



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS



UM MÉTODO MULTIOBJETIVO APLICADO AO PROBLEMA DO CAIXEIRO VIAJANTE COM LUCRO

RELATÓRIO FINAL DE PROJETO DE INICIAÇÃO CIENTÍFICA
(PIBIC/CNPq/INPE)

Carla Cristina Doescher Fernandes (UNIFESP, Bolsista PIBIC/CNPq)
E-mail: c.fernandes11@unifesp.br

Prof. Dr. Luiz Antonio Nogueira Lorena (LAC/INPE, Orientador)
E-mail: lorena@lac.inpe.br

COLABORADORES

Prof. Dr. Antônio Augusto Chaves (ICT/UNIFESP)
Prof. Dra. Kelly Cristina Poldi (ICT/UNIFESP)

INPE
São José dos Campos
Julho de 2012

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Gabinete do Diretor (GB)
Serviço de Informação e Documentação (SID)
Caixa Postal 515 - CEP 12.245-970
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/6921
Fax: (012) 3208-6919
E-mail: pubtc@sid.inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE (RE/DIR-204):

Presidente:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Membros:

Dr. Antonio Fernando Bertachini de Almeida Prado - Coordenação Engenharia e Tecnologia Espacial (ETE)

Dra. Inez Staciari Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

Dr. Germano de Souza Kienbaum - Centro de Tecnologias Especiais (CTE)

Dr. Manoel Alonso Gan - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dra. Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

EDITORAÇÃO ELETRÔNICA:

Vivéca Sant'Ana Lemos - Serviço de Informação e Documentação (SID)



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS



UM MÉTODO MULTI OBJETIVO APLICADO AO PROBLEMA DO CAIXEIRO VIAJANTE COM LUCRO

RELATÓRIO FINAL DE PROJETO DE INICIAÇÃO CIENTÍFICA
(PIBIC/CNPq/INPE)

Carla Cristina Doescher Fernandes (UNIFESP, Bolsista PIBIC/CNPq)
E-mail: c.fernandes11@unifesp.br

Prof. Dr. Luiz Antonio Nogueira Lorena (LAC/INPE, Orientador)
E-mail: lorena@lac.inpe.br

COLABORADORES

Prof. Dr. Antônio Augusto Chaves (ICT/UNIFESP)
Prof. Dra. Kelly Cristina Poldi (ICT/UNIFESP)

INPE
São José dos Campos
Julho de 2012

RESUMO

A classe de problemas do Caixeiro Viajante com Lucros (TSPP, do inglês *Traveling Salesman Problem with Profits*), associa a cada cliente um valor de prêmio (lucro) a ser ganho quando este for visitado, assim o TSPP pode ser visto como um problema do caixeiro viajante com dois objetivos opostos, um que pressiona o caixeiro a viajar (ou seja, maximizar os prêmios coletados) e outro que estimula o caixeiro a minimizar os custos de viagem (permitindo a ele não visitar alguns clientes). Desta classe advém um problema conhecido como Problema do Vendedor com Multiobjetivos (MVP, do inglês *Multiobjective Vending Problem*) que trata desses dois objetivos separadamente. Neste trabalho aplica-se o método Busca por Agrupamentos (CS, do inglês *Clustering Search*) na solução deste problema biobjetivo. Para tanto, foi proposto o PCS (*Pareto Clustering Search*) uma variação do CS para a solução heurística do problema sob a visão multiobjetivo.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 3.1 - Dominância de Pareto.....	6
Figura 4.1 - Fluxograma do método CS.....	11
Figura 5.1 - Representação da solução	12
Figura 6.1 - Gráfico de comparação PSA e PCS	15

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 6.1 - Tempo de execução PCS e PSA	16

LISTA DE SIGLAS E ABREVIATURAS

INPE	Instituto Nacional de Pesquisas Espaciais
TSP	<i>Traveling Salesman Problem</i>
TSPP	<i>Traveling Salesman Problem with Profits</i>
MVP	<i>Multiobjective Vending Problem</i>
CS	<i>Clustering Search</i>
PCS	<i>Pareto Clustering Search</i>
PSA	<i>Pareto Simulated Annealing</i>
VND	<i>Variable Neighborhood Descent</i>
PR	<i>Path-Relinking</i>

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
2 PROBLEMA DO CAIXEIRO VIAJANTE COM LUCRO	3
2.1. Formulação Matemática	4
3 ALGORITMO MULTIOBJETIVOS	6
3.1. <i>Pareto Simulated Annealing</i> (PSA).....	7
4 BUSCA POR AGRUPAMENTOS	9
5 APLICAÇÃO DO PCS AO MVP.....	12
6 RESULTADOS	15
7 CONCLUSÃO.....	17
REFERÊNCIAS BIBLIOGRÁFICAS.....	18

1 INTRODUÇÃO

O Problema do Caixeiro Viajante referido na literatura como *Traveling Salesman Problem* (TSP) [16] é um dos mais tradicionais problemas de otimização combinatória. O TSP consiste em otimizar a sequência de visitas a clientes a partir de um depósito central, sendo que todos clientes precisam ser visitados, e conseqüentemente, nenhum valor é associado ao serviço de atendimento ao cliente. Porém, algumas generalizações deste problema propõem selecionar clientes dependendo de um valor de prêmio (benefício) que é ganho quando a visita acontecer. Esta característica dá origem a uma classe de problemas que foi nomeada *Traveling Salesman Problems with Profits* (TSPP) ou Problemas do Caixeiro Viajante com Lucros [7].

Os TSPP podem ser vistos como problemas do caixeiro viajante biobjetivos. Na prática, a maioria das pesquisas existentes sobre estes problemas trata-os como sendo versões de um único objetivo. Assim, ou os dois objetivos são calculados e combinados linearmente, ou um dos objetivos é transformado em restrição com um valor limite especificado. Porém, este trabalho propõe solucionar um problema oriundo da classe TSPP que trata dos dois objetivos separadamente, tal problema é denominado Problema do Vendedor com Multiobjetivos (MVP, do inglês *Multiobjective Vending Problem*) [13]. Desta forma, resolver o MVP resulta em encontrar uma fronteira de Pareto, ou seja, um conjunto de soluções viáveis tal que nenhum objetivo possa ser melhorado sem deteriorar o outro. Neste trabalho aplica-se o método Busca por Agrupamentos (CS, do inglês *Clustering Search*) [4], na solução deste problema biobjetivo. Para isto, foi proposto o PCS (*Pareto Clustering Search*) que visa combinar meta-heurísticas e heurísticas de busca local multiobjetivo, intensificando o processo de busca somente em regiões consideradas promissoras.

O restante deste trabalho está organizado da seguinte forma. No capítulo 2 apresenta-se uma formulação matemática para o TSPP e faz-se uma revisão bibliográfica. No capítulo 3, define-se métodos multiobjetivos. No capítulo 4

descreve-se a meta-heurística CS e sua adequação ao PCS. No capítulo 5 discute-se a aplicação do PCS ao MVP . No capítulo 6 apresentam-se os resultados computacionais obtidos. No capítulo 7 são apresentadas algumas conclusões deste trabalho.

2 O PROBLEMA DO CAIXEIRO VIAJANTE COM LUCRO

O problema do Caixeiro Viajante com Lucro (TSPP, do inglês *Traveling Salesman Problem with Profits*) [3] atribui para cada cidade um prêmio (lucro) que o caixeiro recebe caso visite a cidade (não sendo obrigado a visitar todas cidades). Sendo assim, TSPP é um problema biobjetivo, em que um dos objetivos é minimizar os custos da viagem e o outro consiste em maximizar o lucro obtido.

O TSPP de uma forma geral, pode ser representado em um grafo completo $G = (V,A)$, onde $V = \{0, 1, \dots, n\}$ é um conjunto de n vértices e A é um conjunto de arestas (grafo não direcionado). Para cada vértice $i \in V$ existe associado um prêmio p_i , e cada aresta $(i, j) \in A$ possui um custo de deslocamento c_{ij} . Supondo que o vértice 0, sem perda de generalidade, seja o depósito ou a cidade de origem do caixeiro, este vértice deve ter prêmio nulo ($p_0 = 0$). O TSPP consiste em determinar um circuito elementar que contenha o vértice 0, levando em consideração o prêmio coletado e os custos de deslocamento.

Os diferentes problemas que formam o TSPP surgem das diferentes maneiras que existem para tratar os dois objetivos:

1. Os dois objetivos são tratados separadamente, gerando um problema multiobjetivo, onde os objetivos são, minimizar os custos de deslocamento e maximizar prêmios coletados. Este problema é conhecido como *Multiobjective Vending Problem* (MVP) [13];
2. Ambos os objetivos são combinados numa função objetivo, visando encontrar uma rota que minimize os custos de deslocamento menos os prêmios coletados. Em [6] apresenta-se esta versão como sendo o *Profitable Tour Problem* (PTP), sendo que, ao invés de coletar um prêmio por visitar uma cidade, o caixeiro paga uma penalidade caso deixe de visitar alguma cidade.
3. O objetivo do custo de deslocamento é definido como uma restrição, e o objetivo é encontrar uma rota que maximize o prêmio coletado tal que o custo

de deslocamento não exceda um valor máximo. Este problema é chamado de *Orienteering Problem* (OP) [17].

4. O objetivo do prêmio é definido como uma restrição, e o objetivo é encontrar uma rota que minimize os custos de deslocamento e que o prêmio coletado não seja menor que um valor pré-definido. Este problema é definido como *Prize-Collecting TSP* (PCTSP) [3] onde também é inserido o conceito de penalidades, ou *Quota TSP* (QTSP) [2].

2.1. Formulação Matemática

É possível definir um conjunto de restrições básicas para as formulações matemáticas dos TSPs. Considere x_{ij} ($i, j \in V, i \neq j$) sendo uma variável binária igual a 1 se a aresta (i, j) pertencer à solução e x_{ij} igual 0 caso contrário, e uma variável binária y_i ($i \in V$) que controla se o vértice i está presente na solução, assumindo valor 1 caso seja visitado e valor 0 caso contrário.

Todos TSP compartilham as restrições a seguir :

$$\sum_{j \in \mathcal{V}_i} x_{ij} = y_i \quad \forall i \in V \quad (2.1)$$

$$\sum_{i \in \mathcal{V}_j} x_{ij} = y_j \quad \forall j \in V \quad (2.2)$$

$$y_0 = 1 \quad (2.3)$$

$$x_{ij} \in \{0,1\} \quad \forall i, j \in V \quad (2.4)$$

$$y_i \in \{0,1\} \quad \forall i \in V \quad (2.5)$$

As restrições (2.1) e (2.2) são chamadas restrições de atribuição e garantem que cada vértice seja visitado no máximo uma vez. A restrição (2.3) assegura

que o depósito seja visitado, as restrições (2.4) e (2.5) asseguram que as variáveis x_{ij} e y_i sejam binárias.

A função objetivo, no entanto, é diferente para cada problema da classe TSPP. Este projeto trata-se do MVP que possui duas funções objetivos, descritas a seguir:

$$\min \sum_{i \in V} \sum_{j \in V} c_{ij} x_{ij} \quad (2.6)$$

$$\max \sum_{i \in V} p_i y_i \quad (2.7)$$

sujeito a (2.1 - 2.5).

A função objetivo (2.6) busca diminuir o custo de deslocamento do caixeiro, enquanto a (2.7) visa aumentar o lucro.

Keller e Goodchild [13] apresentam uma abordagem para solucionar o MVP que consiste em resolver sequencialmente versões do problema com um único objetivo, tal tratamento não procura encontrar um conjunto de soluções não-dominadas.

3 ALGORITMOS MULTIOBJETIVOS

Um algoritmo multiobjetivo consiste em minimizar e/ou maximizar simultaneamente um conjunto de critérios (objetivos) satisfazendo restrições. Nesse contexto, na otimização multiobjetivo não é encontrado apenas uma solução que otimize todos os objetivos, mas uma variedade delas onde nenhuma solução é melhor que a outra solução em todos os objetivos, ou seja, soluções que não são dominadas por outras soluções. Essa variedade de soluções é chamada de soluções Pareto-ótimas.

Suponha A, B, C, D, E, F e G soluções de um problema de otimização com dois objetivos de minimização (f_1 e f_2), a Figura 3.1 ilustra uma possível relação de dominância entre elas.




Figura 3.1 - Dominância de Pareto.

Fonte: Arroyo [1]

As soluções E e F são maiores do que C nos dois objetivos e portanto, C domina estas soluções. Por outro lado, as soluções A e B são menores do que C em ambos objetivos e sendo assim, A e B dominam C.

3.1. Pareto Simulated Annealing (PSA)

O *Pareto Simulated Annealing* (PSA) [15] é um método multiobjetivo que utiliza-se de uma busca local probabilística.

O PSA inicia seu processo a partir de um conjunto de soluções iniciais aleatórias. Então, é criado um *loop* que gera aleatoriamente, para cada solução corrente x um único vizinho y .

No PSA existem três condições quando a nova solução y e a solução corrente x são comparadas :

- y domina ou é igual a x ,
- y é dominado por x ,
- y é não-dominado com relação à x (y é indiferente a x).

Na primeira situação, y domina ou é igual a x , então a nova solução y é aceita com probabilidade igual a 1. Na segunda situação, a nova solução é considerada pior que a solução corrente e é aceita com probabilidade menor que 1. Existem várias regras de agregação para tratar a terceira situação, a regra utilizada na implementação do algoritmo é a denominada regra SL que é interpretada como uma agregação local de todos os objetivos com uma função de escala linear. Tal regra é definida pela seguinte expressão:

$$P(x, y, T, \Delta) = \min \{1, \exp (-\sum_j \lambda_j (f_j(x) - f_j(y)/T))\} \quad (3.1)$$

Onde :

- T é a temperatura;
- x é a solução corrente;
- y é a nova solução gerada a partir de x ;
- $\Delta = (\lambda_1, \dots, \lambda_n)$ é o vetor de pesos; e
- f_j é a função objetivo j .

Primeiramente T assume um valor elevado T_0 e após certo número de iterações a temperatura decai gradativamente por uma razão de resfriamento α , tal que $T_k = \alpha * T_{k-1}$, onde $0 < \alpha < 1$.

Os vetores de pesos são primeiramente, gerados aleatoriamente e depois são modificados iteração por iteração. Para cada solução gerada existe um vetor de pesos associada a ela. Estes vetores permitem influenciar a direção da busca no espaço objetivo para uma solução gerada em particular. O vetor de pesos associados com cada solução gerada x é modificado na tentativa de aumentar a probabilidade de mover x na direção do vizinho mais próximo x' . Para isso é feito um incremento dos pesos quando x é melhor que x' e um decrementado dos pesos quando x é pior que x' .

O PSA efetua uma exploração da fronteira de Pareto, encontrando um grande número de solução eficientes (não dominadas), essa meta-heurística multiobjetiva, além de minimizar a distância do conjunto dominante encontrado ao conjunto Pareto-Ótimo, obtém uma boa distribuição das soluções no conjunto dominante gerado.

4 PARETO CLUSTERING SEARCH (PCS)

O método Busca por Agrupamentos (CS, do inglês, *Clustering Search*) [4] é um método híbrido que combina adequadamente meta-heurísticas e heurísticas de busca local. A busca é intensificada somente em regiões do espaço de busca que sejam consideradas promissoras. Este projeto propõe uma nova abordagem do CS, o PCS (*Pareto Clustering Search*) que possui a mesma proposta do CS, porém sob uma visão multiobjetivo.

O CS objetiva sofisticar o processo de escolha de soluções para aplicar busca local, ao invés de escolher aleatoriamente ou aplicar busca local em todas as soluções geradas por uma meta-heurística. Assim, espera-se uma melhoria no processo de convergência associado a uma diminuição no esforço computacional em virtude do emprego mais racional dos métodos de busca local.

O CS divide o espaço de busca e localiza regiões promissoras por meio do enquadramento dessas em *clusters*. Um *cluster* pode ser definido por três atributos, $C_i = (c_i, v_i, r_i)$, o centro c_i , o volume v_i e o índice de ineficácia r_i .

O centro c_i é uma solução que representa o *cluster* C_i , identificando a sua localização dentro do espaço de busca.

O volume v_i representa a quantidade de soluções agrupadas no *cluster* C_i . Um *cluster* se torna promissor quando o volume atinge certo limitante λ , definido *a priori*.

O índice de ineficácia r_i é uma variável de controle para indicar o número de vezes consecutivas que a busca local foi aplicada no *cluster* C_i e não melhorou a solução. Este atributo evita que a busca local fique sendo executada por mais de r_{max} vezes em regiões ruins ou regiões que já tenham sido suficientemente exploradas.

Para agrupar soluções em *clusters* define-se alguma forma de medir a distância entre duas soluções. Sendo assim, uma função de medida de distância $d(i, j)$ é definida para calcular a distância entre duas soluções.

O CS é um método iterativo que possui três componentes principais: uma meta-heurística, um processo de agrupamento e um método de busca local. A cada iteração do CS, uma solução s_k é gerada pela meta-heurística e enviada para o processo de agrupamento, então s_k é agrupada no *cluster* mais similar C_j , que é o *cluster* mais próximo à solução s_k . E, o centro deste *cluster* (c_j) é atualizado com informações contidas na nova solução agrupada por meio do processo de assimilação, fazendo com que o centro se desloque no espaço de busca.

Em seguida é analisado o volume v_j do *cluster*. Caso v_j tenha atingido um limitante λ definido a priori, esse *cluster* pode estar em uma região de busca promissora. Porém, se o método de busca local não tiver obtido sucesso nas últimas r_{max} aplicações neste *cluster* promissor (índice de ineficácia $r_j \geq r_{max}$) é aplicada uma perturbação aleatória no centro c_j , objetivando escapar desta região do espaço de busca.

Porém, se r_j for menor que r_{max} , uma busca local é aplicada no centro c_j intensificando a busca na vizinhança do *cluster*. A busca obtém sucesso em um *cluster* quando encontra uma solução que seja a melhor obtida neste *cluster* até o momento .

Depois do processo de agrupamento, retorna-se para a meta-heurística que gera outra solução. O critério de parada do CS é dado pelo critério de parada da meta-heurística utilizada na geração de soluções.

A estratégia híbrida do método CS para um problema de minimização é descrita pelo fluxograma ilustrado na Figura 4.1.

O método *Pareto Clustering Search* (PCS), proposto neste trabalho, é uma variação do CS para a solução heurística do problema sob a visão multiobjetivo. Neste trabalho, o PCS inicia sua busca por soluções através da meta-heurística multiobjetivo *Pareto Simulated Annealing* (PSA) descrito no capítulo anterior.

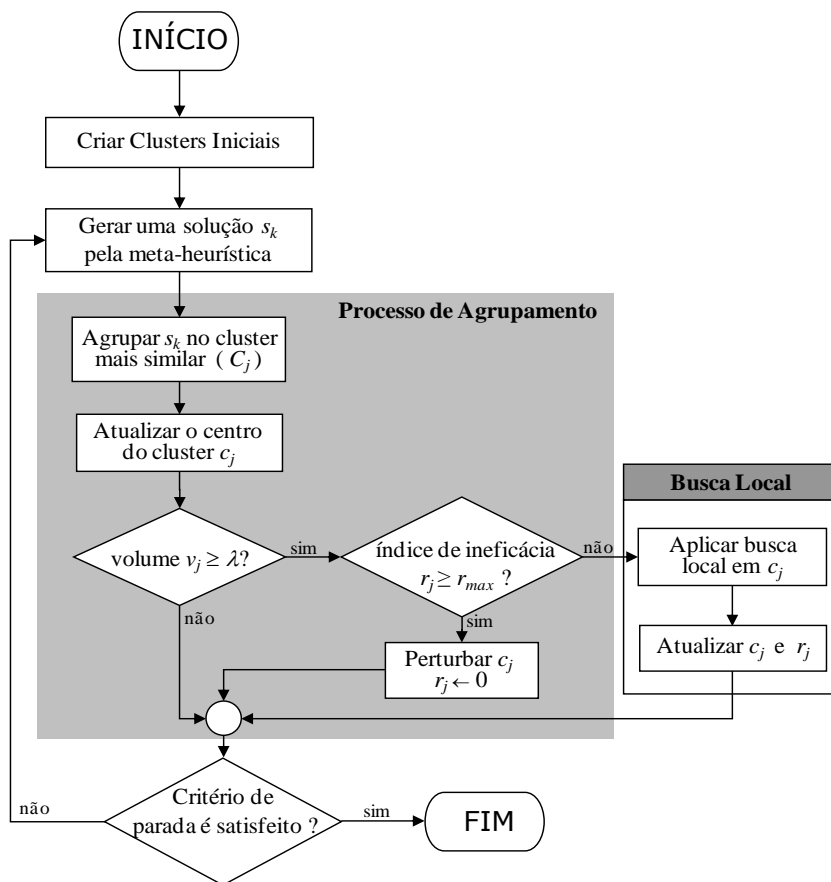


Figura 4.1 - Fluxograma do método CS.

Fonte: Chaves e Lorena [4]

O PCS possui o mesmo processo que o CS, porém utiliza a meta-heurística multiobjetivo PSA e os *clusters* representam a fronteira de Pareto. Além disso, os métodos de busca local são multiobjetivos.

O PCS cria os clusters iniciais como sendo um conjunto de Pareto, em seguida as soluções geradas pela meta-heurística PSA são agrupadas no *cluster* mais próximo, de acordo com uma medida de distância entre funções objetivo.

Assim que um *cluster* se torna promissor é aplicada uma heurística de busca local multiobjetivo, visando encontrar soluções que sejam não dominadas. O PCS é responsável por controlar a fronteira de Pareto, criando novos *clusters* com soluções não dominadas desde que não sejam similares às soluções já existentes e eliminando *clusters* com soluções que se tornem dominadas.

5 APLICAÇÃO DO PCS AO MVP

O *Pareto Clustering Search* (PCS) foi aplicado ao *Multiobjective Vending Problem* (MVP) criando-se uma estrutura para representar as soluções geradas, tal estrutura contém o valor da função denominada f_{01} cujo objetivo é minimizar o custo de deslocamento e da função f_{02} que visa aumentar o lucro. Além disso, essa estrutura contém um vetor contendo as cidades visitadas pelo caixeiro e outro vetor com as cidades que não foram visitadas.

Suponha uma rota que contenha as cidades 1,2,3,4 e 5, cada uma com seu prêmio específico. A Figura 5.1 ilustra a representação de uma possível solução para este problema.

Cidades visitadas :	1	3	4
Cidades não visitadas :	2	5	
$f_{01} = 1348$			
$f_{02} = 507$			

Figura 5.1 - Representação da solução.

Neste exemplo, o caixeiro visitou as cidades 1,3 e 4, a soma dos prêmios coletados, dado pela f_{02} , foi de 507, e o custo da viagem, dado pela f_{01} , foi 1348.

O PCS retorna uma série dessas soluções, cujas funções objetivos são não dominadas entre si. Esse conjunto de soluções representa a fronteira de Pareto.

O PSA foi utilizado como gerador de soluções no PCS, as estruturas de vizinhanças do PSC aplicado ao MVP foram empregadas no PSA e são definidas através dos seguintes movimentos:

- Inserir um vértice que não está sendo visitado;
- Retirar um vértice que está sendo visitado;
- Trocar 2 vértices que estão sendo visitados de posição.

O método de busca local utilizado para intensificar a busca do centro do *cluster* é chamado Descida em Vizinhança Variável (VND, do inglês *Variable Neighborhood Descent*) [14]. O VND é composto por três diferentes heurísticas de refinamento: *2-Opt*, *Add-step* e *Drop-step*.

A heurística *2-Opt* consiste na troca entre pares de aresta do grafo. Removem-se duas arestas, quebrando o circuito em dois caminhos, e os reconecta de outra maneira. O objetivo do *2-Opt* é reduzir a distância entre os vértices por meio da substituição de arestas de maior custo por outras de menor custo.

A heurística *Add-step* consiste em adicionar o vértice que possuir o melhor valor de economia de inserção, se o valor da economia for positivo então ambas funções objetivo irão melhorar após o movimento.

O movimento *Drop-step* consiste em retirar o vértice que possuir o melhor valor de economia de remoção, se o valor da economia for positivo então a função objetivo responsável por minimizar a distância irá melhorar após o movimento.

O principal aspecto a ser observado é que todos os movimentos são executados preservando a viabilidade da solução.

Para atualizar os centros dos *clusters*, utiliza-se o método Reconexão por Caminhos (PR, do inglês *Path-Relinking*). O PR realiza movimentos exploratórios na trajetória que interconecta duas soluções. Assim sendo, o processo de assimilações é responsável por intensificar e diversificar a busca dentro de um *cluster*, pois o centro será deslocado para a melhor solução avaliada nessa trajetória.

O PR inicializa a partir de duas soluções. A primeira é o centro do *cluster* mais similar (s_i). A segunda é a solução gerada pela meta-heurística (s_g). O método inicializa calculando a diferença simétrica entre as duas soluções, que é o conjunto de movimentos necessários para alcançar s_g a partir de s_i . Um caminho de soluções é gerado, conectando s_i e s_g . O método termina quando a

solução s_g for alcançada ou quando uma porcentagem do caminho for analisada. A melhor solução neste caminho é o novo centro do *cluster*.

6 RESULTADOS

O PCS para o MVP foi codificado em C++ e os experimentos foram conduzidos em um PC com processador Intel core i5, 2.5 GHz e memória de 6 GB de RAM sob plataforma *Windows 7*. Os experimentos foram realizados com objetivo de validar a abordagem proposta, mostrando que o PCS pode ser competitivo para resolução de problemas multiobjetivos. Para testar o modelo proposto foi utilizada a instâncias-teste *burma14_100_100*, *att48_100_100*, *berlin52_100_100* e *ulysses22_100_100* que podem ser encontradas em <http://www.sjc.unifesp.br/docente/chaves/problem-instances>. Visando verificar a eficiência do PCS, fez-se a comparação das soluções obtidas somente através da meta-heurística PSA e das soluções dadas pelo PCS. Os gráficos apresentado na Figura 6.1 mostra estas soluções. O eixo das abscissas representa o custo de deslocamento. O eixo das coordenadas representa a quantidade de prêmios coletados.




Figura 6.1 - Gráficos de comparação PSA e PCS.

A Tabela 6.1 apresenta os melhores e piores tempos computacionais obtidos em 10 execuções do PSA e PCS.

Tabela 6.1- Tempo de execução PSC e PSA

<i>Instâncias teste</i>	PSA		PCS	
	<i>Tempo mínimo</i>	<i>Tempo máximo</i>	<i>Tempo mínimo</i>	<i>Tempo máximo</i>
burma14	310,40 segundos	323,47 segundos	305,21 segundos	323,12 segundos
att48	308,02 segundos	318,53 segundos	302,42 segundos	319,401 segundos
berlin52	315,35 segundos	330,53 segundos	303,96 segundos	327,52 segundos
ulysses22	303,34 segundos	312,75 segundos	303,73 segundos	311,43 segundos

Nota-se que as soluções geradas pelo PCS possuem maiores valores para o lucro (fo_2 , eixo das coordenadas) e menores valores para o custo da viagem (fo_1 , eixo das abscissas) do que as soluções geradas pelo PSA e portanto o PCS gera soluções significativamente melhores que o somente PSA. Além disso, as soluções geradas pelos dois métodos possuem uma boa distribuição na fronteira de Pareto . Para a comparação entre os métodos ser justa, o tempo de execução de ambos algoritmos foi configurado de forma que executassem o algoritmo por pelo menos um determinado número de segundos.

7 CONCLUSÃO

Este trabalho propõe uma abordagem heurística, utilizando a meta-heurística *Pareto Clustering Search* (PCS), para a resolução do Problema do Vendedor com Multiobjetivos (MVP). Esta meta-heurística utiliza o conceito de algoritmos híbridos, combinando meta-heurísticas com um processo de agrupamento de soluções em subespaços de busca (*clusters*), visando detectar regiões promissoras. Sempre que uma região for considerada promissora é realizada uma intensificação da busca nesta região, objetivando uma aplicação mais racional do método de busca local.

Através dos testes realizados percebe-se que o algoritmo proposto é capaz de encontrar um conjunto de soluções eficientes para o problema em estudo.

Para trabalhos futuros pretende-se aplicar o PCS em problemas com maior quantidade de objetivos, e também utilizar outra meta-heurística clássica sob visão multiobjetivo para gerar soluções, tal como o algoritmo genético.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ARROYO, J.E.C. Heurísticas e Meta-heurísticas para Otimização Combinatória Multiobjetivo, p. 7-21, 2002.
- [2] AWERBUCH, B.; AZAR, Y.; Blum, A.; VEMPALA, S. (1998), New approximation guarantees for minimum weight k-trees and prize-collecting salesmen. *SIAM Journal on Computing*, v. 28, n. 1, p. 254–262.
- [3] BALAS, E. (1989), The prize collecting traveling salesman problem. *Networks*, v. 19, p. 621–636.
- [4] CHAVES, A. A., LORENA, L. A. N. Clustering search algorithm for the capacitated centred clustering problem, *Computers & Operations Research*, v. 37, 552-558, 2009.
- [5] CZYZAK P., JASZKIEWICZ A. Pareto Simulated Annealing – a metaheuristic technique for multiple objective combinatorial optimization. *Journal of Multi-Criteria Decision Analysis*, v. 7, 34-47, 1998.
- [6] DELL'AMICO, M.; MAFFIOLIaffioli, F.; VARBRAND, P. (1995), On prize collecting tours and the asymmetric travelingsalesman problem. *International Transactions in Operational Research*, v. 2, n. 3, p. 297–308.
- [7] FEILLET, D.; DEJAX, P.; GENDREAU, M. Traveling salesman problems with profits. *Transportation Science*, v. 2, n. 39, p. 188-205, 2005.
- [8] FONSECA C.M, FLEMING P.J. Multiobjective Genetic Algorithms made easy: Selection, Sharing and Matinig restrictions. In *First International Conference on Genetic Algorithms in Engineering Systems: Innovations and Applications (GALESIA 95)*, London, UK, pp. 45-52. The Institution of Electrical Engineers, 1995.
- [9] GLOVER, F. Tabu search and adaptive memory programing: advances, applications and challenges. In: BARR, R. S.; HELGASON., R. V.; KENNINGTON, J. L. (Ed.). *Interfaces in Computer Science and Operations Research*. Norwell: Kluwer, p. 1-75, 1996.
- [10] HOLLAND, J. H. Adaptation in natural and artificial systems. Michigan: University of Michigan Press, 1975. 211 p.
- [11] JASKIEWICZ A. Genetic local search for multi-objective combinatorial optimization, *European Journal of Operational Research* vol.137, p. 50-71, 2002.
- [12] JONES D.F., MIRRAZAVI S.K. e TAMIZ M. Multi-objective meta-heuristics: An overview of the current state-of-art, *European Journal of Operational Research* vol.137, p. 1-19, 2002.
- [13] KELLER, C.P.; Goodchild, M., The multiobjective vending problem: A generalization of the traveling salesman problem. *Environment and Planning B: Planning and Design*, v. 15, p. 447–460, 1988.
- [14] MLADENOVIC, N.; HANSEN, P. (1997), Variable neighborhood search. *Computers and Operations Research*, v. 24, p. 1097–1100.

- [15] PEREIRA, G.W. Aplicação da Técnica de Recozimento Simulado em Problemas de Planejamento Florestal Multiobjetivo, 2004.
- [16] REINELT, G., *Traveling Salesman : Computational Solutions for TSP Applications*. Springer: Lecture Note in Computer Science, 1994.
- [17] TSILIGIRIDES, T. (1984), Heuristic methods applied to orienteering. *Journal of Operational Research Society*, v. 35, n. 9, p. 797–809.
- [18] ULUNGU E.L., TEGHEM J. e OST C. Efficiency of interactive multi-objective simulated annealing through a case study”, *Journal of the Operational Research Society*, vol.49, p. 1044-1050, 1998.
- [19] VAN VELDHUIZEN D.A., LAMONT G.B. Multiobjective evolutionary algorithms: Analysing the state-of art, *Evolutionary Computation*, vol. 8(2), p. 125-147, 2000.