

Using Genetic Algorithms in the Stock Control and Delivery Scheduling

Kelly Cristina Nery de Barros (Centro Universitário da Cidade do Rio de Janeiro, RJ, Brasil) kelly.nery@gmail.com

Albert Silva Lacerda (Centro Universitário da Cidade do Rio de Janeiro, RJ, Brasil) albert.lacerda@gmail.com

Ronaldo Ribeiro Goldschmidt (Centro Universitário da Cidade do Rio de Janeiro, RJ, Brasil) rribeiro@univercidade.edu.br

Jorge de Abreu Soares (Centro Universitário da Cidade do Rio de Janeiro, RJ, Brasil) jorge@univercidade.edu.br

In today's global economy, businesses of all areas are continuously under pressure to increase productivity. Efficient distribution of consumer goods and raw materials is a fundamental part of the production process. The oil industry is the biggest and most important in the energy production segment, since hydroelectric, coal and gas industries do not have a high aggregate value source as oil. It is necessary to optimize oil usage because petroleum is a material with high aggregate value and, since it is a non renewable natural resource, its supply is limited. In order to obtain better results in the refining process, a catalyst is used to maximize production. Although the catalyst is an essential part of the refining process the refineries do not keep a high supply in stock because it is the most expensive product used in refining oil. This means that the industries that produce catalysts should control closely and precisely their clients' stock, in order to be able to deliver more product as soon as it is needed. In this project it is presented the specific case of the Fábrica Carioca de Catalisadores (FCC), which produces catalysts and has an operational routine centered in delivery management. Industry automation has produced expressive economic results, increasing credibility and performance. This project's goal is to demonstrate the use of genetic algorithms in the development of solutions to control and program remote stock delivery.

Genetic Algorithms, Stock Control, Expert Systems, Computer-Aided Delivery Logistics, Artificial Intelligence

Algoritmos Genéticos no Controle de Estoque e Logística de Entrega

Kelly Cristina Nery de Barros, Albert Silva Lacerda, Ronaldo Ribeiro Goldschmidt,
Jorge de Abreu Soares

Núcleo de Projetos e Pesquisas em Aplicações Computacionais – NUPAC
Centro Universitário da Cidade do Rio de Janeiro – UniverCidade
Rio de Janeiro – RJ – Brasil

kelly.nery@gmail.com, albert.lacerda@gmail.com, rribeiro@UniverCidade.edu.br,
jorge@UniverCidade.edu.br

Abstract. *In today's global economy, businesses of all areas are continuously under pressure to increase productivity. Efficient distribution of consumer goods and raw materials is a fundamental part of the production process. The oil industry is the biggest and most important in the energy production segment, since hydroelectric, coal and gas industries do not have a high aggregate value source as oil. It is necessary to optimize oil usage because petroleum is a material with high aggregate value and, since it is a non renewable natural resource, its supply is limited. In order to obtain better results in the refining process, a catalyst is used to maximize production. Although the catalyst is an essential part of the refining process the refineries do not keep a high supply in stock because it is the most expensive product used in refining oil. This means that the industries that produce catalysts should control closely and precisely their clients' stock, in order to be able to deliver more product as soon as it is needed. In this project it is presented the specific case of the Fábrica Carioca de Catalisadores (FCC), which produces catalysts and has an operational routine centered in delivery management. Industry automation has produced expressive economic results, increasing credibility and performance. This project's goal is to demonstrate the use of genetic algorithms in the development of solutions to control and program remote stock delivery.*

Resumo. *Diante da economia global dos dias de hoje, empresas de todas as áreas são continuamente pressionadas a aumentar sua produtividade e competitividade. A distribuição eficiente de bens de consumo e matérias-primas é parte fundamental do processo produtivo. A indústria petrolífera é a maior e mais importante dentro do segmento de produção de energia, visto que as hidroelétricas, indústrias de carvão, indústrias de gás e todas as demais não possuem uma matéria-prima com um valor agregado tão alto, nem mesmo um retorno por investimento aplicado tão expressivo. O melhor aproveitamento do petróleo é fundamental, por ser material de alto valor agregado. Para se obter o melhor resultado na transformação do petróleo em seus diversos derivados, utiliza-se um catalisador que maximiza o rendimento na produção. O catalisador é insumo essencial, porém as refinarias de petróleo não se interessam em manter um alto estoque por se tratar do insumo mais caro de todos os utilizados no refino de petróleo. Com isso, as indústrias produtoras deste insumo devem*

controlar de forma precisa o consumo e o estoque de seus clientes, para só fazer a entrega do material ao cliente quando for realmente necessário. Neste trabalho, analisaremos o uso de algoritmos genéticos na solução do problema de programação de entregas e controle de estoques remotos na Fábrica Carioca de Catalisadores (FCC), produtora deste produto, que dedica uma especial atenção em sua rotina operacional ao gerenciamento de entrega.

1 Introdução

Reduzir os estoques representa uma das formas de se aumentar a eficiência de um negócio, pois reduz o capital imobilizado. Esta estratégia ficou conhecida como “*just in time*” (Hutchins, 1993). Por isso, o presente trabalho concentra-se em uma tarefa relacionada ao paradigma de gestão de estoques, a programação de entregas de bens aos clientes, de forma a manter os níveis de estoque dentro de faixas aceitáveis.

A natureza complexa deste problema, além do fato de ele não apresentar uma solução única, torna-o um excelente candidato para aplicação de algoritmos genéticos (AG), onde diversas alternativas de solução serão produzidas e a solução mais adequada deverá ser selecionada. Algoritmos Genéticos fazem parte do paradigma evolucionário da Inteligência Computacional e constituem uma interessante alternativa para solução de problemas de otimização tais como o controle de estoque e a logística de entrega.

O caso que analisamos neste trabalho baseia-se em um caso real apresentado por uma fábrica de insumos para o refino de petróleo, a *Fábrica Carioca de Catalisadores – FCC*. O catalisador é um produto em forma de pó branco extremamente fino, não tóxico e inerte, armazenado em silos semelhantes aos utilizados no armazenamento de grãos e líquidos. Estes silos são monitorados através de um radar, que informa continuamente o nível do catalisador dentro do silo para a FCC. A quantidade de catalisador no silo é definida por quatro níveis fundamentais (figura 1): 1) **Capacidade total**: dada pelas dimensões físicas do silo; 2) **Capacidade máxima**: definida pelo cliente; 3) **Ponto de reposição**: nível intermediário onde o silo pode (e deve) receber uma ou mais entregas e nível mínimo; e 4) **Ponto crítico do silo**: onde a produção do cliente está em risco de ser interrompida.




Figura 1 - Detalhe dos silos

O nível ideal de produto no silo encontra-se entre o nível máximo e o ponto de reposição, sendo tolerável que, em determinados momentos, o silo alcance um nível acima de sua capacidade máxima (porém, abaixo de sua capacidade total), ou abaixo do ponto de reposição (porém, acima no nível mínimo). Esta flexibilidade é explorada pela programação de entrega, para conseguir uma utilização ótima da frota de caminhões próprios.

O catalisador é transportado em caminhões especiais e há uma frota própria limitada destes veículos, sendo possível o aluguel de caminhões adicionais, porém não desejável devido ao aumento de custo envolvido. A FCC deve suprir diversas refinarias diferentes e a programação de entrega é feita mensalmente.

Atualmente, a programação de entrega é realizada manualmente. Porém, no decorrer do mês, ocorrem imprevistos e alterações no consumo das refinarias, onde são necessárias três ou quatro revisões ao longo deste período. O problema apresentado não possui apenas uma solução única; a melhor é aquela que mantém o nível de todos os silos o mais baixo possível (mas dentro da região ideal), utilizando o menor número de caminhões. Para solucionar este problema de natureza exploratória e de otimização, é apresentado um sistema computacional baseado em algoritmos genéticos, denominado *LogAge*.

O gráfico da figura 2 mostra a projeção do nível para um silo real no mês de Setembro de 2006, com base na quantidade de catalisador disponível no início deste mês e o calendário de entregas elaborado manualmente pela FCC. Este silo tem os seguintes parâmetros: mínimo = 30 toneladas; reposição = 60 toneladas; máximo = 90 toneladas e capacidade total = 184 toneladas. Observa-se que no dia 29 a previsão indica que o nível ficará um pouco abaixo do mínimo. O gráfico com a medição real do mês de setembro (figura 2) mostra que o nível não chega ao mínimo.



Figura 2 - Previsão do nível no silo

O restante deste artigo está organizado da seguinte forma: a Seção 2 apresenta um resumo dos principais conceitos sobre algoritmos genéticos. Alguns exemplos de outros trabalhos realizados com a mesma técnica são apresentados na Seção 3. A Seção 4 mostra o modelo proposto para este artigo. O protótipo e os resultados dos experimentos são apresentados na Seção 5. Por fim, a Seção 6 mostra as conclusões finais do artigo e aponta possibilidades de trabalhos futuros.

2 Algoritmos Genéticos para o *LogAge*

Nesta seção, serão apresentados os conceitos de Algoritmos Genéticos (AG), juntamente com o modelo de AG proposto para o *LogAge*, os testes realizados e os resultados obtidos.

2.1 Conceitos de Algoritmos Genéticos

Algoritmos Genéticos (Goldberg, 1989) são modelos computacionais de busca e otimização de soluções em problemas complexos, inspirados em princípios da teoria da evolução natural de Charles Darwin (Darwin, 1859) e da reprodução genética.

Segundo o princípio básico da evolução natural de Darwin, indivíduos mais aptos possuem maiores chances de sobrevivência e, conseqüentemente, mais oportunidades de gerarem descendentes e perpetuarem seus códigos genéticos pelas gerações seguintes. A identificação de cada indivíduo é expressa pelo seu código genético, que fica representado nos cromossomos deste indivíduo.

Resumidamente, Algoritmos Genéticos são técnicas inspiradas na biologia, que procuram obter boas soluções para problemas complexos por meio da evolução de populações de soluções codificadas em cromossomos artificiais. Todo problema de difícil modelagem matemática ou com um número muito grande – possivelmente infinito – de soluções, é considerado um problema complexo. Eles empregam um processo adaptativo e paralelo de busca de soluções em problemas complexos, uma vez que consideram várias alternativas de solução em um mesmo momento. O processo é adaptativo, pois as soluções que surgem a cada instante influenciam na busca por futuras soluções. O paralelismo do processo é decorrência natural do fato de que diversas soluções são consideradas a cada momento pelo algoritmo.

Nos Algoritmos Genéticos, um cromossomo é uma estrutura de dados que representa uma das possíveis soluções do espaço de busca de um problema. Cromossomos são então submetidos a um processo evolucionário que avalia, seleciona e combina soluções ao longo de diversos ciclos, procurando obter indivíduos mais aptos (melhores soluções).

A tabela 1 apresenta a analogia entre Algoritmos Genéticos e a Evolução Natural.

Tabela 1 – Analogia entre AG e a Evolução Natural

Evolução Natural	Algoritmos Genéticos
Meio Ambiente	Problema
Indivíduo	Solução
Cromossoma	Representação (palavra binária, vetor, etc)
Gene	Característica do Problema
Alelo	Valor da Característica
Reprodução Sexual	Operador de Cruzamento
Mutação	Operador de Mutação
População	Conjunto de Soluções
Gerações	Ciclos

O AG simula mecanismos da natureza criando uma representação computacional do cromossomo e codificando neste uma solução possível para o problema apresentado. Na sua forma mais simples, o cromossomo é composto por uma seqüência de bits (zeros e uns), que são agrupados para representar uma solução para o problema em questão. O elemento chave de todo AG é a função de aptidão que, dado um cromossomo, avalia-o para determinar (quantificar) sua aptidão para solucionar o problema apresentado. O algoritmo genético cria populações de indivíduos que evoluem ao longo de ciclos de processamento, também denominados gerações.

Esta classe de algoritmos são especialmente úteis na solução de funções não lineares, onde a busca pelo maior ou menor valor pode encontrar diversas regiões promissoras. A função abaixo (Haupt e Haupt, 2004:6) é um destes exemplos:

$$F(x,y) = x.seno(4.x) + 1,1.y.seno(2.y)$$

onde $0 \leq x \leq 10$ e $0 \leq y \leq 10$

A figura 3 mostra a visão em três dimensões do gráfico da função com x e y apresentados em intervalos de comprimento 0,1.




Figura 3 – Gráfico da função

O menor valor é -18,43 (em $x = 9$ e $y = 8,7$). Com apenas duas variáveis e uma pequena faixa de valores é possível localizar os valores com uma busca deste tipo, mas em funções com mais variáveis este método não é prático.

Uma possível codificação binária para este exemplo pode ser vista na figura 4:




Figura 4 – Cromossomo para função do exemplo

A quantidade de bits atribuída a cada variável (x e y) será determinada pela precisão da amostragem desejada. A função de avaliação deverá interpretar o cromossomo e converter o número binário resultante em decimal para poder operar a fórmula $f(x,y)$ e obter o valor de aptidão do indivíduo.

Para representar a solução de um dado problema com AG, é utilizado o cromossomo, composto por *genes*, onde cada gene corresponde a uma informação e pode ser binário, real ou inteiro. Conceitua-se como *alelo* o valor de um gene. A representação binária é a mais empregada, por sua simplicidade e facilidade de manipulação. Como exemplo de cromossomo binário, considera-se a representação de números de 0 a 63: isso seria possível utilizando 6 bits. Então: C1: 001001 representando o número 9, C2: 000100 representando o número 4 e de igual maneira para os demais números.

O AG gera uma população inicial formada por um conjunto aleatório de indivíduos que representam possíveis soluções para o problema. Durante o funcionamento do AG, a evolução da população é realizada pela atribuição de uma nota, ou índice para cada indivíduo da mesma. Esta nota reflete a qualidade do indivíduo como solução do problema. Uma porcentagem das melhores soluções é mantida, enquanto as outras soluções são descartadas. Após esta seleção, os indivíduos podem sofrer modificações em suas características fundamentais por meio de mutações e recombinação genética (*crossover*), conforme exemplos ilustrados nas figuras 5 e 6, gerando descendentes para a próxima

geração. Esse processo, chamado de reprodução, é repetido (por várias gerações) até que uma solução satisfatória seja encontrada.




Figura 5 – Cruzamento de um ponto




Figura 6 - Mutação

3 Trabalhos Relacionados

Nesta seção, optamos pela apresentação de alguns dos trabalhos relacionados com o tema proposto, mostrando a relação existente entre algoritmos genéticos e questões de armazenamento de produtos, programação de eventos e roteamento de veículos.

Em (Castro, 2001), é apresentado um Sistema de Produção e Armazenamento do Gás Liquefeito de Petróleo da Refinaria Henrique Lage, utilizando Algoritmos Genéticos, e observando as seguintes necessidades: (a) Aumentar a produção do produto de maior valor agregado sem prejudicar a produção do produto principal, considerando o espaço de armazenamento, escoamento e necessidade do mercado consumidor; (b) Considerar os acontecimentos externos e internos à refinaria que interferem no processo; (c) Gerar uma programação de produção mais abrangente e gerar também uma programação de produção alternativa a ser utilizada em situações de contingência. Neste trabalho, a função de avaliação analisa a receita obtida com a venda e estocagem de cada produto, penalizando a violação de estoques mínimos de certos itens.

Este trabalho está voltado basicamente aos aspectos de produção e armazenamento de gás. Embora se assemelhe à solução proposta pelo presente trabalho no que se refere à questão de armazenamento, não enfoca o problema da distribuição e entrega de produtos. A política de penalidade atribuída a violações de estoques mínimos é um ponto comum entre ambos os trabalhos.

Já (Túpac, 2002) propôs um sistema de apoio à busca da melhor opção no desenvolvimento de um campo de petróleo. Este sistema utiliza algoritmos genéticos integrados a métodos pré-existentes de sistemas convencionais de busca usados na engenharia de reservatórios. Tem como principal tarefa desenvolver uma estratégia para alcançar a produção da maior quantidade de hidrocarboneto possível dentro dos limites físicos e econômicos existentes. A otimização do desenvolvimento consiste em encontrar a quantidade, a localização e o tipo de poço que maximize o VPL (Valor Presente Líquido). O modelo apresentado neste trabalho é composto de três blocos: o algoritmo genético, que gera o conjunto de variáveis e parâmetros; o simulador de reservatórios IMEX (GMG, 2000), que recebe as variáveis e parâmetros gerados pelo AG e fornece a curva de produção; módulo de cálculo de Valor Presente Líquido, baseado na curva gerada pelo

simulador de reservatórios. Assim, após o cálculo de VPL, essa informação é passada para o AG, que o utiliza como valor de avaliação da alternativa. Esta pesquisa encontra-se em fase preliminar de desenvolvimento, estando voltada à busca de outras iniciativas, dentre elas um novo modelo de algoritmo genético.

(Túpac, 2002) busca modelos para auxiliar na definição de pontos de perfuração de novos poços petrolíferos. Em oposição ao trabalho ora proposto, não se estabelece limites de produção em função de limitações físicas de armazenamento. Além disso, também não enfoca o problema da distribuição e entrega de produtos.

Em (Ribeiro, 2005), a proposta é encontrar uma forma dinâmica de obter soluções ótimas para roteamento de veículos com janelas de tempo utilizando algoritmos genéticos, onde é possível observar fatores como: veículo quebrado ou atrasado, uma nova requisição do cliente, dentre outras variantes. O problema de roteamento dinâmico de veículos com janelas de tempo é composto de uma série de problemas estáticos de roteamento de veículos com estas mesmas janelas de tempo, onde é buscada uma solução para a reprogramação utilizando AG. As variáveis usadas neste trabalho foram: a posição atual do veículo, o espaço disponível no mesmo (peso e volume) e a localização e janela de tempo (intervalo de atendimento) do cliente programado e ainda não atendido, como também novas requisições. Os resultados encontrados neste trabalho com o AG melhoraram as rotas existentes, sendo ainda melhores ou iguais aos resultados observados utilizando a Heurística 2-opt (Lin e Kernighan, 1973: 498-516), indicada para problemas de roteamento de veículos.

(Ribeiro, 2005) concentra-se no problema de roteamento de uma frota com intervalos de tempo decorrentes dos deslocamentos dos veículos. O modelo adotado forneceu algumas inspirações para o trabalho descrito no presente artigo. Cabe ressaltar, no entanto, que no trabalho ora proposto não existe propriamente o roteamento dos veículos em relação ao percurso, e sim em relação à necessidade de entrega e o tempo de viagem até o destino final. É importante ressaltar o seu não tratamento de questões que envolvam produção nem controle de estoque, requisitos necessários ao sistema *LogAge*.

Em (Croce, 2004:89-104) são utilizados AGs para a solução do problema de programação de produção em fundições de mercado, nome dado para fundições que trabalham com peças sob encomenda. O processo produtivo de uma fundição consiste basicamente nas seguintes etapas: acúmulo de pedido; modelagem; vazamento – onde as ligas metálicas são colocadas nos moldes e acabamento. O objetivo de (Croce, 2004:89-104) é decidir quais itens de pedido disponíveis em carteira serão programados para o ciclo de produção, a partir dos pedidos acumulados do ciclo atual e de ciclo anteriores, caso ainda não tenham sido produzidos, e tendo todas as restrições produtivas satisfeitas. As penalidades e prêmios são calculados de forma financeira para cada item de pedido na carteira de pedidos em aberto, além das penalidades e prêmios gerados pelo impacto do programa de produção no processo produtivo. Também foi necessário avaliar restrições produtivas, economia das ligas a serem fundidas, coordenação entre cada etapa e limitações do forno. Em (Croce, 2004: 89-104), foram formulados e comparados três modelos de solução para o problema de programação: modelo matemático, modelo heurístico e modelo baseado em Algoritmos Genéticos. O modelo matemático foi baseado em diversas equações representando restrições impostas ao problema. O modelo heurístico foi baseado no método heurístico *beam search* (Junior, 2006: 205-222). No modelo baseado em Algoritmos Genéticos, cada cromossomo foi subdividido em duas partes. Na primeira parte, cada gene armazena uma corrida de forno programada na ordem em que as

corridas irão acontecer. O gene guarda três informações para identificar: o forno, o reator e a liga usada. Na segunda parte, cada gene armazena um item de pedido que será fundido na referida programação, onde a ordem de aparecimento dos genes no cromossomo representa como os fornos deverão ser carregados.

Os experimentos realizados revelaram que o modelo matemático tem seu melhor desempenho quando há um número maior de itens de pedido em aberto. Os modelos Heurístico e AG, de maneira inversa, apresentam melhores resultados quando há um número menor de itens de pedido em aberto. Nos experimentos com itens de pedido mais complexos, o modelo matemático apresentou desempenho inferior. Para o modelo heurístico, o desempenho é maior se for inversamente proporcional à quantidade de recursos produtivos necessários. O modelo AG conseguiu desempenho superior em casos isolados e foram obtidos resultados satisfatórios para todos os casos considerados. Algoritmos Genéticos foram consistentes nos diversos cenários, confirmando sua robustez na busca da solução.

(Croce, 2004: 89-104) está voltado basicamente a aspectos de produção. Embora haja a preocupação com existência de recursos para a produção, não há referência a questões de armazenamento e distribuição da produção. Por outro lado, a solução proposta no presente artigo não se concentra em restrições quanto à produção e sim quanto à distribuição e ao armazenamento de produtos.

Convém ressaltar que em nenhum dos trabalhos pesquisados foi detectada uma abordagem com características idênticas às necessidades de controle de estoque e logística de entrega da FCC. Foram encontrados trabalhos com algumas características semelhantes. Por exemplo, a programação de entrega pode ser equiparada à programação de produção, pois nas duas vertentes são analisados tempo e redução de custos, isso atendendo as regras de negócio.

4 Modelo de Algoritmo Genético para o *LogAge*

O primeiro passo para a aplicação do algoritmo genético em um problema consiste em definir uma modelagem adequada. Uma das abordagens mais comuns para a modelagem dos cromossomos é o uso de uma seqüência de bits, onde cada bit representa um gene e pode assumir os valores “0” (zero) e “1” (um). Como as entregas de catalisador são eventos discretos ocorridos ao longo do tempo, apenas um bit é necessário para indicar uma entrega em um determinado dia, onde “1” (um) significa que haverá uma entrega no dia e “0” (zero) significa que não haverá. Assim, a programação de entrega para um determinado silo de um cliente ao longo de um mês pode ser armazenada em um grupo de até 31 bits, conforme o mês que estiver sendo programado. Assim o grupo poderá ter 28, 29, 30 ou 31 bits. O cromossomo será então composto por vários grupos destes bits, sendo um grupo para cada silo. A figura 7 mostra um cromossomo para um mês de 31 dias, onde cada bit corresponde a um gene que representa um dia do mês.




Figura 7 - Codificação do cromossomo

Os dias representados no cromossomo correspondem à chegada do catalisador no silo do cliente. Deste ponto de vista, todos os dias do mês são válidos, pois para manter o nível adequado no silo pode ser necessário haver uma chegada de produto em um domingo

(as refinarias de petróleo operam 24 horas por dia, sete dias por semana). Esta visão é diferente da FCC, que não realiza saídas nos domingos. A função de avaliação descrita a seguir deve observar esta característica e o tempo de viagem até cada silo para determinar se ocorrerá uma saída em um domingo.

4.1 Função de avaliação

A responsabilidade da função de avaliação é calcular a aptidão de um indivíduo, examinado a solução codificada nos genes para determinar a qualidade desta solução. A função deverá receber como argumentos o cromossomo, o ano e o mês da programação, bem como uma estrutura auxiliar com informações sobre os silos. Como cada cliente possui silos com dimensões distintas e seu consumo é diferenciado, torna-se necessário fornecer à função de avaliação uma matriz com informações de cada silo contendo: o saldo inicial (quantidade remanescente de produto) no dia 1º do mês da programação, o nível mínimo, o ponto de reposição, a capacidade máxima, a capacidade total, o consumo médio e o tempo total de viagem (ida e volta) em dias.

Os objetivos da programação de entrega são: reduzir o volume total entregue no mês aos clientes, reduzir o número máximo de caminhões em uso por dia e reduzir o número médio de caminhões em uso por dia.

Há situações em que a função de avaliação deve penalizar o indivíduo, reduzindo sua aptidão. Estas são situações não ótimas, porém aceitáveis: nível do silo abaixo do ponto de reposição, nível do silo acima do máximo, ou número de caminhões em uso maior que a frota disponível. A ocorrência dessa última situação demandaria a locação extra de caminhões, acarretando em maior custo.

Por último ainda há situações inválidas (ilegais), não permitidas pelas regras do negócio ou fisicamente impossíveis, conforme a relação: nível do silo abaixo do ponto mínimo, nível do silo acima da capacidade total, entrega de catalisador enquanto ainda não há espaço físico no silo para o volume transportado e saída de entrega no domingo. Ao detectar alguma destas situações, a função de avaliação deve sinalizar para o AG que este indivíduo é inválido e deve ser retirado da população. Para tratar a condição de entrega no domingo, foi criado um operador genético específico, executado após o *crossover* e a mutação. Este operador analisa as soluções candidatas e retira (muda o valor do gene para “0”) as entregas que correspondem a uma saída (levando em conta o tempo de viagem) em um domingo.

Neste trabalho são utilizadas duas formas de quantificação: o primeiro, chamado *Modelo 1*, mais simples, que apenas soma os objetivos e as penalidades; e o segundo, dito *Modelo 2*, mais elaborado que calcula a quantidade de entregas que deverá ocorrer para cada silo antes de tentar otimizá-las.

4.1.1 Modelo 1

Para calcular a aptidão de um indivíduo, o volume total entregue será somado às diversas penalidades que a solução candidata pode sofrer. Estas penalidades serão multiplicadas por pesos apropriados à sua importância. A ordem de grandeza destes pesos foi estimada por meio de um processo experimental iterativo, visando quantificar a gravidade das violações das regras de negócio. Portanto, quanto mais grave for a violação, maior será o peso a ela associado. A tabela 2 apresenta os pesos estimados e que foram adotados nos experimentos realizados com o *LogAge*.

Tabela 2 Pesos das penalidades

Item de aptidão	Peso
Volume total entregue no mês	Elevado ao quadrado
Nível abaixo do ponto de reposição	Multiplicado por 10^3
Nível acima do máximo	Multiplicado por 10^5
Nível abaixo do mínimo	Multiplicado por 10^7
Nível acima do total	Multiplicado por 10^9

Todos os valores são somados para cada silo individualmente. A aptidão do indivíduo é o somatório da aptidão de cada silo mais as penalidades pelo uso de caminhões. Se a solução apresenta um pico de utilização diária superior à frota própria, ocorre uma penalização severa; caso contrário, a aptidão é reduzida de forma proporcional à média de caminhões utilizados.

O volume total foi elevado ao quadrado para maximizar a diferença entre os indivíduos. Como o objetivo da FCC é reduzir o volume total entregue, como mostrado anteriormente, o objetivo do AG deste projeto é minimizar o valor da função de avaliação.

4.1.2 Modelo 2

Esta forma de quantificação do indivíduo parte do fato de que a quantidade de entregas (aproximada) que um silo deve receber em um mês pode ser previamente calculada. Esta quantidade é diretamente proporcional ao consumo médio diário do silo (que é conhecido) e a quantidade de dias no mês, sendo também inversamente proporcional à quantidade de catalisador transportada em cada entrega. A fórmula a seguir mostra este cálculo:

$$\frac{(\text{consumo médio diário} \times \text{número de dias no mês}) - \text{nível inicial} + \text{nível de reposição}}{\text{quantidade de catalisador em cada entrega}}$$

A forma de quantificar as violações foi modificada neste modelo. Ao invés de calcular quanto o nível do silo passou de um determinado ponto, a função passa a contar o número de dias em que o nível do silo permaneceu acima ou abaixo do ponto permitido. Para cada silo representado em um cromossomo, são avaliados os seguintes pontos:

Tabela 3 – Forma de quantificação

Item de aptidão	Tipo
Quantidade de entregas no mês	Número
Quantidade de dias abaixo da reposição	Número
Quantidade de dias abaixo do mínimo	Número
Quantidade de dias acima do máximo	Número
Nível abaixo de zero (negativo)	Lógico
Nível acima da capacidade total	Lógico

De posse dos itens da tabela 3 calculados para cada silo, a função de avaliação quantifica o indivíduo como um todo.

Para aumentar a diferença relativa de aptidão entre os indivíduos, foi definido um valor de aptidão máximo e deste valor são debitadas as penalidades. Para aumentar a

aptidão das melhores soluções, são definidos dois indicadores adicionais de qualidade da solução. Se um silo não atinge o nível mínimo, não atinge o nível máximo e também não atinge o nível de reposição, este é considerado um silo ótimo. Se, além de não cometer estas três violações citadas anteriormente o silo apresenta a quantidade de entregas igual ou inferior à média calculada, este silo é considerado excelente. A função de avaliação conta quantos silos no cromossomo alcançam um dos critérios de qualidade citados anteriormente e multiplica o valor de aptidão por esta quantidade (se houver). Se algum cromossomo apresenta silos que violam a capacidade total ou têm o nível abaixo de zero, sua aptidão é reduzida em 90%. A tabela 4 abaixo mostra os pesos aplicados:

Tabela 4 – Pesos aplicados

Item de aptidão	Peso
Quantidade de entregas no mês	1 (*)
Quantidade de dias abaixo da reposição	0,5
Quantidade de dias abaixo do mínimo	1
Quantidade de dias acima do máximo	3
Nível abaixo de zero (negativo)	-90%
Nível acima da capacidade total	-90%
Silos ótimos	x quantidade de silos
Silos excelentes	x quantidade de silos
Uso de caminhões acima da frota	-50%
Mais de 3 carregamentos por dia	-30%

A penalidade referente à quantidade de entregas no mês é aplicada somente se o silo apresenta uma quantidade de entregas superior à média calculada. O objetivo do AG será minimizar o valor da função de avaliação.

Para entender o número de caminhões em uso, faz-se necessário esclarecer que o tempo de viagem (ida e volta) para entrega do produto pode ser de vários dias, o que faz com que, em um determinado dia, existam vários caminhões em trânsito (indo ou voltando do cliente). Para exemplificar segue um roteiro de entregas fictício:

1º Dia - foram realizadas três entregas para clientes localizados a quatro dias de viagem. Esses caminhões somente estarão disponíveis novamente no dia 5 (dois dias indo, dois dias voltando).

2º Dia - foram realizadas mais três entregas, que alcançou um total de seis caminhões em uso neste dia: os três caminhões do 1º dia (que ainda vão chegar ao seu destino) e os três utilizados no 2º dia.

Desta forma, somando-se o número de entregas diárias e contando também com o tempo de viagem das entregas anteriores, pode-se calcular o uso diário de caminhões. Uma boa programação de entrega deve reduzir ao máximo o pico desta utilização diária, pois este pico pode ocasionar custo extra de locação de um ou mais caminhões.

Destaca-se que, para quantificar o uso de caminhões, a função de avaliação deve examinar todos os blocos de informação e não apenas um silo por vez. A tabela 5 mostra um exemplo de como é calculado o uso de caminhões para os 10 (dez) primeiros dias de um mês, tomando cinco silos como base.

Tabela 5 – Exemplo de uso de caminhões

Dia	1	2	3	4	5	6	7	8	9	10	Dias de viagem
Silo 1											2
Silo 2											4
Silo 3											4
Silo 4											1
Silo 5											3
Número de caminhões em uso	3	5	3	3	2	1	3	4	4	3	3,1 (média diária de uso de caminhões)

4.2 Operador de Cruzamento

Um segundo operador de cruzamento foi criado para respeitar os blocos de informação que compõem o cromossomo. Conforme a figura 7, cada bloco de genes (com a quantidade de dias do mês sendo programado) representa um silo. O crossover normal seleciona de forma aleatória uma posição de corte (*locus*) e isso pode dividir um bloco de genes (referente a um silo) em qualquer ponto, potencialmente deteriorando uma solução promissora. Para abordar este problema foi criado um operador de cruzamento especial que determina os pontos de cruzamento respeitando o número de dias no mês, de forma a preservar os blocos dos silos inteiros, conforme figura 8. Esta nova operação de cruzamento foi incluída no AG após o cruzamento normal (que foi mantido para aumentar a diversidade genética).




Figura 8 – Exemplo do cruzamento customizado

Desta forma, se um indivíduo apresenta apenas um silo projetado adequadamente, do cruzamento pode resultar um descendente que preserva o silo projetado de forma correta para a população posterior.

5 Protótipo, Experimentos e Resultados

Todos os recursos de software deste projeto são de código livre, sem restrições de uso e amplamente utilizados em seus respectivos segmentos. Para desenvolver o sistema-piloto, foi utilizada a linguagem *Java* para criar uma aplicação Web utilizando as tecnologias *JSP/Servlet (MVC)* (JSP, 2006) (SERVLET, 2006) no servidor de aplicação *Tomcat* (TOMCAT, 2006). O Sistema Gerenciador de Banco de Dados utilizado foi o *PostgreSQL*, versão 8.1 (POSTGRESQL, 2006). Todo o projeto foi desenvolvido com o ambiente de desenvolvimento *Eclipse* (ECLIPSE, 2006). As operações genéticas foram

feitas com o auxílio da biblioteca livre *JGAP* (JGAP, 2006). Para gerar os gráficos de resultados, foi utilizado o *JFreeChart* (JFREECHART, 2006).

A figura 9 mostra como é a visualização da programação gerada pelo AG, que corresponde ao calendário do mês e ano solicitado pelo gestor para criação de nova programação de entrega.

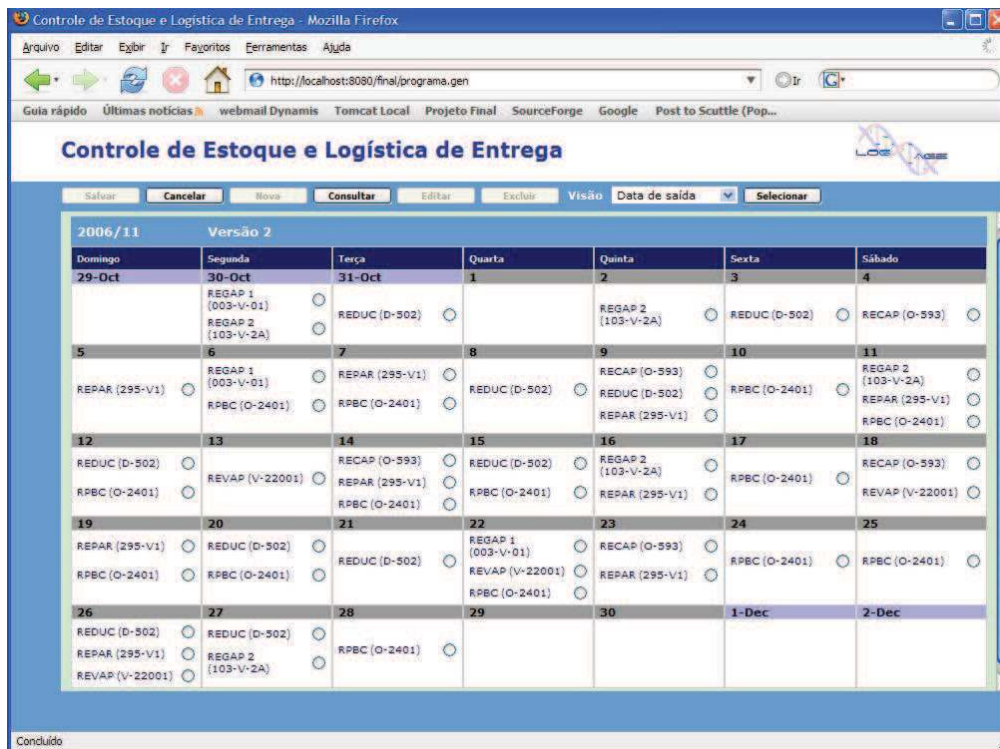


Figura 9 – Tela Programação de Entrega

5.1 Testes com silos reais

Com base na programação real criada pela FCC (manualmente) para os meses de Agosto, Setembro e Outubro de 2006 foram configurados sete silos, um de cada cliente com os parâmetros reais obtidos na FCC. A FCC atende a um número maior de refinarias, mas para o objetivo deste projeto, somente aquelas que a entrega é feita com os caminhões específicos para o transporte de catalisador são consideradas. Também foram obtidas as leituras do radar para os silos em estudo, permitindo assim observar o comportamento real ao longo de cada um dos três meses.

Um fato que se destacou foi a grande variação no consumo de catalisador por parte das refinarias. Frequentemente os clientes solicitam um aumento ou uma redução da quantidade de catalisador entregue em um mês específico, seja por um aumento sazonal da produção ou uma parada para manutenção. O problema destas solicitações é que o gestor da programação normalmente não atualiza os parâmetros do silo para refletir estas mudanças. Durante os testes com silos reais isso causou situações anormais como o silo iniciar o mês bastante acima do nível máximo (por pedido do cliente). A tabela 6 mostra os silos que foram cadastrados.

Tabela 6 – Características dos silos reais

Cliente	Silo	Data	Consumo médio diário	Nível atual	Nível máximo	Nível mínimo	Capacidade total	Nível de reposição	Ativo
REDUC	D-502	31/08/2006	8	64,7	90	30	184	60	S
RECAP	O-593	31/08/2006	5	63,41	70	20	80	50	S
REGAP 1	003-V-01	31/08/2006	1,6	32,02	75	25	90	45	S
REGAP 2	103-V-2A	31/08/2006	2,6	41,36	100	25	250	50	S
REPAR	295-V1	31/08/2006	9,2	115,02	90	50	137	75	S
RPBC	O-2401	31/08/2006	15	144,16	85	45	291	60	S
REVAP	V-22001	31/08/2006	6	133,32	75	35	235	50	S

Inicialmente os parâmetros do AG foram definidos conforme a tabela 7:

Tabela 7 – Parâmetros do AG

Parâmetro	Valor
Total de gerações	50
Quantidade de indivíduos	20
Taxa de crossover	50%
Tipo de crossover	um ponto e “por silo”*
Método de seleção	Ranking
Taxa de mutação	7%
Elitismo	Sim (40%)

Foram realizadas três execuções consecutivas com os seguintes parâmetros do AG, apresentados na tabela 8.

Tabela 8 – Parâmetros do AG

Parâmetro	Valor
Total de gerações	3500
Quantidade de indivíduos	20
Taxa de crossover	50%
Tipo de crossover	um ponto e “por silo”*
Método de seleção	Ranking
Taxa de mutação	7%
Elitismo	Sim (40%)

Analisando as entregas do mês de Agosto, podemos observar no exemplo do silo 103-V-2A das figuras 10 e 11, que o AG realizou uma entrega a mais que a programação manual. Como podemos ver no dia 01 do gráfico da programação manual, o silo inicia o mês no nível mínimo, e o gráfico gerado pelo AG mostra o nível próximo a 50 toneladas (reposição), resultado de uma entrega programada para chegar no dia primeiro.




Figura 10 – Programação manual no mês de Agosto para o silo 103-V-2A



Figura 11 – Programação com AG no mês de Agosto para o silo 103-V-2A

Ainda no mês de Agosto, as programações manuais e com o AG do silo D-502 das figuras 12 e 13 revelam que o segundo distribuiu melhor as entregas para evitar a região próxima do mínimo no início do mês.



Figura 12 – Programação manual no mês de Agosto para o silo D-502



Figura 13 – Programação com AG no mês de Agosto para o silo D-502

No exemplo do silo 003-V-01 do mês de Agosto (figuras 14 e 15) ocorreu o mesmo que no silo 103-V-2A: o AG realizou uma entrega a mais que a programação manual. Como podemos ver no dia 01 do gráfico da programação manual, o silo inicia o mês no nível mínimo, e o gráfico gerado pelo AG mostra o nível próximo a 40 toneladas (um pouco abaixo da reposição), resultado de uma entrega programada para chegar no dia primeiro.



Figura 14 – Programação manual no mês de Agosto para o silo 003-V-01



Figura 15 – Programação com AG no mês de Agosto para o silo 003-V-01

Com estas configurações da tabela 7, os resultados não foram ótimos. Os gráficos apresentados nas figuras 16 e 17 mostram os silos V-22001 e D-502 no mês de Setembro:



Figura 16 – Previsão com o AG do silo V-22001 no mês de Setembro



Figura 17 – Previsão com o AG do silo D-502 no mês de Setembro

Como se pode observar, o resultado não foi satisfatório no mês de Setembro. O silo V-22001 permaneceu com o nível acima do máximo permitido e o silo D-502 ficou abaixo do mínimo no dia 11. A seguir o número de gerações foi aumentado até que um resultado satisfatório e consistente fosse alcançado.

O resultado foi bastante consistente entre as execuções e a previsão do mês de Setembro para o silo D-502 com base no melhor indivíduo de uma das três execuções é mostrado no gráfico da figura 18.



Figura 18 – Previsão com o AG no mês de Setembro para o silo D-502

Outro resultado importante foi obtido com o silo V-22001. Este silo iniciou o mês de Setembro com 133,32 toneladas de catalisador, acima do seu nível máximo que é de 75 toneladas. Isso se deve a uma solicitação do cliente. Na programação manual, este silo recebeu apenas três entregas (duas no dia 6 e uma do dia 7), uma vez que seu consumo médio diário é de seis toneladas. O gráfico da figura 19 mostra a previsão do nível do silo com a programação manual no mês de Setembro:



Figura 19 – Programação manual do mês de Setembro para o silo V-22001

Com a programação gerada pelo AG, a previsão ficou desta forma:



Figura 20 – Previsão com o AG do mês de Setembro para o silo V-22001

Pelo gráfico da figura 20 pode-se ver que o AG percebeu a violação do nível máximo, não realizando entregas até que o nível do silo atingisse os valores normais (no dia 14) e a quantidade de entregas foi a mesma da programação manual (três entregas).

Quando o silo apresenta um consumo mais baixo (menor número de entregas por mês) o AG tem mais facilidade de distribuir as entregas e frequentemente produz o resultado ótimo para o silo. Como exemplo pode-se tomar o silo 003-V-01, que tem um consumo diário de apenas 1,6 toneladas de catalisador. Na programação manual para este silo foram previstas apenas duas entregas (dias 4 e 11) e o resultado estimado pode ser visto no gráfico da figura 21.




Figura 21 – Programação manual no mês de Setembro para o silo 003-V-01

Com a programação gerada pelo AG, a previsão se apresenta como aparece na figura 22. Neste exemplo, o AG realizou três entregas (uma a mais que a programação manual) e colocou a primeira entrega chegando no primeiro dia do mês. Esta ação evitou que o silo ficasse abaixo do ponto de reposição. Frequentemente o gestor reduz a quantidade de entregas a pedido do cliente, que não se importa que o silo fique próximo do nível mínimo. Possivelmente os níveis mínimo, máximo e de reposição deste silo deveriam ser revistos pelo gestor.




Figura 22 – Programação com o AG no mês de Setembro para o silo 003-V-01

Analisamos também as entregas do mês de Outubro. Neste caso, as situações representadas nas figuras 14 e X1 (silo 103-V-2A e 003-V-01), de nível de silo próximo do mínimo na programação manual, são resultado de acordos (informais) entre o responsável pela programação de entrega e os clientes (que pedem para reduzir as entregas de catalisador, não se importando com o fato do nível baixar próximo ao mínimo). O correto seria alterar os parâmetros dos silos (reduzindo o nível mínimo e o de reposição) para que o AG criasse resultados semelhantes ao da programação manual.

Os gráficos do silo 103-V2A (figura 23) mostram outra situação onde o cliente solicitou a suspensão das entregas de catalisador durante o mês de outubro, devido ao baixo consumo diário do silo. O AG realizou apenas três entregas, o suficiente para manter o nível dentro da região ótima (figura 24).




Figura 23 – Programação manual no mês de Outubro para o silo 103-V-2A




Figura 24 – Programação com AG no mês de Outubro para o silo 103-V-2A

Neste outro caso, o silo D-502 (figura 25) ocorreu outra situação anormal, com a interrupção das entregas a partir do dia 17 (provavelmente por solicitação do cliente). O AG prosseguiu normalmente, inclusive com uma maior regularidade das entregas (figura 26).



Figura 25 – Programação manual no mês de Outubro para o silo D-502



Figura 26 – Programação com AG no mês de Outubro para o silo D-502

No silo 003-V-01 da figura 28 também ocorreu uma entrega adicional para manter o nível na região ótima, contrapondo-se à programação manual proposta, representada na figura 27.




Figura 27 – Programação manual no mês de Outubro para o silo 003-V-01




Figura 28 – Programação com AG no mês de Outubro para o silo 003-V-01

5.2 Conclusão dos testes

Com base nos experimentos realizados e nos resultados obtidos, pode-se perceber uma boa adequação da modelagem do AG para criação de programações de entrega consistentes e em conformidade com as regras estabelecidas. Apesar de ser um processo de busca aleatória, os resultados de diferentes execuções apresentaram grande semelhança entre si. O método de codificação 1 se mostrou limitado ao lidar com um maior número de silos e especialmente com silos que iniciam um mês em uma condição fora do normal (acima do máximo ou abaixo do ponto de reposição).

Também ficou evidente a sensibilidade do AG aos parâmetros dos silos (mínimo, máximo, reposição e consumo médio diário). Se estes níveis não forem consistentes com a realidade do silo, a programação resultante não atenderá ao cliente. O AG se mostrou bastante disciplinado, seguindo o objetivo de manter o silo na região ideal.

O objetivo da FCC é entregar aos seus clientes apenas a quantidade necessária à manutenção dos níveis do silo, reduzindo os estoques de catalisador ao mínimo. Nesta visão, se os níveis do silo estão dentro dos valores aceitáveis para o cliente, quanto menos entregas, melhor. Os testes mostraram que, ajustando adequadamente o parâmetro de consumo médio diário do silo, pode-se programar a quantidade exata de entregas para atender um silo, inclusive reduzindo as entregas em relação à programação manual.

Apesar de terem sido destacados apenas três silos, todos os experimentos foram feitos com os sete silos da tabela 6 e o AG apresentou resultado adequado em todos.

Os exemplos citados são do mês de Setembro de 2006, mas os testes foram realizados também nos meses de agosto e outubro do mesmo ano. Em todas as situações os resultados gerados pelo AG foram adequados e consistentes.

Convém mencionar que o tempo médio do AG nos experimentos realizados foi de 3 (três) minutos. A plataforma utilizada para testes foi um Intel Centrino Duo 1,66MHz com 1GB de RAM.

Cabe ressaltar ainda que, como um sistema de apoio à decisão, no *LogAge* a programação de entrega gerada pelo AG pode ser modificada pelo gestor do sistema, permitindo que sejam feitos ajustes em função das necessidades específicas dos clientes.

6 Considerações finais

A realização de entregas de bens aos clientes, de forma a manter os níveis de estoque dentro de faixas aceitáveis, é uma das grandes preocupações logísticas no cenário globalizado e competitivo da atualidade.

O presente trabalho teve como objetivo demonstrar o uso dos algoritmos genéticos (AG) na solução de problemas de programação de entregas e controle de estoques remotos. Para tanto, foi utilizado o caso particular da Fábrica Carioca de Catalisadores (FCC), que produz catalisador para refino de petróleo e possui em sua rotina operacional a questão do gerenciamento de entrega. A FCC procura atender seus clientes na medida certa, entregando somente a quantidade de catalisador consumida por estes. Simultaneamente a FCC deseja fazer um uso adequado de sua frota de caminhões.

Dois modelos de AG foram desenvolvidos e experimentados. Nos testes realizados, ambos os modelos ilustraram a adequação da utilização de algoritmos genéticos para a tarefa de logística de entrega.

O modelo 1 de quantificação permitiu uma visão mais simples e uma abordagem direta na medida da qualidade de cada solução, bem como um maior entendimento do funcionamento interno do AG. As lições aprendidas com os testes desse modelo foram fundamentais na elaboração de um novo modelo capaz de lidar com as situações mais complexas do mundo real.

O modelo 2 contribuiu para ilustrar a capacidade dos algoritmos genéticos de encontrar soluções a partir de restrições complexas e formas de avaliação de alto custo de processamento.

Os modelos de AG foram incorporados a um sistema de apoio à decisão, o *LogAge*. Este sistema tem como objetivo auxiliar os gestores no planejamento de entrega de catalisador da FCC, reduzindo com isso o tempo requerido para a realização manual desse tipo de atividade. O desenvolvimento do *LogAge* mostrou a maturidade das ferramentas de código livre disponíveis atualmente, em especial a biblioteca de algoritmos genéticos (*JGAP*), que permitiu que a maior parte dos esforços fosse concentrado especificamente no problema e menos na técnica de AG.

O principal desafio enfrentado foi o tratamento dos parâmetros dos silos reais, que podem interferir negativamente no desempenho do AG ao introduzir condições iniciais que violam as regras do negócio. Outro fator enfrentado durante o desenvolvimento foi o tratamento do cromossomo com as particularidades do negócio, como os blocos de cada silo e a questão do tempo de viagem diferenciado por cliente, assim como as visões de saída da FCC e a chegada no silo.

Entre os trabalhos futuros podem ser destacados: (a) A avaliação comparativa do AG com outras técnicas de otimização na implementação da programação de entregas; (b) A inclusão do controle de estoque nos centros de distribuição utilizados pela FCC no atendimento a algumas refinarias. Esta melhoria implicaria no controle de dois tipos de caminhos: os específicos de catalisador (foco desse trabalho) e os convencionais, além da quantidade variável de produto por entrega; (c) A integração da programação de produção do produto ao controle de entrega de catalisador já desenvolvida, ampliando o escopo do *LogAge*.

Referências

CASTRO, H. P., **Utilização de Algoritmos Genéticos para solução de problemas de programação de produção de uma refinaria de petróleo**, Tese de M.Sc., Universidade Federal de Santa Catarina, Brasil, 2001

CROCE, F. D., GHIRARDI, M., TADEI, R., “Recovering beam search: Enhancing the beam search approach for combinatorial optimization problems”, **Journal of Heuristics**, volume 10, número 1, pp. 89-104, 2004.

DARWIN, C., **On the Origin of Species by Means of Natural Selection**, Inglaterra, John Morrey, 1859

ECLIPSE, disponível em <http://www.eclipse.org/>, último acesso em novembro de 2006.

GOLDBERG, DAVID E, **Genetic Algorithms in Search, Optimization, and Machine Learning**, 1ª Edição, EUA, Addison Wesley, 1989

HAUPT, R. L., HAUPT, S. E., **Practical Genetic Algorithms**, 2ª Edição, EUA e Canadá, Wiley-Interscience, 2004

HUTCHINS, D., **Just in Time**, 1ª Edição, São Paulo - Brasil, Ed. Atlas, 1993.

JFREECHART, disponível em <http://www.jfree.org/jfreechart/>, último acesso em novembro de 2006.

JGAP, disponível em <http://jgap.sourceforge.net/>, último acesso em novembro de 2006.

JSP, disponível em <http://java.sun.com/products/jsp/>, último acesso em novembro de 2006.

JUNIOR, R. F. T., FERNANDES, F. C. F., PEREIRA, N. A., “Sistema de Apoio à Decisão para Programação da Produção em Fundições de Mercado”, **Revista Gestão e Produção**, volume 13, número 3, pp. 205-222, 2006

LIN S., B. W. KERNIGHAN, An Effective Heuristic Algorithm for the traveling Salesman Problem, **Operations Research**, v. 21, pp. 498-516, 1973

POSTGRESQL, disponível em <http://www.postgresql.org/>, último acesso em novembro de 2006.

RIBEIRO, G. M., LORENA, L. A. N., “Roteamento de Veículos Dinâmicos Usando Algoritmos Genéticos”, **In: XIX ANPET - Congresso de pesquisa e ensino em transportes, Recife e Panorama Nacional da Pesquisa em Transportes 2005**, v. 19, pp. 1593-1603, Brasil, 2005.

SERVLET, disponível em <http://java.sun.com/products/servlet/>, último acesso em novembro de 2006.

TOMCAT, disponível em <http://tomcat.apache.org/>, último acesso em Novembro de 2006.

TÚPAC, Y. J., VELLASCO, M. M. R., PACHECO, M. A. C., “Planejamento e Otimização do Desenvolvimento de um Campo de Petróleo por Algoritmos Genéticos”, **In: Anais do XXII Encontro Nacional de Engenharia de Produção**, Brasil, Outubro de 2002.