais pressionadas por questões ambientais, o que torna seus problemas operacionais ainda mais complexos, pelas obrigações que são obrigadas a cumprir neste contexto. Assim, surge a necessidade de utilização de ferramentas que apoiem os gerentes na tomada de decisão.

Empresas que exploram recursos naturais como, por exemplo, as indústrias de mineração e petróleo, costumam possuir uma complexidade operacional muito grande em seus principais processos. Um problema comum a estas indústrias é possuir um número limitado de recursos para atender a uma grande quantidade de projetos. Sendo assim, para estes processos, é necessário realizar um cronograma de execução dos projetos.

Este problema é conhecido como um Problema de Scheduling de Projetos com Restrição de Recursos (*Resource Constrained Project Scheduling Problem – RCSPP*) e pertence à classe dos problemas de otimização combinatória. O conceito de projeto atualmente aceito e utilizado (PMBOK, 2000) é de que um projeto é um empreendimento temporário, com data de início e fim, com objetivo de criar ou aperfeiçoar um produto ou serviço. Segundo Vasconcellos (2007), na implantação de um projeto, a estimativa de aporte de recursos é feita com base, dentre outros aspectos, no cronograma (*schedule*) previsto para o projeto. Logo, esta etapa é vital no planejamento e controle do projeto pelo impacto que provoca no planejamento orçamentário.

Com a utilização de computadores, é possível criar ferramentas de apoio para a resolução deste tipo de problema. As ferramentas que utilizam técnicas

matemáticas, os chamados métodos exatos, como *Branch & Bound*, costumam implicar em tempo computacional inviável. Isto faz com que as pesquisas atuais busquem a utilização de métodos metaheurísticos de solução como GRASP (FEO e RESENDE, 1989), *Tabu Search* (KOLISH e HARTMANN, 2006) e algoritmos genéticos (MICHALEWICZ, 1996), dentre os quais este último tem se destacado. Também é possível a utilização de algoritmos híbridos destes (KOCHETOV e STOLYAR, 2003).

Na indústria de petróleo, cada vez mais as sondas de exploração têm se tornado um recurso crítico. Tendo em vista ser este um insumo escasso no mercado, ou seja, não existe oferta suficiente disponível para atender a demanda, os custos diários do seu aluguel, que já costumam ser vultosos, podem estar ainda mais majorados. Faz-se necessário, portanto, trabalhar com um planejamento plurianual da sua alocação.

Na realização do planejamento de sondas vários fatores precisam ser levados em consideração. Alguns deles são: as políticas de investimentos da empresa, as avaliações do potencial petrolífero de diferentes áreas, os compromissos firmados com a agência nacional reguladora da atividade de exploração e exploração petrolífera e responsabilidades com o meio-ambiente. Considerando todos os fatores envolvidos, percebe-se que esta não é uma atividade trivial.

Denominaremos o problema a ser tratado de Problema de Alocação de Sondas para Projetos Exploratórios (PASPE). Trataremos aqui de uma situação onde existem algumas poucas dezenas de sondas para atender a centenas de projetos exploratórios de uma empresa de grande porte do segmento de exploração de petróleo.

Na literatura, foram encontrados trabalhos buscando soluções para o problema de alocação de sondas, porém não associados à atividade exploratória, mas sim à intervenções em poços produtores para minimização da perda de vazão. Este problema é chamado de Problema de Intervenção em Poços (PIP) e é conceitualmente diferente do PASPE, pois possuem objetivos distintos. Enquanto no PIP tratamos de minimizar o tempo gasto para intervir em um dado número de poços (minimização do *makespan*), diminuindo também o custo total, aqui estamos interessados em maximizar o retorno econômico no menor tempo possível. Além disso, no PIP todos os poços devem ser atendidos. Na

perfuração de poços para exploração, temos um horizonte de tempo definido e alguns projetos da carteira podem ficar fora do planejamento.

O trabalho de Costa (2005) sugere uma solução para o PIP na produção terrestre. Buscando alternativas para resolução do problema, o autor realizou implementações utilizando programação inteira em conjunto com heurísticas e metaheurísticas. As heurísticas utilizadas foram a Heurística de Máxima Prioridade Tricritério (HMPT) e a Heurística de Montagem Dinâmica (HMD). A metaheurística usada foi GRASP (*Greedy Randomized Adaptive Search Procedures*). O autor chega a conclusão de que a técnica que obteve melhor desempenho foi HMD. Entretanto, seus testes foram feitos em um cenário com um número reduzido de sondas e poços e, provavelmente, envolveria um tempo computacional muito elevado para o planejamento plurianual da exploração de hidrocarbonetos em todo o Brasil de uma empresa de grande porte, como é o caso a ser tratado nesta monografia.

Natal (2003), em seu trabalho, trata do problema PIP utilizando uma técnica de programação matemática chamada programação não-linear inteira. Em seu estudo de caso fica exposta a limitação dos métodos matemáticos, pois se trata de um exemplo com poucas sondas e poucos poços envolvidos.

Vasconcellos (2007) também trata do PIP, utilizando simulação de Monte Carlo para estimar a duração dos projetos e algoritmo genético (AG) para realizar a alocação das sondas. Foram desenvolvidas duas abordagens no tratamento das aleatoriedades inerentes ao processo: análise estatística dos dados e inferência por redes neurais. A metodologia foi validada através da aplicação em um exemplo com dados reais e com a posterior comparação dos resultados obtidos com aqueles fornecidos por outras técnicas de solução – Branch & Bound, GRASP e Programação por Restrições. O autor conclui que sua abordagem comprovou a eficácia e eficiência do algoritmo genético nos problemas de *scheduling* de projetos, por se basear em exemplos com dados reais. É interessante ressaltar que uma de suas sugestões de trabalhos futuro considere o maximizar Valor Presente Líquido (VPL) ao invés de minimizar o *makespan*, de forma semelhante ao que será feito no presente trabalho.

No trabalho de Borchardt (2002), é utilizado algoritmo genético também para o PIP, entretanto seu objetivo é maximizar a produção, o que difere do objetivo da pesquisa de Vasconcellos (2007). A autora implementa, além de um AG híbrido, o algoritmo transgenético Proto-Gene (ProtoG) da metaheurística

Transgenética Computacional. Sua conclusão é de que o ProtoG fornece melhores resultados para o problema em relação ao AG implementado.

O que se pode concluir dos trabalhos anteriores é que, mesmo quando são utilizados exemplos reduzidos e simplificados em relação a realidade, a utilização da tecnologia da informação e técnicas de inteligência computacional sempre traz vantagens no planejamento de alocação de sondas. Entretanto, como dito anteriormente, apesar do problema resolvido nestes trabalhos ter muitas características comuns ao que discutiremos, é diferente deste em seus objetivos, além de haver diferenças em algumas restrições e outras características que serão detalhadas mais adiante.

1.1. DESCRIÇÃO DO TRABALHO

Este trabalho foi realizado em sete etapas:

- Estudo de trabalhos anteriores;
- Definição do problema;
- Coleta e análise dos requisitos;
- Análise do mecanismo de inteligência computacional aplicado;
- Modelagem do problema para aplicação do mecanismo;
- Implementação de um Algoritmo Genético sobre o modelo proposto;
- Comparação da solução obtida com um cronograma já existente.

1.2. ORGANIZAÇÃO DA MONOGRAFIA

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

O capítulo 2 apresenta o problema de planejamento de sondas para projetos exploratórios, ressaltando os aspectos que o tornam complexo e mostrando como ele é realizado atualmente.

O capítulo 3 versa sobre a técnica que será utilizada para ajudar os planejadores a resolver o problema, a otimização por algoritmos genéticos.

No capítulo 4 são apresentados os detalhes da aplicação da técnica de inteligência computacional ao problema escolhido, ou seja, a implementação da ferramenta de apoio à decisão. Neste capítulo, indica-se a representação computacional utilizada para representar possíveis soluções, como decodificá-la

e avaliá-la, além da técnica empregada para a busca da "eficiência econômica" para o problema.

O capítulo 5 detalha os resultados obtidos e faz uma comparação com planejamentos realizados sem ferramentas de apoio à decisão, procurando mostrar os ganhos proporcionados.

Finalmente, o capítulo 6 descreve as conclusões do trabalho e identifica possíveis trabalhos futuros.

2. DESCRIÇÃO DO PROBLEMA

Em um ambiente onde as reservas de petróleo vêm diminuindo, todo dia é uma corrida para encontrar e produzir o máximo volume de óleo e gás ao menor custo possível (IRGENS e LAVENUE, 2007). Dentro deste contexto, o planejamento exploratório é uma disciplina tanto estratégica quanto crítica para a indústria de petróleo. Isto se dá pelos vultosos investimentos a ele associados e pelo risco subjacente às etapas do processo exploratório. Estes investimentos são particularmente significativos em se tratando da prospecção *offshore*, onde as profundidades a serem atingidas já ultrapassaram o marco de 10 mil metros.

Um planejamento exploratório compreende o estudo de projetos exploratórios para diferentes áreas de interesse. São estudadas tanto as áreas do portfólio da empresa quanto aquelas em que se pretende participar. Esta participação pode se dar tanto pela aquisição do direito de nelas trabalhar como pela entrada em parcerias com empresas que nelas atuam.

Num projeto exploratório busca-se quantificar e qualificar o potencial petrolífero de uma área, ou seja, o volume esperado de hidrocarbonetos economicamente recuperável. Faz parte do projeto o planejamento de atividades exploratórias e de atividades delimitatórias. O primeiro poço perfurado na área é denominado poço pioneiro. Se ele for descobridor de alguma acumulação de hidrocarbonetos prossegue-se com a investigação através da realização de atividades delimitatórias, de forma a determinar se a descoberta, até então considerada como geológica, é economicamente viável.

Na avaliação da comercialidade de uma descoberta, com frequência são perfurados poços de extensão, também denominados poços de avaliação. Neste caso, há necessidade de sonda tanto para a perfuração do poço pioneiro descobridor, como dos poços de extensão. O índice de sucesso (IS) representa o percentual de poços pioneiros que resultaram em descobertas economicamente viáveis. Mundialmente este índice está em torno de 25% (PETRÓLEO BRASILEIRO S.A., 2009).

Algumas das características de um projeto exploratório são a sua identificação, localização, requisitos tecnológicos e informações geológicas e econômicas. Dentre as informações de localização, temos coordenadas propostas para a boca (início) do poço, o bloco exploratório em que se encontra e a batimetria da área (lâmina d'água). Como informação derivada dos alvos do projeto, temos as formações geológicas, onde se encontram os potenciais

reservatórios de hidrocarbonetos que se pretendem alcançar e a profundidade vertical máxima a ser alcançada pelo poço.

O tempo para perfurar um poço é calculado tendo por base a profundidade final a ser alcançada por este e as diferentes estruturas geológicas que serão por ele atravessadas. Comumente faz-se analogia com poços em áreas semelhantes para estimá-lo. Sendo assim, é possível assumir que a duração dos projetos é conhecida.

Os projetos também diferem quanto ao seu grau de maturidade, classificando-se em ordem decrescente de conhecimento do sistema petrolífero originador da acumulação em identificados, indicados e conceituais (ROSE, 2001). Busca-se minimizar os riscos exploratórios procurando-se primeiro realizar atividades em áreas mais maduras. Esta informação encontra-se embutida nos "fatores de chance do projeto", tanto geológico (FCG) quanto econômico (FCE). Para cada projeto exploratório é avaliado o seu Valor Presente Líquido de Desenvolvimento para a Produção (VPLdp). Este valor é atualizado com referência ao ano de início de cada projeto, quando são realizadas as primeiras atividades exploratórias propostas.

Um dos recursos impactantes no orçamento de um projeto exploratório é o aluguel de sondas para perfuração dos poços. O aluguel de uma sonda corresponde, atualmente, a algumas centenas de milhares de dólares por dia, flutuando de acordo com as leis de oferta e demanda. Garantir a disponibilidade de tais recursos no tempo devido e ao menor custo possível é um dos objetivos do planejamento exploratório. Tal tarefa se torna ainda mais crítica considerando-se a escassez atual, em nível mundial, das sondas de perfuração, o que torna tal planejamento crítico não apenas em termos de utilização como também pela pouca oferta (RASHEED, 2006). Além de considerar a execução dos projetos exploratórios, também é preciso levar em consideração o tempo relativo às paradas para manutenção das sondas. As sondas são contratadas de diferentes fornecedores, que informam um cronograma de indisponibilidade das mesmas.

Na seleção de uma sonda para perfurar um poço alguns requisitos técnicos precisam ser atendidos. A sonda deve poder trabalhar na lâmina d'água onde o poço deve ser perfurado e conseguir atingir a profundidade final prevista para o mesmo. Também é necessário que a sonda possua uma licença ambiental específica, denominada anuência, para atuar na bacia geológica onde

o poço será perfurado. Além disso, alguns contratos de aluguel de sonda preveem que a mesma só pode atuar em determinadas bacias. Ainda, por questões de logística operacional, é interessante que a programação de uma sonda atenda projetos em localidades próximas, sem realizar grandes deslocamentos.

O direito de realizar atividades exploratórias é adquirido em leilões promovidos pela agência nacional reguladora desta atividade, a ANP (Agência Nacional do Petróleo, Gás e Biocombustíveis). Em tais leilões são ofertadas várias áreas, chamadas de blocos exploratórios. Um vencedor na competição para executar atividades exploratórias em um bloco fica incumbido de realizá-las em períodos com vencimentos pré-determinados. A exigência de execução destas atividades se chama Programa Exploratório Mínimo (PEM).

Atualmente, o PEM é calculado por Unidades de Trabalho, que são computadas pelo comprometimento da realização de certas atividades em quantidades propostas e multiplicadas pelos fatores determinados pela própria ANP no edital de licitação. Assim, são estabelecidas alíquotas diferenciadas para cada setor e de acordo com a atividade que será desenvolvida.

O não cumprimento do PEM poderá resultar a aplicação de diversas penalidades contratuais e administrativas pela ANP. As primeiras consubstanciam a obrigação de pagamento baseada em percentuais fixados no contrato de concessão, que incidirão sobre a diferença entre aquilo a que o concessionário se comprometeu e o que efetivamente cumpriu. Com relação às penalidades administrativas, a ANP poderá aplicar penalidades que, em função da gravidade, irão variar de multas pecuniárias a sanções restritivas de direito, que poderão levar à suspensão do direito de participar em rodadas de licitação pelo prazo mínimo de seis meses e máximo de cinco anos ou até mesmo o direito de celebrar contratos com a referida autarquia federal (LEMOS, 2004).

O que se busca, portanto, é gerar um cronograma de alocação de sondas, como na Figura 1, em projetos exploratórios de forma a obter a eficiência econômica, considerando os compromissos com a ANP e as consequências pelo não cumprimento destes. Atualmente, o cronograma é gerado e atualizado em reuniões semanais dos planejadores de exploração da empresa em estudo. Nestas reuniões, o conhecimento de cada participante sobre os projetos exploratórios e os compromissos nos blocos de responsabilidade de sua

gerência é essencial para a discussão conjunta. Ao final desta reunião, chega-se a um consenso nas alocações do cronograma, que é revisto periodicamente.

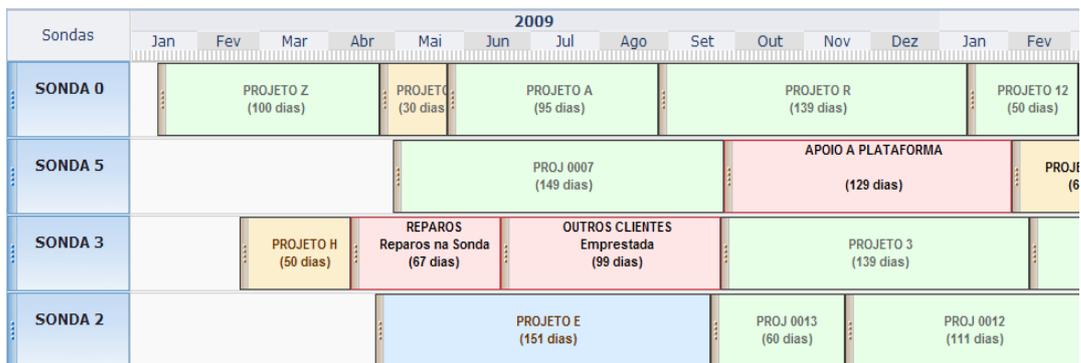


Figura 1: Exemplo de um cronograma de alocação de sondas

Atualmente, a alocação de sondas para projetos exploratórios é feita sem nenhum processo de otimização. Apenas busca atender ao máximo possível os compromissos com a agência reguladora brasileira – Agência Nacional do Petróleo, Gás e Biocombustíveis (ANP). Como se vê, garantir que a sonda correta esteja no lugar e na hora corretas, minimizando seus movimentos e custos, é praticamente intratável usando a abordagem manual (IRGENS e LAVENUE, 2007).

3. ESTADO DA ARTE – ALGORITMOS GENÉTICOS

Neste capítulo é apresentada, de maneira resumida, a fundamentação teórica da principal técnica de inteligência computacional utilizada na solução do problema de alocação de sondas: os Algoritmos Genéticos.

3.1. BREVE HISTÓRICO

Na década de 1950, vários grupos de cientistas da computação iniciaram, de maneira independente, estudos sobre sistemas evolucionários. A ideia que dava embasamento a estas pesquisas era a de que a teoria da evolução das espécies de Darwin (1859) poderia servir de base para algoritmos que, utilizando aos conceitos de evolução e adaptação, pudessem encontrar boas soluções para problemas complexos de engenharia.

O conceito que diferenciava essa técnica das já existentes é o de que é possível partir de uma população de indivíduos, cada um representando uma possível solução do problema, que são melhorados de geração em geração, através da aplicação de operadores inspirados na variação genética e na seleção natural.

Entretanto, os trabalhos realizados não possuíam qualquer tipo de preocupação com as estratégias de evolução, programação evolucionária e algoritmos genéticos atuais, pois sempre tinham foco nos problemas específicos. Somente nas décadas de 1960 e 1970, John Holland, auxiliado por seus alunos, surgiu com a ideia dos algoritmos genéticos. O principal objetivo de Holland foi dedicar-se ao estudo formal do fenômeno da evolução, como ocorre na natureza, e desenvolver maneiras de trazê-lo aos sistemas de computação.

Em 1975, Holland publicou o livro que hoje é considerado a bíblia dos Algoritmos Genéticos: "*Adaptation in Natural and Artificial Systems*". Nesta publicação, Holland (1975) apresentou o conceito dos algoritmos genéticos como uma abstração da evolução biológica e estabeleceu a base teórica para a adaptação de soluções através da variação genética e seleção natural. Baseia-se no princípio da sobrevivência dos mais aptos e na reprodução das espécies, inspirado no mecanismo de evolução das espécies apresentado nos trabalhos de Charles Darwin (1859) e na herança genética proposta por Mendel (1865).

Segundo Pacheco (2008), os algoritmos genéticos são particularmente adequados para problemas complexos de otimização de difícil modelagem matemática como aqueles que apresentam com diversos parâmetros ou

características que precisam ser combinadas em busca da melhor solução; problemas com muitas restrições ou condições que não podem ser representadas matematicamente; e problemas com grandes espaços de busca. De acordo com Michalewicz (1995) (1996), algumas áreas de aplicação de algoritmos genéticos são: Otimização de Planejamento, Problema de Otimização de Rota de Veículos, Otimização Combinatorial, Otimização de Funções Matemáticas, Otimização de Layout de Circuitos, Problema do Caixeiro Viajante, entre outros.

3.2. NOMENCLATURA

A nomenclatura utilizada nos algoritmos genéticos é fartamente encontrada na literatura e guarda estreita relação com a origem biológica da técnica. Segue, de maneira sucinta, a descrição dos principais termos usados:

Cromossoma: Indivíduo que representa uma solução em potencial, representado por um vetor de comprimento finito;

Gene: Localizado em cada posição do cromossoma;

Alelo: Valor associado ao gene. Existe um conjunto de valores possíveis;

Lócus: Posição de um gene específico no indivíduo;

Genótipo: Indivíduo candidato a solução;

Fenótipo: Valor da função para um dado indivíduo.

3.3. FUNCIONAMENTO

A base do funcionamento do algoritmo genético é a manutenção de uma população de indivíduos (também chamados de cromossomas) onde cada um deles representa uma potencial solução para o problema analisado. A cada rodada do algoritmo é gerada uma nova geração da população $P(t)$, através de processos estocásticos. Alguns membros da nova geração sofrem transformação através dos operadores genéticos, que são, basicamente, mutação e cruzamento. Cada indivíduo da nova geração é avaliado de maneira a medir sua adaptação. Esta adaptação é medida através de uma função denominada função de avaliação. A aplicação dos operadores genéticos tende a formar na nova geração indivíduos mais adaptados do que da geração anterior. Após algumas gerações, o algoritmo converge, e então espera-se que o melhor indivíduo (mais adaptado) represente uma solução próxima do ótimo global.

O princípio básico dos operadores genéticos é transformar a população através de sucessivas gerações, estendendo a busca até chegar a um resultado satisfatório. Os operadores genéticos são necessários para que a população se diversifique e mantenha características de adaptação adquiridas pelas gerações anteriores.

Os operadores genéticos mais utilizados no processo são a reprodução, o cruzamento (*crossover*) e a mutação (*mutation*). O primeiro realiza a seleção e a cópia de determinados cromossomas para a população seguinte de acordo com sua aptidão. Conforme a teoria de Darwin, os cromossomas mais aptos têm maior probabilidade de contribuir para a formação de um ou mais indivíduos da próxima geração da população. As estratégias mais comuns de reprodução são (PACHECO e VELLASCO, 2007):

- Troca de toda a população;
- Troca de toda a população com elitismo, onde o cromossoma mais apto é copiado para a próxima geração e o restante é substituído;
- Troca parcial com *steady state*, onde os N melhores indivíduos da população corrente são copiados para a próxima geração, e o restante é substituído.

O cruzamento consiste na composição do cromossoma de solução a partir do cruzamento dos genes existentes nos cromossomas dos pais. Os pais normalmente são escolhidos por sorteio ou em torneios onde os mais adaptados possuem maior chance de serem escolhidos, de forma que sua informação genética tenha mais chances de ser passada às próximas gerações, conforme ocorre na teoria de evolução de Darwin. A tarefa do cruzamento é explorar a bagagem genética existente nos pais, de maneira a ajudar na busca local da solução. O local representa a região na qual pode ser encontrado o material genético existente em todos os indivíduos da população. O cruzamento busca uma solução a partir do conhecimento já existente nos indivíduos da população. Sua chance de ocorrer é dada por um valor percentual, denominado taxa de cruzamento. A Figura 2 ilustra o processo de cruzamento simples em dois cromossomas com representação binária.

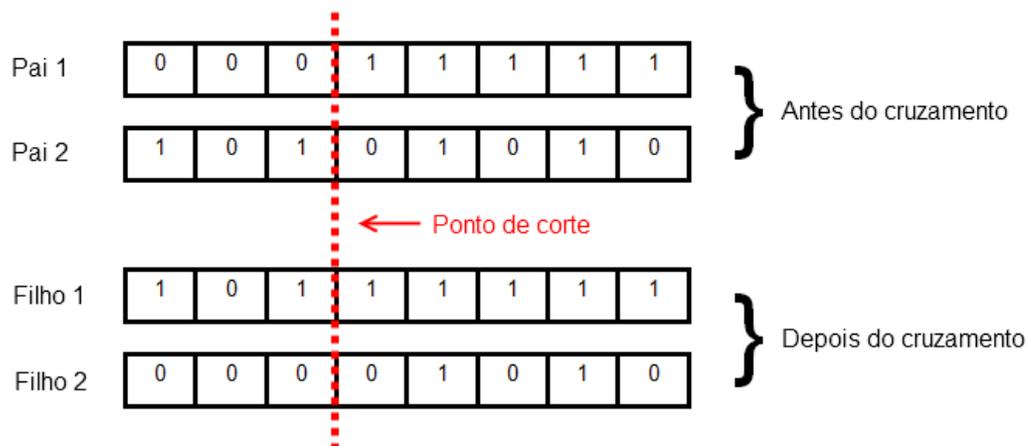


Figura 2: Exemplo de operação de cruzamento

O operador de mutação é tem a função de introduzir e manter a diversidade genética da população, alterando arbitrariamente um ou mais genes de um indivíduo escolhido, fornecendo assim meios para introdução de novos elementos na população. É uma forma de se contornar o problema de mínimos locais pois, com esse mecanismo, altera-se levemente a direção da busca, promovendo a avaliação de áreas do espaço de busca ainda não exploradas. Exemplos de operações de mutação são a troca entre dois genes de um cromossoma ou a seleção aleatória de um novo valor para um determinado gene. A probabilidade de ocorrência de mutação é dada por um percentual chamado taxa de mutação. A operação de mutação está exemplificada na Figura 3.



Figura 3: Exemplo de operação de mutação

A definição de bons operadores genéticos é fundamental para o sucesso dos algoritmos genéticos. Sem o devido cuidados, estes operadores podem gerar indivíduos inviáveis (HUSBANDS e MILL, 1994), o que causa perda de eficiência do algoritmo, pois faz com que estes sejam descartados. Sendo assim,

os operadores genéticos devem ser escolhidos de acordo com o problema abordado e a representação escolhida para o cromossoma.

Esta é a descrição do chamado algoritmo genético puro (AGP) e seu fluxo de funcionamento é apresentado na Figura 4.

Neste processo, os parâmetros de entrada são as taxas de ocorrência dos operadores, o tamanho da população e a condição de parada. Esta última indica quando o algoritmo deve parar de ser executado. Esta regra pode ser dada, por exemplo, por atingir um tempo de processamento máximo, bem como pelo número máximo de gerações, ou algum critério de localização da solução ideal (desde que conhecido), entre outros.

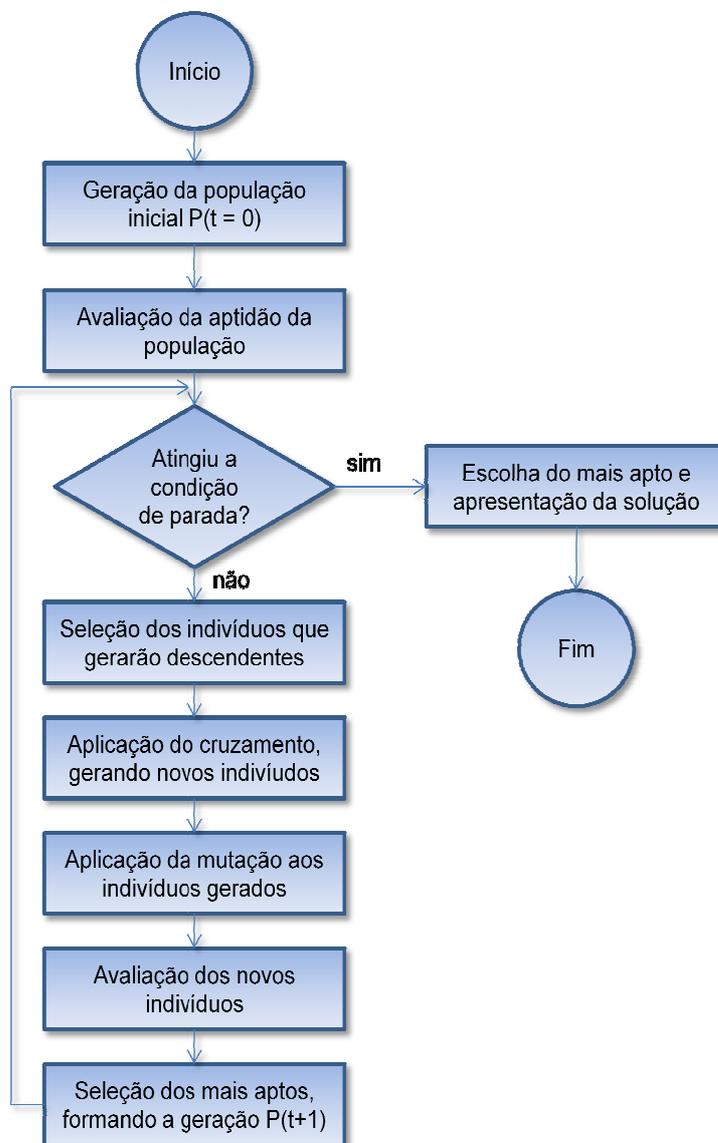


Figura 4: Fluxograma do Algoritmo Genético Puro

O algoritmo começa com a inicialização da população, criando indivíduos de forma aleatória. Em seguida, todos os indivíduos são analisados pela função de avaliação e recebem seu valor de aptidão. Depois, as seguintes etapas são repetidas, até que a condição de parada seja satisfeita:

Seleção dos pais: os mais aptos têm maior chance de serem escolhidos

Cruzamento: realiza o cruzamento das informações dos pais, para geração dos filhos

Mutação: altera os filhos de maneira aleatória

Avaliação: calcula a aptidão dos novos indivíduos gerados

Seleção: seleciona os mais aptos para a próxima geração.

3.4. ALGORITMO GENÉTICO HÍBRIDO

Pela utilização do algoritmo genético puro pode não ser possível representar alguns problemas. Sua representação (em bits, uns e zeros) e seus operadores genéticos não são afeitos a problemas mais complexos. Ao acrescentarmos conhecimento específico do problema na formulação do AG, criamos algoritmos genéticos híbridos (AGH). Esta adaptação pode ocorrer pela adoção de uma forma diferente de representação, na adaptação dos operadores ou na adoção de heurísticas de otimização.

A utilização de algoritmos genéticos híbridos tem como principais vantagens a incorporação do conhecimento no domínio do problema e resultar em um sistema mais familiar para o usuário. Além disso, o AGH pode garantir uma inicialização da população menos aleatória e mais eficiente (PACHECO e VELLASCO, 2007).

4. ARQUITETURA DO SISTEMA PROPOSTO

O problema proposto é de grande complexidade se tratado em todos os seus detalhes. Logo, serão adotadas algumas simplificações, de maneira que a solução apresentada não resolverá o problema real como um todo. Entretanto, esta solução será de grande valia para o entendimento e a modelagem do problema assim como o conhecimento dos mecanismos do algoritmo genético, possivelmente resultando em um futuro trabalho mais detalhado sobre a questão. Sendo assim, as seguintes simplificações serão adotadas:

- As distâncias entre os poços a serem perfurados serão calculadas pela menor distância entre suas coordenadas no globo terrestre, ou seja, não será considerada a costa brasileira como obstáculo;
- Não será considerada a anuência das sondas, pois atualmente esta informação não tem bom índice de preenchimento e não é muito utilizada nos planejamentos;
- Não serão alocadas sondas para a realização de atividades delimitatórias das descobertas, nem seu custo participará na função de avaliação;
- Não será considerado o compromisso com a ANP, devido à sua complexidade de implementação.

Alguns parâmetros devem ser fixados para o problema e, uma vez definidos, deverão ser mantidos para uma série de experimentos. São eles:

- Taxa Mínima de Atratividade (TMA);
- Lista de projetos a serem alocados;
- Lista de sondas disponíveis;
- Cronograma original.

Como cada projeto exploratório envolverá a perfuração de um poço pioneiro, podemos estabelecer uma correspondência biunívoca entre cada projeto e seu pioneiro. Assim, nosso objetivo pode ser encarado como alocar sondas para perfurar poços pioneiros.

O cronograma original passado como parâmetro servirá para, além de preservar seu passado e os projetos em execução na solução gerada, definir a partir de que data podemos alocar projetos, em cada sonda. Além disso, ele proverá as data de início e a duração de outras atividades não relacionadas a

perfuração de poços como, por exemplo, paradas para manutenção, apoio à plataforma, docagem, pescaria, entre outras.

4.1. REPRESENTAÇÃO DO CROMOSSOMA

Dado um conjunto P de poços com m elementos e um conjunto S de sondas com n elementos, o cromossoma será uma lista de poços e representará a ordem em que estes serão alocados no cronograma. Cada gene do cromossoma é o identificador de um poço. Logo, o tamanho do cromossoma será de m genes e o algoritmo deverá realizar uma permutação dos identificadores dos poços. Uma representação gráfica seria da seguinte forma:

P1	P2	P3	P4	P5	...	Pm
----	----	----	----	----	-----	----

Entretanto, essa representação ainda não gera soluções para o problema pois não indica em que sondas os projetos serão alocados. Sendo assim, vamos indicar em uma segunda linha, para cada projeto, em que sonda ele deve ser alocado, através do identificador da sonda. Desta forma, o algoritmo também deverá fazer o sorteio das sondas associadas. Sendo assim, um gene será da seguinte forma:

Px
Sy

Um possível cromossoma seria:

P1	P2	P3	P4	P5	...	Pm
S3	S1	S3	S2	S4	...	Sn

Com essa representação, é possível obter soluções que podem ser decodificadas para gerar cronogramas, conforme proposto, pois se sabe em que sonda cada poço deve ser alocado e em que ordem. Estas são as informações mínimas necessárias para a elaboração de um cronograma.

4.2. RESTRIÇÕES

De maneira a evitar a geração de uma grande quantidade de soluções inválidas devido às restrições técnicas de cada poço, deve-se condicionar a

escolha de sondas por poço ao subconjunto de S que possui características técnicas para atender a cada poço. As características que definem que sondas podem atender um projeto são:

- A sonda deve possuir um alcance de lâmina d'água maior ou igual à do poço
- A sonda deve possuir um alcance de profundidade final maior ou igual à do poço

4.3. DECODIFICAÇÃO DO CROMOSSOMA

Para decodificar o cromossoma, este deve ser percorrido da esquerda para direita, alocando os projetos nas suas respectivas sondas, na ordem. É importante notar que o número de projetos alocados varia por sonda. O próximo exemplo servirá para esclarecer o processo.

4.3.1. Exemplo

Para facilitar o entendimento da representação e decodificação adotadas, é proposto o seguinte exemplo.

Suponha um cenário de planejamento com os conjuntos a seguir:

- O conjunto P de poços contém sete elementos: {P1, P2, P3, P4, P5, P6, P7}
- O conjunto S de sondas contém quatro elementos: {S1, S2, S3, S4}

As características das sondas são tais que elas permitem atender aos seguintes poços:

S1: P3, P5

S2: P1, P3, P5, P6

S3: P1, P3, P4, P5, P6, P7

S4: P1, P2, P3, P4, P5, P6, P7

Inicia-se escolhendo aleatoriamente a ordem dos poços:

P6	P4	P1	P2	P5	P3	P7

Agora, deve-se selecionar aleatoriamente, para cada poço, uma sonda do subconjunto que atende os requisitos técnicos do poço. Para facilitar esta tarefa, será listado o conjunto de sondas que pode atender a cada projeto:

P1: {S2, S3, S4}

P2: {S4}

P3: {S1, S2, S3, S4}

P4: {S3, S4}

P5: {S1, S2, S3, S4}

P6: {S2, S3, S4}

P7: {S3, S4}

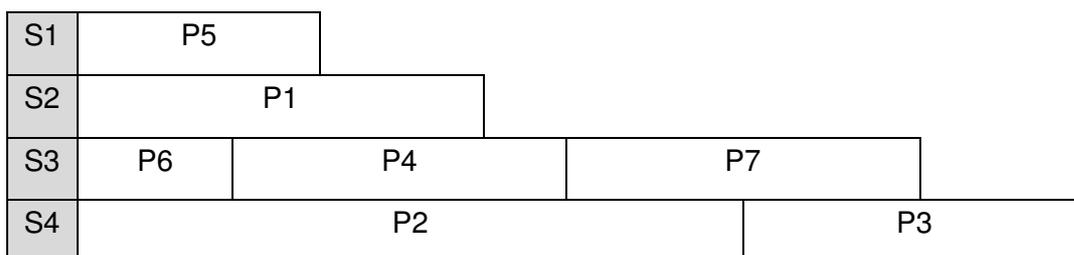
Por exemplo, para P6 deve ser escolhida aleatoriamente uma sonda do conjunto {S2, S3, S4}.

Ao final da escolha de sondas, obtém-se um cromossoma como o seguinte:

P6	P4	P1	P2	P5	P3	P7
S3	S3	S2	S4	S1	S4	S3

A decodificação deste cromossoma será a alocação dos poços, com suas respectivas sondas, respeitando a ordem em que estão no cromossoma, da esquerda para a direita:

→ Tempo



4.3.2. Outras atividades da sonda

Além do deslocamento da sonda, também devem ser alocados espaços para outras atividades, como paradas para manutenção, testes, etc. Estas atividades têm suas datas definidas, para cada sonda, no cronograma original. Sendo assim, é feita uma verificação para saber se há alguma dessas atividades programadas para aquele período. Caso positivo, as mesmas deverão ser alocadas na sonda e só então se procede a alocação dos projetos. Dessa forma, as atividades do cronograma original são alocá-las na solução gerada.

4.3.3. Deslocamento da sonda

No Problema de Alocação de Sondas para Projetos Exploratórios, ao contrário da maioria dos problemas de alocação de recursos críticos, é a sonda que se desloca até o projeto. Sendo assim, deve ser incluída entre os projetos uma alocação representando este deslocamento. Para deslocamentos pequenos (menores que 1 dia), essa alocação não será considerada. Para os demais, será assumido que uma sonda percorre, em média, 150 Km por dia. Esses deslocamentos serão penalizados no cálculo da função de avaliação, de forma a induzir que na solução gerada o cronograma seja operacionalmente viável.

Utilizando o exemplo de 0, deve-se supor que os projeto P4 e P7 estão distantes 450 Km entre si. Dessa forma, o tempo de deslocamento da sonda entre eles é de $450 / 150 = 3$ dias. Logo, uma alocação representando esse deslocamento deve ser alocada entre os projeto citados:

S1	P5			
S2	P1			
S3	P6	P4	(deslocamento de 3 dias)	P7
S4	P2			P3

4.4. AVALIAÇÃO

Antes de definir a função de avaliação, serão explicitadas quais informações são, de antemão, necessárias para que possamos realizar o cálculo desta.

Para cada projeto exploratório, devem-se conhecer previamente suas seguintes características:

- a. Duração do projeto, em dias;
- b. Localização da boca do poço;
- c. Lâmina d'água da localidade a ser perfurada (LDA);
- d. Profundidade final a ser atingida pelo poço pioneiro (PF);
- e. Fator de Chance de Descoberta Econômica (FCE);
- f. Ano de início perfuração do poço pioneiro da avaliação econômica (AnoPion);
- g. Valor Presente Líquido de desenvolvimento para a produção, calculado em relação ao AnoPion (VPLdp);

Em relação às sondas, deve-se conhecer:

- a. Lâmina d'água máxima contratada (LDA)
- b. Profundidade final máxima contratada (PF);
- c. Custo diário de aluguel da sonda (Csonda).

4.4.1. Função de Avaliação

Para avaliar quão próximo se está da eficiência econômica, o deve-se somar o Valor Monetário Esperado (VME) dos projetos e subtrair deste valor os custos com deslocamento das sondas:

$$f = \sum VME_{proj} - \sum C_{desl_sonda}$$

O VME original do projeto é calculado na análise econômica do mesmo, que define um ano para a perfuração do poço pioneiro, e é dado pelo produto do Valor Presente Líquido após o Desenvolvimento para Produção do poço (VPLdp) e pelo seu Fator de Chance (FC). Deve-se calcular seu novo VPLdp, trazendo-o para a sua data de alocação na solução. Para isso, aplica-se uma correção monetária pela Taxa Mínima de Atratividade (TMA). O valor deve ser corrigido pelo número de anos da diferença entre o ano original do seu poço pioneiro e o ano em que ele foi alocado no cronograma. Sendo assim, o valor é obtido desta forma:

$$VPLdp' = VPLdp * (1 + TMA)^{AnoPion - AnoAlocacao}$$

Para o cálculo do VME do projeto, ainda é necessário calcular o custo de perfuração do poço pioneiro, que produto do custo diário da sonda pela duração do projeto, corrigidos pela TMA, porém em relação ao ano corrente, já que o custo da sonda está em valores atuais:

$$CPion = Csonda \times Duracao \text{ Pr ojet}o \times (1 + TMA)^{AnoCorrente - AnoAlocacao}$$

De posse do VPLdp corrigido do projeto e o custo do pioneiro calculado, é possível obter o VME do projeto:

$$VMEproj = VPLdp' * FCE - CPion$$

Para penalizar os deslocamentos da sonda, é preciso conhecer seu custo durante estes períodos. Sendo assim, o custo de deslocamento de cada é assim calculado:

$$Cdesl_sonda = Csonda * DuracaoDeslocamento * (1 + TMA)^{AnoCorrente - AnoAlocacao}$$

4.5. OPERADORES

Abaixo serão descritos os operadores utilizados nos cromossomas para a formação de novas gerações de indivíduos na execução do algoritmo genético. Existem dois tipos de operadores a serem aplicados: *crossover* e mutação.

4.5.1. Crossover

A operação de *crossover* dos cromossomas será baseada na técnica de "*crossover* uniforme baseado em ordem". Com o método utilizado, busca-se criar variedade de ordenação de alocação nos projetos assim como alternativas de associação sonda/poço. Segue o algoritmo para realização desta operação.

Dados dois genitores, F1 e F2, criar descendente C1:

1. Gere um padrão de bits do comprimento do cromossoma;
2. Preencha C1, copiando o genitor F1 nas posições em que o padrão é igual a "1", incluindo a associação de sondas;
3. Faça uma lista dos elementos de F1 associados com os bits "0" do padrão, somente considerando os poços;
4. Permute estes elementos de modo que eles apareçam na mesma ordem em que aparecem em F2;
5. Preencha as lacunas de C1 com os elementos ordenados no passo anterior, sem designar a sonda associada a estes;
6. Escolha aleatoriamente um bit para decidir como será a associação de sondas.
7. Caso o bit escolhido seja "0", as sondas associadas aos poços dos bits "0" do padrão seguirão aquelas de F1. Caso seja "1", a associação das sondas será a mesma de F2 para estes poços.

Para ilustrar o algoritmo, utilizaremos o mesmo exemplo de 0.

Supõe-se que os genitores F1 e F2 foram escolhidos e seus cromossomas são:

F1:

P6	P4	P1	P2	P5	P3	P7
S3	S3	S2	S4	S1	S4	S3

F2:

P2	P4	P7	P6	P3	P1	P5
S4	S4	S3	S2	S1	S4	S1

Então, é gerado aleatoriamente um padrão de bits:

0	1	1	0	1	0	1
---	---	---	---	---	---	---

Preenche-se C1, copiando F1 nas posições onde o padrão é "1":

C1:

	P4	P1		P5		P7
	S3	S2		S1		S3

Agora, deve ser feita uma lista com os elementos de F1 associados aos bits "0" do padrão: {P6, P2, P3}

Em seguida, os elementos são permutados para que fiquem na mesma ordem em que aparecem em F2: {P2, P6, P3}

Então, as lacunas de C1 são preenchidas com os elementos ordenados no passo anterior:

C1:

P2	P4	P1	P6	P5	P3	P7
	S3	S2		S1		S3

Para determinar a associação dos projetos do bit "0" do padrão, escolhe-se um bit aleatoriamente:

1

A associação de sondas dos elementos ligados aos bits "0" do padrão será a mesma de F2:

C1:

P2	P4	P1	P6	P5	P3	P7
S4	S3	S2	S2	S1	S1	S3

A geração de um segundo descendente C2 é feita de maneira análoga. Basta apenas realizar a operação de negação binária (*not*) sobre o padrão de bits e sobre o bit escolhido para decidir a associação de sondas, e aplicar o mesmo algoritmo.

C2:

P2	P4	P5	P6	P3	P1	P7
S4	S3	S1	S2	S4	S4	S3

4.5.2. Mutação

A mutação do cromossoma tem por objetivo criar soluções alternativas que podem não ser geradas pelo *crossover* entre os indivíduos de uma determinada população. Dessa maneira, a mutação pode conseguir chegar à soluções no espaço de busca que não seriam alcançadas somente com operações de *crossover*.

forma, o número de genes a ser sorteado deve ficar entre 3 e o resultado da divisão inteira do número total de genes por 10.

4.6. TÉCNICAS

A aplicação pura da teoria de algoritmos genéticos pode não conduzir aos melhores resultados por não levar em conta o conhecimento já adquirido do problema. Embora esse conhecimento nem sempre seja traduzido em métodos rigorosos, em geral reflete o conhecimento humano e permite obter uma solução satisfatória. O uso desse conhecimento é chamado heurística. A união da heurística com algoritmos genéticos produz o que se denomina algoritmos genéticos híbridos. As técnicas descritas a seguir detalham a hibridização do algoritmo.

4.6.1. Reprodução

No processo de reprodução existe a possibilidade de eu membros que são piores que os genitores tenham sido gerados. Para garantir que o melhor indivíduo de uma nova geração não seja pior que o melhor da geração anterior, pode-se utilizar a técnica de elitismo. Essa técnica seleciona n indivíduos e os coloca diretamente na nova geração, sem passar pelo processo evolutivo.

Outra maneira de garantir bons indivíduos na nova geração é utilizar o *steady state*. Nesta técnica, busca-se eliminar os n piores membros da população para que os novos sejam inseridos. Dessa forma, substituem-se indivíduos com má avaliação por outros mais bem avaliados.

4.6.2. Inicialização da população

Na geração da população inicial do algoritmo, é incluído o próprio cronograma original que estamos usando como base como um indivíduo da população. Essa estratégia combinada com o elitismo ou *steady state* garante que teremos soluções no mínimo equivalentes a que já temos sem o uso da ferramenta.

4.6.3. Evolução adaptativa

A interpolação de parâmetros produz a variação dos parâmetros do algoritmo genético durante a execução. Sendo assim, uma boa estratégia costuma ser uma taxa de *crossover* que diminui com o tempo enquanto a taxa de mutação aumenta. Esta estratégia se baseia na tendência de que, após

muitas evoluções, a população se estabilize mesmo que as melhores soluções estejam ainda longe da solução ótima.

Após muitas evoluções, o *crossover* não consegue produzir soluções melhores do que as já geradas, pois acaba sempre criando indivíduos com muitas características em comum. Em contrapartida, o aumento da taxa de mutação pode fazer com que indivíduos com maior diversidade sejam gerados, fazendo com que o espaço de busca seja mais bem explorado. Em relação aos operadores de mutação, ambos podem ter a mesma chance de serem utilizados a cada rodada do algoritmo.

5. RESULTADOS

Neste capítulo são apresentados os resultados obtidos na realização de testes de otimização de um cronograma real. Conforme explicado no capítulo anterior, este cronograma real (original) é um dos dados de entrada para o problema.

Como os dados do cronograma original são de caráter sigiloso, os valores absolutos de resultados da função objetivo não poderão ser apresentados. Sendo assim, a medida de desempenho utilizada será o percentual de ganho do resultado da função objetivo de cada teste em relação ao do obtido sobre o cronograma original.

O número de indivíduos por geração e o total de gerações do algoritmo genético foram variados nos testes com o intuito de fazer com que seu tempo de execução total ficasse em torno de dois minutos. O processamento completo de uma geração de duzentos indivíduos, passando pelas operações genéticas, decodificação e avaliação, levou em média dois segundos em um computador *desktop*. Este tempo computacional pode ser considerado pequeno em comparação aos obtidos por em trabalhos semelhantes que utilizam, por exemplo, técnicas de programação matemática. Sendo assim, foi possível utilizar um grande número de indivíduos por geração. De fato, os melhores resultados foram alcançados com um grande número de indivíduos por geração e um número não muito alto de gerações. O aumento de número de gerações em detrimento do número de indivíduos não gerou resultados tão bons. Os melhores resultados são apresentados na Tabela 1, em conjunto com os parâmetros utilizados em cada caso.

rodada	% de ganho	tamanho da população	nº de gerações	reprodução
1	8,41%	50	200	elitismo
2	8,13%	100	100	elitismo
3	8,51%	200	60	elitismo
4	8,83%	400	40	elitismo
5	6,72%	50	200	steady state
6	6,41%	100	100	steady state
7	8,07%	200	60	steady state
8	8,81%	400	40	steady state

Tabela 1 - Resultados

A evolução adaptativa colaborou bastante para a obtenção dos melhores resultados. Nos testes realizados com taxas de mutação e *crossover* fixas, os resultados foram inferiores àqueles em que estas taxas variaram de acordo com

a evolução do algoritmo. A taxa de *crossover* alta no início permite a troca de informações entre indivíduos ainda com genomas bastante diferentes entre si. Entretanto, nas últimas gerações os indivíduos já possuem genomas razoavelmente parecidos, de forma que o *crossover* acaba criando indivíduos com muitas características comuns. Em contrapartida, uma alta moderada da taxa de mutação nesta fase é interessante, pois daí pode surgir um indivíduo que explore outros espaços de busca onde pode haver uma solução melhor. Sendo assim, as taxas de mutação foram de 5% no início e de 50% no final e as taxas de *crossover* foram de 90% no início e de 50% no final.

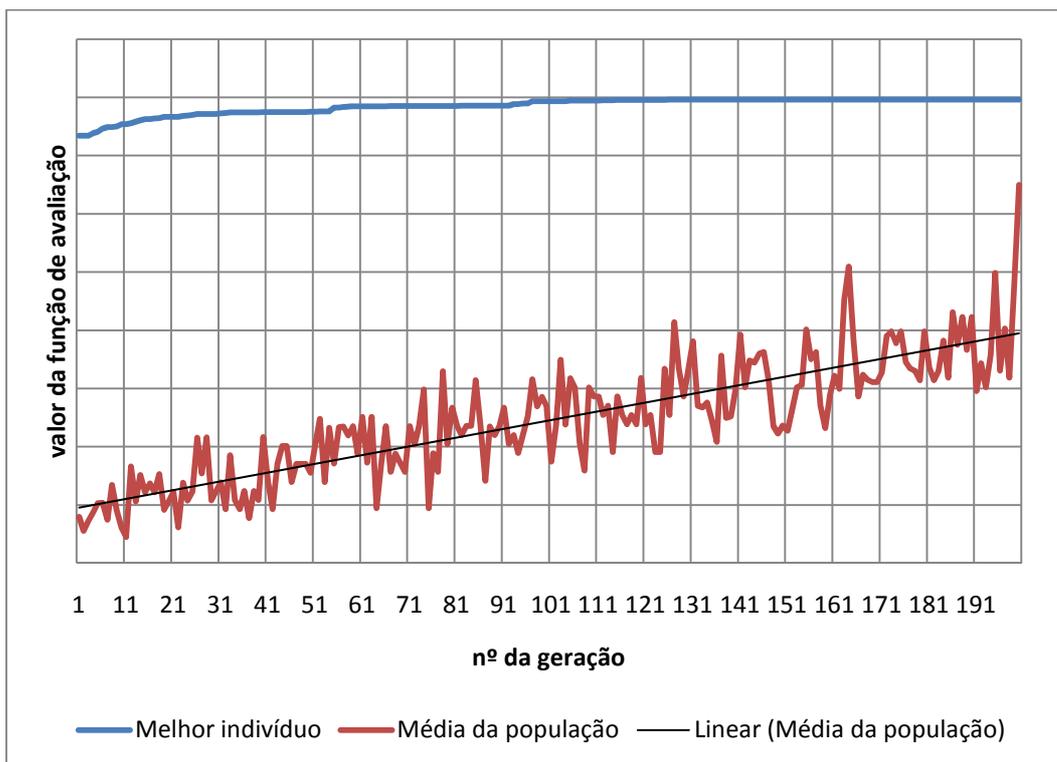


Gráfico 1 - Rodada 1 com retorno da avaliação em valores absolutos

O Gráfico 1 apresenta a evolução do melhor indivíduo e da média da população em valores absolutos para a primeira rodada, onde foi usada a técnica de elitismo. Neste gráfico podem-se observar resultados típicos da aplicação desta técnica. Como esperado, a média da população tem a tendência de subir. Conforme o algoritmo se aproxima do final da execução, devido ao aumento da taxa de mutação, existem oscilações ligeiramente mais fortes na média da população do que no início da execução. Nota-se também que o melhor indivíduo de uma geração nunca é pior de que o de uma geração anterior, já que no elitismo alguns dos melhores indivíduos de uma geração são copiados para a próxima. O Gráfico 2 exibe a evolução do melhor indivíduo em

percentuais de melhora em relação ao cronograma original. O comportamento das demais rodadas com elitismo é análogo ao observado nesta rodada.

Utilizando *steady state* na reprodução, os resultados obtidos foram semelhantes aos de elitismo no geral, com um tempo computacional ligeiramente mais alto para os mesmos parâmetros. Entretanto, como se pode notar no Gráfico 4, elaborado com dados da quinta rodada, o algoritmo converge mais rapidamente, estabilizando em torno da septuagésima geração neste caso. Quando usado o elitismo, o valor se estabiliza em torno da 110ª rodada. Dessa forma, seria possível obter o mesmo tempo computacional do elitismo se fosse reduzido o número de gerações, levando o tempo de processamento das diferentes técnicas a valores equivalentes, como é possível observar na comparação entre as rodadas 4 e 8, pelo Gráfico 5.

Já a média da população utilizando *steady state* apresenta um comportamento diferenciado em relação ao elitismo, como pode ser observado no Gráfico 3. Neste caso, a média tende a se aproximar rapidamente do melhor indivíduo. Entretanto, quando o algoritmo se aproxima das últimas gerações a média começa a oscilar, caindo um pouco. A explicação para isto é que a mutação, que é mais provável nas últimas gerações, produz muitos indivíduos com avaliação ruim enquanto busca algum que se diferencie dos demais e ao mesmo tempo seja melhor do que estes. Os gráficos das demais rodadas com *steady state* são análogos aos desta rodada.

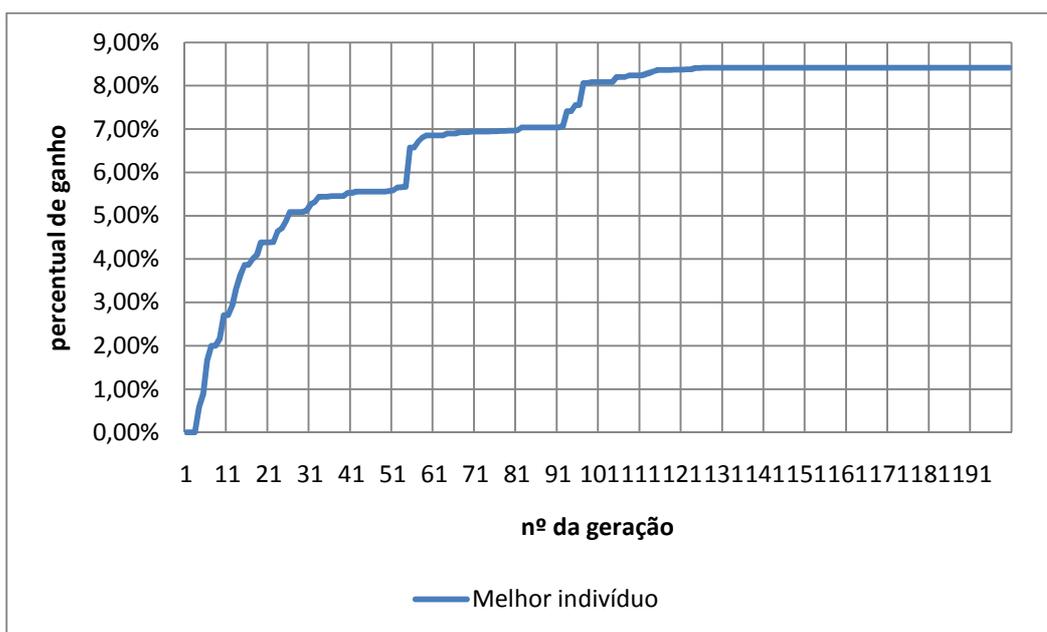


Gráfico 2 - Percentual de ganho na Rodada 1

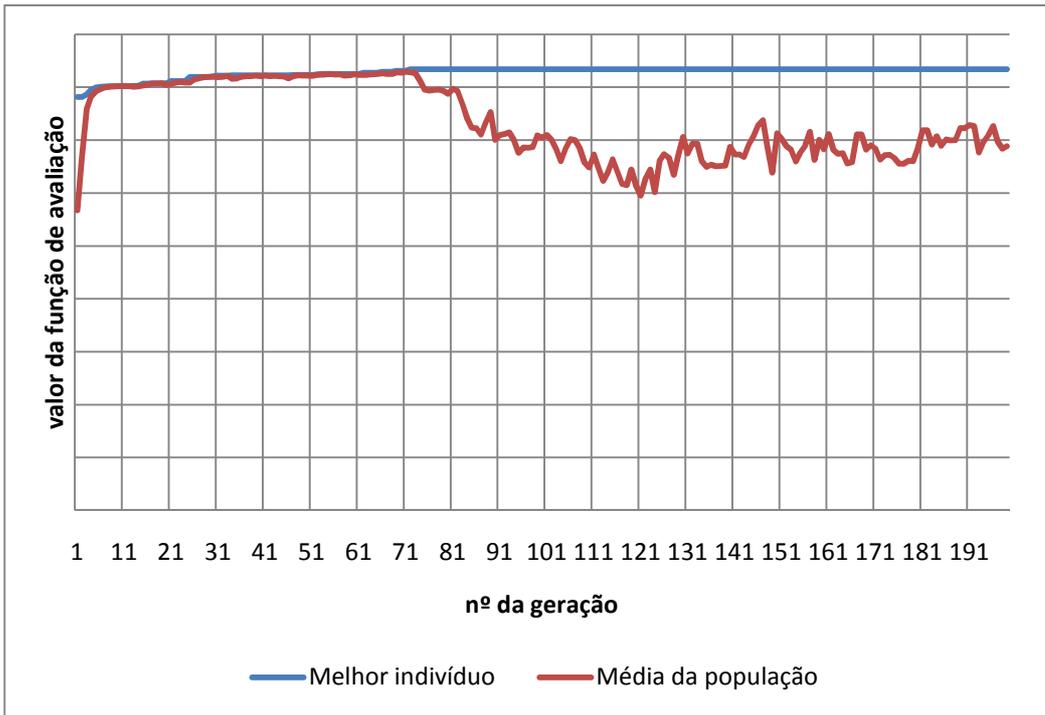


Gráfico 3 - Rodada 5 com retorno da avaliação em valores absolutos

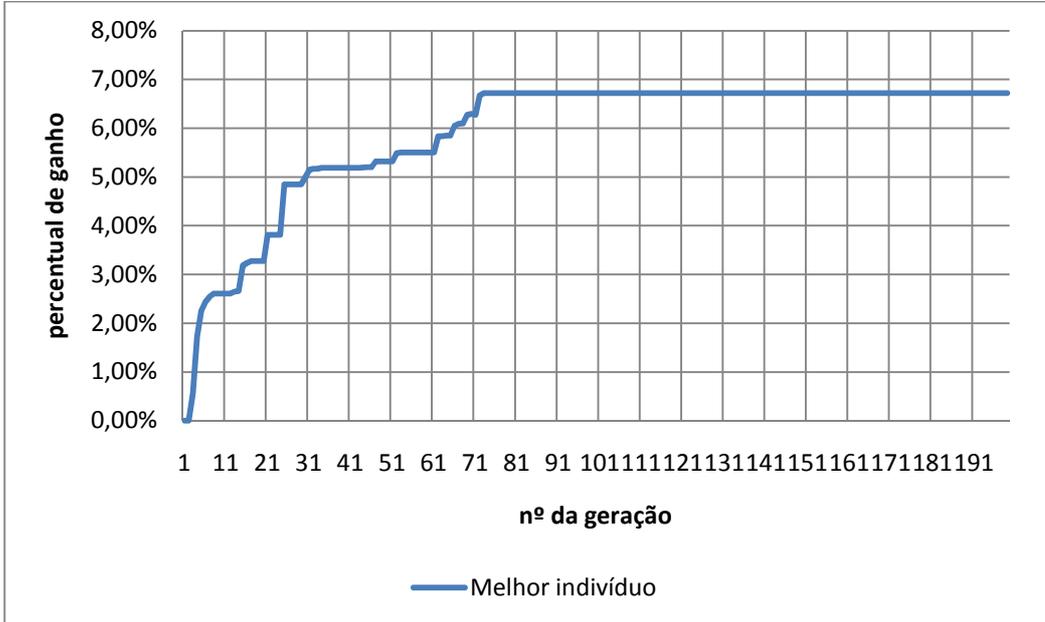


Gráfico 4 - Percentual de ganho na Rodada 5

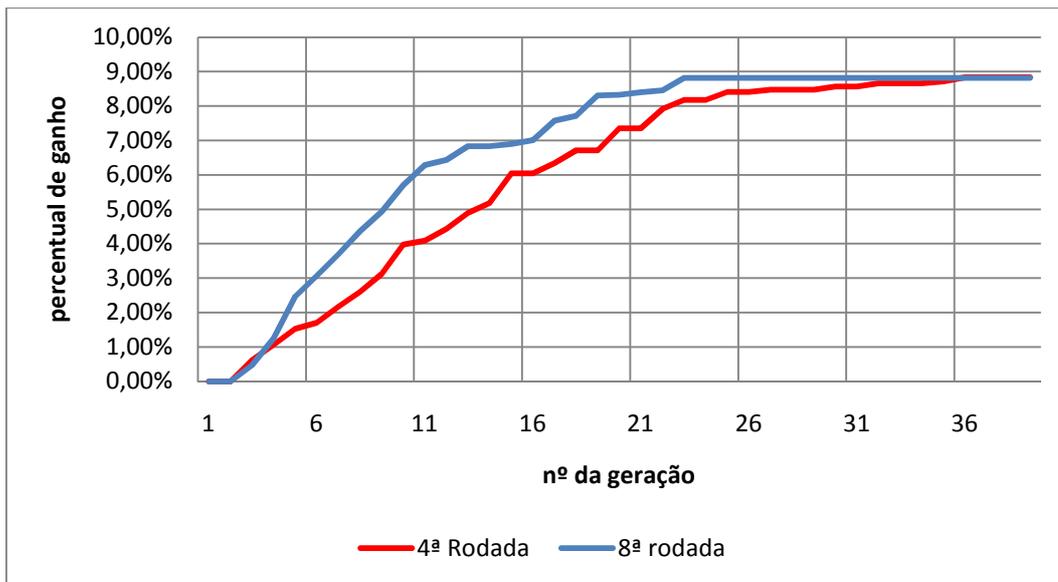


Gráfico 5 - Elitismo x Steady State

Destas rodadas apresentadas, mesmo considerando aquelas em que a escolha dos parâmetros não foi muito favorável, a média de ganho da função objetivo em relação ao cronograma original foi de aproximadamente oito pontos percentuais. Considerando que a função objetivo tem como resultado valores na grandeza de bilhões de dólares, o valor obtido representa um ganho expressivo em retorno financeiro, além do benefício da solução respeitar as restrições impostas pelo problema, o que, por si só, já constitui um desafio considerável.

6. CONCLUSÕES E TRABALHOS FUTUROS

O objetivo deste trabalho foi realizar a implementação de um sistema de otimização para o Problema de Alocação de Sondas para Projetos Exploratórios. Como este é um problema complexo, com diversas considerações a serem feitas e vários objetivos a se conciliar, foi necessário adotar algumas simplificações na solução final. Entretanto, criou-se uma base consistente para que, futuramente, seja feita uma implementação que considere o problema em todos os seus aspectos.

A técnica de algoritmos genéticos provou ser eficaz para resolver o problema proposto com um tempo computacional adequado. Trabalhos que utilizaram outras técnicas como, por exemplo, programação inteira, enfrentaram problemas como dificuldade de modelagem ou tempo computacional alto ao trabalhar com muitos dados. Mesmo trabalhando com dezenas de sondas e centenas de projetos, a implementação deste trabalho trouxe soluções com tempo de resposta bastante apropriado. Uma sintonia fina dos parâmetros do algoritmo, assim com das técnicas utilizadas, pode fazer com que os resultados sejam ainda mais interessantes e rapidamente gerados.

Além do reduzido tempo de processamento, a modelagem por algoritmos genéticos mostrou-se bastante flexível, permitindo a introdução das complexidades do problema ao poucos. Neste trabalho, por exemplo, a inclusão do deslocamento da sonda e de suas paradas programadas não foi feita na fase inicial de implementação, mas sim em fases posteriores, o que permitiu enfrentar o problema por partes.

Os resultados obtidos, apesar das simplificações adotadas, foram bastante satisfatórios, considerando o objetivo do problema e o tempo computacional requerido para encontrar soluções. Observou-se ganho expressivo em retorno financeiro nas soluções geradas quando comparadas aos cronogramas originais, feitos sem auxílio de um sistema. Além disso, as soluções geradas possuem a vantagem de atender a todas as restrições do problema, o que nem sempre é fácil sem o uso de uma ferramenta de apoio,

Apesar de não constituir um fator determinante para a resolução do problema, o cálculo do deslocamento da sonda poderia ser melhorado em trabalhos futuros. De maneira a torná-lo mais realístico, seria necessário utilizar um algoritmo que levasse em conta a costa brasileira para o traçado das rotas.

Também seria interessante ter as informações sobre a velocidade de deslocamento de cada sonda, o que não temos acesso hoje.

Em trabalhos futuros, é possível que com pouco trabalho seja factível generalizar a modelagem para atender também a cronogramas de sondas terrestres. Além disso, seria interessante poder incluir no processo outros projetos além daqueles que estão no cronograma original. Também é importante levar em consideração a classificação das sondas (própria, emprestada, necessidade de sonda) na geração das soluções, privilegiando as que possuem maior disponibilidade.

Uma vez que a ferramenta passe a considerar todos os detalhes do problema, a vantagem de respeitar todas as restrições será ainda mais interessante e, com os resultados obtidos, acreditamos que ainda haverá aumento do retorno financeiro na solução em relação ao cronograma original. Entretanto, é importante observar que, no contexto atual, o compromisso com a ANP é um fator altamente relevante na produção de um cronograma e este não foi considerado no escopo do presente trabalho, ficando como legado para estudos futuros.

REFERÊNCIAS BIBLIOGRÁFICAS

- BORCHARDT, M. **Algoritmos evolucionários na solução do problema da programação de sondas de produção**. Universidade Federal do Rio Grande do Norte. Rio Grande do Norte. 2002.
- COSTA, L. R. D. **Soluções para o Problema de Otimização de Itinerário de Sondas**. Universidade Federal do Rio de Janeiro/COPPE. Rio de Janeiro. 2005.
- DARWIN, C. **The Origin of Species**. London: Albermale Street, 1859.
- FEO, T. A.; RESENDE, M. G. C. A probabilistic heuristic for a computationally difficult set covering problem, v. 8, p. 67-71, 1989.
- HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. Ann Arbor, MI: The University of Michigan Press, 1975.
- HUSBANDS, P.; MILL, F. Scheduling with Genetic Algorithms. **AISB Quarterly**, n. 89, 1994.
- IRGENS, M.; LAVENUE, W. L. **Use of Advanced Optimization Techniques to Manage a Complex Drilling Schedule**. SPE Annual Technical Conference and Exhibition. [S.l.]: Anaheim, California, E.U.A. 2007.
- KOCHETOV, Y.; STOLYAR, A. A. **Evolutionary Local Search with Variable Neighborhood for the Resource Constrained Project Scheduling Problem**. Workshop on Computer Science and Information Technologies. CSIT'2003, Ufa, Russia. 2003.
- KOLISH, R.; HARTMANN, S. Experimental Investigation of Heuristics for Resource Constrained Project Scheduling: An Update. [S.l.]: EJOR – European Journal, v. 174, 2006. p. 23-27.
- LEMOS, L. A. M. E. O Programa Exploratório Mínimo e a Sexta Rodada. **Escritório Online**, 2004. Disponível em:
<http://www.escriptorioonline.com/webnews/noticia.php?id_noticia=5162&
>. Acesso em: 18 março 2010.
- MENDEL, G. **Ensaio com Plantas Híbridas**. Sociedade de História Natural de Brno. [S.l.]. 1865.
- MICHALEWICZ, Z. **A survey of constraint handling techniques in evolutionary computing methods**. Proceedings of the 4th Annual

Conference on Evolutionary Programming. Cambridge, MA: MIT Press.
1995. p. 135-155.

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. 3ª edição. ed. New York: Springer, 1996.

NATAL, A. C. **Aplicação de programação matemática na racionalização do uso de sondas de perfuração e completação de poços de petróleo off-shore**. Universidade Federal do Rio de Janeiro. Rio de Janeiro. 2003.

PACHECO, M. A. C. **Algoritmos Genéticos: Princípios e Aplicações**. Curso de Introdução aos Algoritmos Genéticos, Notas de Aula, ICA - Laboratório de Computação Aplicada. Rio de Janeiro: PUC-Rio. 2008.

PACHECO, M. A. C.; VELLASCO, M. M. B. R. **Sistemas Inteligentes de Apoio à Decisão: Análise Econômica de Projetos de Desenvolvimento de Campo**. Rio de Janeiro: Editora Interciência, 2007.

PETRÓLEO BRASILEIRO S.A. Petrobras Platforms. **Petrobras**, 2009.

Disponível em:

<http://www2.petrobras.com.br/Petrobras/ingles/plataforma/pla_campos_petroleo.htm>. Acesso em: 18 março 2009.

PMBOK. **Project Management Body of Knowledge**. Project Management Institute. [S.l.]. 2000.

RASHEED, W. Rig shortage prompts change in Petrobras strategy. **Drilling Contractor**, p. 24-26, Maio/Junho 2006.

ROSE, P. **Risk Analysis and Managemnet of Petroleum Exploration Ventures**. [S.l.]: American Association of Petroleum Geologists, 2001.

VASCONCELLOS, R. V. J. D. C. **Um Algoritmo Genético para o Problema de Scheduling de Projetos com Restrição de Recursos – Uma Solução com Gerenciamento de Risco**. Universidade Federal do Rio de Janeiro/COPPE. Rio de Janeiro. 2007.