



AUTORES AUTHORS	PALAVRAS CHAVES/KEY WORDS		AUTORIZADA POR/AUTHORIZED BY
	P-MEDIANAS RELAXAÇÃO LAGRANGEANA "BRANCH AND BOUND"		<i>Ralf Gielow</i> Ralf Gielow Pres. Cons. Pós-Graduação

AUTOR RESPONSÁVEL RESPONSIBLE AUTHOR	DISTRIBUIÇÃO/DISTRIBUTION	REVISADA POR / REVISED BY
<i>Hilcêa Ferreira Marengoni</i> Hilcêa Ferreira Marengoni	<input type="checkbox"/> INTERNA / INTERNAL <input checked="" type="checkbox"/> EXTERNA / EXTERNAL <input type="checkbox"/> RESTRITA / RESTRICTED	<i>Luiz Antonio N. Lorena</i> Luiz Antonio N. Lorena

CDU/UDC	DATA / DATE
519.688	Setembro 1989

TÍTULO/TITLE	PUBLICAÇÃO Nº PUBLICATION NO INPE-4924-IDL/384		ORIGEM ORIGIN
	UM ALGORITMO EXATO PARA O PROBLEMA DAS P-MEDIANAS		PG/CPD
PROJETO PROJECT			
AUTORES/AUTHORSHIP	Hilcêa Ferreira Marengoni		FRH/ANS
			Nº DE PAG. NO OF PAGES
		109	A.24
		VERSÃO VERSION	Nº DE MAPAS NO OF MAPS

RESUMO - NOTAS / ABSTRACT - NOTES

Este trabalho descreve o estudo de alguns métodos exatos e heurísticos para resolver o problema das p-medianas. Em particular enfoca um algoritmo exato baseado em uma formulação de programação inteira do problema. Um algoritmo do tipo "branch and bound" é utilizado e os limitantes são obtidos através da relaxação lagrangeana do problema usando um método de otimização por subgradientes. Uma estrutura de dados explorando a estrutura matricial do problema é desenvolvida e a implementação é feita em microcomputadores tipo IBM-PC.

OBSERVAÇÕES / REMARKS

Dissertação de Mestrado em Análise de Sistemas e Aplicações, aprovada em 02 de junho de 1989.

INSTITUTO DE PESQUISAS ESPACIAIS

DISSERTAÇÃO

UM ALGORITMO EXATO PARA O PROBLEMA DAS P-MEDIANAS

SUBMETIDA POR

Hilcêa Ferreira Marengoni

Em cumprimento parcial dos requisitos exigidos para obtenção do título
de Mestre em Análise de Sistemas e Aplicações

1989

Aprovada pela Banca Examinadora
em cumprimento a requisito exigido
para a obtenção do Título de Mestre
em Análise de Sistemas e Aplicações

Dr. Paulo Renato de Moraes



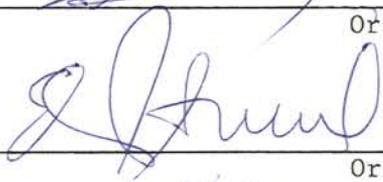
Presidente

Dr. Luiz Antonio Nogueira Lorena



Orientador

Dr. Edson Luiz França Senne



Orientador

Dr. Edgard Dias Batista Jr.



Membro da Banca
- convidado -

Candidata: Hilcéa Ferreira Marengoni

São José dos Campos, 02 de junho de 1989

Ao Maurício que, com apoio, carinho e incentivo, muito contribuiu para a realização deste trabalho.

AGRADECIMENTOS

Ao INPE, Instituto de Pesquisas Espaciais, pela oportunidade de concretização deste trabalho.

Ao pesquisador Acioli Antônio de Olivo, Msc. pelo incentivo, apoio e primeira orientação.

Aos Drs. Luiz Antônio Nogueira Lorena e Edson Luiz França Senne pela orientação e principalmente pela atenção que sempre me dispensaram.

A todos que direta ou indiretamente colaboraram na realização deste trabalho.

RESUMO

Este trabalho descreve o estudo de alguns métodos exatos e heurísticos para resolver o problema das p -medianas. Em particular enfoca um algoritmo exato baseado em uma formulação de programação inteira do problema. Um algoritmo do tipo "branch and bound" é utilizado e os limitantes são obtidos através da relaxação lagrangeana do problema usando um método de otimização por subgradientes. Uma estrutura de dados explorando a estrutura matricial do problema é desenvolvida e a implementação é feita em micro-computadores tipo IBM-PC.

ABSTRACT

This work reports a study of a few heuristic and exact methods for solving the p -median problem. It particularly covers an exact algorithm based on an integer programming formulation of the problem. A "branch and bound" algorithm is presented and the bounds are obtained by solving the lagrangean relaxation and using the subgradient optimization method. A data structure that takes into account the matricial character of the problem is developed and the algorithm is implemented to run on a IBM-PC micro-computer.

SUMÁRIO

	<u>Pág.</u>
LISTA DE TABELAS	xi
<u>CAPÍTULO 1 - INTRODUÇÃO</u>	1
<u>CAPÍTULO 2 - REVISÃO BIBLIOGRÁFICA</u>	3
2.1 - Definição do problema	3
2.2 - Histórico	5
2.2.1 - Método de Enumeração	6
2.2.2 - Métodos Heurísticos	12
2.2.3 - Métodos exatos e programação matemática	20
<u>CAPÍTULO 3 - ALGORITMO PROPOSTO</u>	33
3.1 - Introdução	33
3.2 - Algoritmo de subgradientes	33
3.3 - Algoritmo de Branch and Bound	38
<u>CAPÍTULO 4 - IMPLEMENTAÇÃO E TESTES</u>	45
4.1 - Introdução	45
4.2 - Descrição dos Testes	47
4.3 - Apresentação dos resultados	49
<u>CAPÍTULO 5 - COMENTÁRIOS FINAIS</u>	57
REFERÊNCIAS BIBLIOGRÁFICAS	59
APÊNDICE A - LISTAGEM DO PROGRAMA	

LISTA DE TABELAS

	<u>Pág.</u>
4.1 - Teste 1	51
4.2 - Teste 2	53
4.3 - Teste 3	54
4.4 - Teste 4	54
4.5 - Teste 5	55

CAPÍTULO 1

INTRODUÇÃO

A determinação das p-medianas de uma rede é um problema clássico de localização. O seu objetivo é achar p nós - chamados de medianas da rede - que minimizem a soma das distâncias entre cada nó e sua mediana mais próxima.

Um grande número de algoritmos (exatos e heurísticos) tem sido desenvolvido para a solução do problema das p-medianas (PPM). Alguns autores tentaram resolver o problema através de procedimentos heurísticos; houve aqueles que usaram algoritmos do tipo "branch and bound". Mais recentemente, surgiram abordagens baseadas em Programação Linear Inteira usando relaxação lagrangeana combinada com um método de otimização por subgradientes. Beasley(1985) combinando um método de subgradientes e um procedimento de busca em árvores ("branch and bound"), conseguiu resolver problemas com até 900 nós graças ao emprego do super computador de processamento vetorial CRAY-1S.

O objetivo deste trabalho é fazer um estudo do problema e dos métodos (heurísticos e exatos) existentes para sua resolução. Espera-se obter um algoritmo para resolução exata do problema e desenvolver uma estrutura de dados que explore a estrutura matricial do problema, para implementação em micro-computadores do tipo IBM-PC. Portanto, não se tem a pretensão de resolver problemas da dimensão daqueles resolvidos por Beasley(1985).

Inicialmente, no segundo capítulo, faz-se a definição formal do problema e são citadas algumas de suas aplicações mais comuns. Posteriormente, é feito um relato detalhado sobre algumas abordagens importantes na consolidação do PPM.

No Capítulo 3, apresenta-se o algoritmo usado para resolver o problema.

No Capítulo 4 descrevem-se a implementação do algoritmo e os testes realizados, sendo apresentados, no Capítulo 5, os comentários finais.

CAPÍTULO 2

REVISÃO BIBLIOGRÁFICA

2.1 - DEFINIÇÃO DO PROBLEMA

Uma questão que normalmente aparece nos sistemas de distribuição industrial é a localização de armazéns, fábricas ou outras facilidades numa rede, comumente referido como Problema de Localização de Armazéns (PLA). O problema que vai ser tratado, conhecido na literatura como das P-MEDIANAS (PPM), é uma versão do PLA que consiste em localizar p facilidades (medianas) em uma rede tal que seja minimizada a soma das distâncias entre cada nó e sua mediana mais próxima.

O PPM pode ser formulado como o seguinte problema (P) de programação inteira zero-um:

$$\text{MIN } Z = \sum_{i=1}^n \left(\sum_{j=1}^n d_{ij} x_{ij} \right) \quad (2.1)$$

$$\text{Sujeito a: } \sum_{i=1}^n x_{ij} = 1, \quad j = 1, 2, \dots, n; \quad (2.2)$$

$$\sum_{i=1}^n x_{ii} = p; \quad (2.3)$$

$$x_{ij} \leq x_{ii}; \quad (2.4)$$

$$x_{ij} \in \{0,1\} \quad i, j = 1, 2, \dots, n \quad (2.5)$$

onde (d_{ij}) é qualquer matriz não negativa com $d_{ii} = 0$ para todo i ; (x_{ij}) é uma matriz de alocações onde $x_{ij} = 1$ se o nó j está alocado ao nó i e $x_{ij} = 0$ caso contrário; $x_{ii} = 1$ significa que o nó i é mediano (uma facilidade está localizada nele), $x_{ii} = 0$ caso contrário; p é o número de medianas (facilidades) a serem localizadas na rede e n é o número total de nós da rede. Considera-se V como o conjunto de todos os nós (qualquer nó pode ser uma mediana).

As restrições (2.2) e (2.4) garantem que cada nó j é alocado somente a um único nó i que, por sua vez, precisa ser uma mediana, isto é, $x_{ii} = 1$. A restrição (2.3) determina o número exato de medianas que devem ser localizadas (p) e a (2.5) impõe a integralidade.

Os problemas de localização de facilidades em uma rede são variados e usualmente complexos. Dentre os critérios de otimização utilizados, um é o de minimizar a soma total das distâncias percorridas.

Em estatística, um problema de agrupamento ("Clustering") de observações em grupos homogêneos possui uma formulação idêntica ao problema de localização de medianas em uma rede. Kusiak et al. (1985) desenvolveram três formulações distintas usando programação inteira e cobrindo variações do problema tais como: fixação do número de "clusters" e restrição quanto ao número de elementos dentro de cada "cluster".

O problema descrito que incorpora a restrição quanto ao número de "clusters" possui formulação idêntica a (P), onde n é o número de elementos, p é o número requerido de "clusters", d_{ij} é a distância do elemento i ao elemento j ($d_{ij} \geq 0$ para qualquer $i \neq j$, $i, j = 1, 2, \dots, n$ e $d_{ii} = 0$ para qualquer que seja $i = 1, 2, \dots, n$), $x_{ij} = 1$ se o i -ésimo elemento pertence ao j -ésimo "cluster" e $x_{ij} = 0$ caso contrário. A função objetivo é minimizar a soma total das distâncias de cada "cluster" para o seu mediano. Kusiak et al. (1985) desenvolveram

técnicas heurísticas, empregando Lagrangeano e autovetores, para resolver o problema.

Um outro problema importante que ocorre frequentemente em estatística envolve a determinação de limites para estratos a serem usados em amostragem estratificada. Mulvey (1983) descreve um método prático para estratificação de uma população de observações baseado em análise ótima de "clusters". O objetivo da estratificação é construir uma partição tal que observações dentro de um estrato sejam homogêneas. O problema é definido como um modelo de otimização determinístico com variáveis inteiras cuja formulação é bastante semelhante a do PPM.

2.2 - HISTÓRICO

A seguir, serão apresentados, de forma sintética, alguns algoritmos importantes na consolidação do PPM. A maior parte das provas será omitida pois elas escapam do escopo deste trabalho. Entretanto, as referências apropriadas estão indicadas, de tal forma que os interessados podem examinar em detalhes qualquer dos algoritmos apresentados. Em alguns algoritmos apresentam-se exemplos numéricos para ilustrar os passos do algoritmo (é importante ressaltar que nestes casos o objetivo é apenas ilustrar, portanto não se pretende chegar à solução ótima).

As abordagens na resolução do PPM serão classificadas, neste trabalho, em três categorias: (1)método de enumeração, (2)métodos heurísticos e (3)métodos exatos e programação matemática baseada no primal e dual. Para localização de uma única facilidade, ou quando a rede é pequena, os métodos de enumeração fornecem um procedimento manual para ilustrar o conceito de localização de p-medianas e partição do conjunto de nós em p subconjuntos. Procedimentos heurísticos iterativos baseiam-se em métodos intuitivos de tentativa e erro e não podem garantir uma solução ótima, mas podem ser aplicados a qualquer estrutura geral de redes, fornecendo boas soluções (próximas do ótimo). Os métodos exatos englobam procedimentos

do tipo "branch and bound" e as abordagens de programação matemática são baseadas em uma formulação de programação inteira do PPM. Estas últimas têm atraído muita atenção e têm provado sucesso razoável para redes gerais. O PPM pode ser formulado como um problema de programação inteira e resolvido através de algoritmos baseados no primal e dual do PPM.

2.2.1 - MÉTODO DE ENUMERAÇÃO

O problema mediano mais simples em uma rede é o da determinação de uma única facilidade de tal forma que seja minimizada a média das distâncias.

Hakimi (1964) foi o primeiro a examinar este problema preocupando-se basicamente com duas questões: encontrar a localização ótima dos centros de ligação em uma rede de comunicação e localizar o melhor lugar para construir uma estação policial em um sistema de estradas. O problema da rede de comunicação pode ser descrito como um sistema de interconexão de telefones onde existe, normalmente, um centro de ligação S que recebe todo o tráfego de mensagens e o distribui para seu destino. Um modelo para este sistema pode ser considerado como um grafo finito ponderado G cujos pesos (números não-negativos) estão ligados aos vértices e ramificações da rede. O peso w_i que é ligado ao ramo b_i representa o tamanho (ou custo por unidade) daquele elemento. O peso h_i ligado ao vértice v_i de G representa o número de linhas que devem ser conectadas entre o vértice v_i e o centro de ligação S para manipular o fluxo de informação que tanto se origina como termina em v_i . O problema é encontrar a localização exata do centro de ligação S tal que, o tamanho total das linhas seja mínimo.

O problema de localização ótima da estação policial é de certa forma similar. Hakimi (1964) considerou um número de comunidades de diferentes tamanhos que estão interconectadas por um sistema de estradas. O objetivo é encontrar a localização da estação policial P tal que a distância máxima até P seja mínima.

Da discussão acima fica claro que os conceitos teóricos usuais de grafos para centros e medianas não podem ser usados.

Hakimi (1964) definiu, então, um grafo G e um ponto x em G que pode estar sobre algum ramo de G e ser ou não um vértice de G . A distância entre quaisquer dois pontos x e y em G , representada por $d(x,y)$, é o tamanho de um caminho mais curto em G entre os pontos x e y , onde o tamanho de um caminho é a soma das distâncias multiplicadas pelos pesos dos ramos do caminho.

Definiu-se um ponto x_0 , de um grafo ponderado G , como sendo um centro absoluto de G , se para todo ponto x em G :

$$\text{MAX } \sum_{i=1}^n h_i d(v_i, x_0) \leq \text{MAX } \sum_{i=1}^n h_i d(v_i, x), \quad \forall x \quad (2.6)$$

Similarmente, definiu-se um ponto y_0 em G como sendo mediana absoluta de G , se para todo ponto y em G :

$$\sum_{i=1}^n (h_i d(v_i, y_0)) \leq \sum_{i=1}^n (h_i d(v_i, y)), \quad \forall y \quad (2.7)$$

A mediana absoluta do grafo deve ser identificada com a localização ótima do centro de ligação na rede de comunicação, e o centro absoluto deve ser identificado com a localização ótima da estação policial no sistema de estradas.

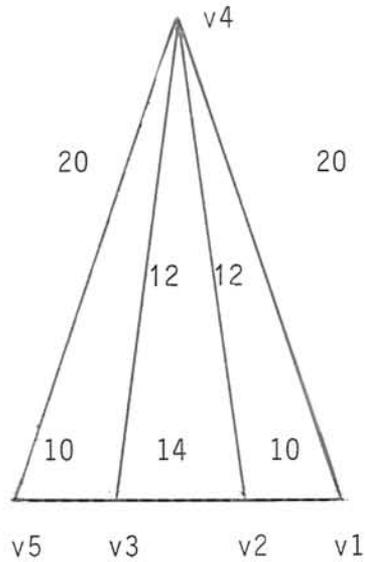
Finalmente Hakimi (1964) demonstrou um teorema que é de grande valia para estudos posteriores do PPM:

"Uma mediana absoluta de um grafo é sempre um vértice do grafo"

Então, concluiu-se que, encontrar a localização ótima em um centro de ligação de uma rede de comunicação pode se limitar a encontrar o vértice mediano do grafo correspondente. E para o problema

da localização da estação policial deve-se encontrar o centro absoluto do grafo correspondente.

Para ilustração, seja o grafo abaixo:



A matriz de distâncias deste grafo é:

$$D = \begin{bmatrix} 0 & 10 & 24 & 20 & 34 \\ 10 & 0 & 14 & 12 & 24 \\ 24 & 14 & 0 & 12 & 10 \\ 20 & 12 & 12 & 0 & 20 \\ 34 & 24 & 10 & 20 & 0 \end{bmatrix}$$

É facilmente determinado que $v4$ é o centro absoluto do grafo, pois:

$$\text{MAX } (d(v_i, v_j)) = \text{MAX } (d(v1, v_j)) = 34 = d(v1, v5)$$

$$\text{MAX } (d(v2, v_j)) = 24 = d(v2, v5)$$

$$\text{MAX } (d(v_3, v_j)) = 24 = d(v_3, v_1)$$

$$\text{MAX } (d(v_4, v_j)) = 20 = d(v_4, v_1) = d(v_4, v_5)$$

$$\text{MAX } (d(v_i, v_j)) = 34 = d(v_5, v_1)$$

$$\text{MIN } [\text{MAX } (d(v_i, v_j))] = d(v_4, v_1) = d(v_4, v_5)$$

Também tem-se que v_2 e v_3 são duas chances possíveis de medianas no grafo, pois:

$$\sum_{i=1}^n d(v_1, v_i) = 88$$

$$\sum_{i=1}^n d(v_2, v_i) = 60$$

$$\sum_{i=1}^n d(v_3, v_i) = 60$$

$$\sum_{i=1}^n d(v_4, v_i) = 64$$

$$\sum_{i=1}^n d(v_5, v_i) = 88$$

Em uma publicação seguinte Hakimi (1965) generalizou o conceito de mediana, em um grafo ponderado, para multi-medianas e apresentou um procedimento simples de enumeração. O problema tratado pode ser descrito assim: em uma rede de comunicação N , como em um sistema de interconexão de telefones, existe usualmente um número de centros de ligação $S_1, S_2, S_3, \dots, S_p$; todo fluxo de mensagens que passa dentro da rede deve chegar até um centro de ligação para então ser processado e enviado à seu destino; assume-se que o custo para manter as ligações é desprezível. Este problema pode ser modelado através de um grafo ponderado G cujos pesos w_i (tamanho ou custo por

unidade de cada ramo) e h_i (número de linhas que devem ser conectadas entre o vértice v_i e o centro de ligação para permitir o fluxo de informações) estão ligados aos ramos e nós de G respectivamente.

Assumiu-se que qualquer centro de ligação pode estar em qualquer lugar sobre o ramo de G , isto é, a localização do centro de ligação não é necessariamente limitada aos vértices de G . O problema é encontrar a distribuição dos centros de ligação S_1, S_2, \dots, S_p tal que o tamanho total das linhas seja mínimo (distribuição ótima dos centros de ligação).

Seja um grafo ponderado G . Um ponto x em G é um ponto sobre o ramo b_i de G que pode ou não ser um vértice de G . A distância entre quaisquer dois pontos x e y em G , denotada por $d(x,y)$, é o tamanho do caminho mais curto em G entre os pontos x e y , onde o tamanho do caminho é a soma dos pesos dos ramos do caminho. Seja X_p o conjunto de p pontos x_1, x_2, \dots, x_p em G e seja

$$d(v_i, X_p) = \text{MIN} [d(v_i, x_1), d(v_i, x_2), \dots, d(v_i, x_p)]$$

O conjunto de pontos X_p^* é uma mediana de G para todo X_p em G se:

$$\sum_{i=1}^n (h_i d(v_i, X_p^*)) \leq \sum_{i=1}^n (h_i d(v_i, X_p))$$

onde h_i é o peso ligado ao vértice v_i em G .

Claramente o conjunto de pontos X_{p^*} pode ser identificado como localização ótima dos centros de ligação numa rede de comunicação. Hakimi (1965) não apresenta um procedimento para encontrar X_{p^*} . Mas, por outro lado, demonstra um teorema que é o principal passo nesta direção:

"Existe um subconjunto V_{p^*} de V contendo p vértices tal que para todo conjunto de p pontos X em G :

$$\sum_{i=1}^n (h_i d(v_i, X)) \geq \sum_{i=1}^n (h_i d(v_i, V_{p^*}))"$$

O teorema acima prova que para encontrar as p -medianas deve-se enumerar todos os subconjuntos de V contendo p vértices e examinar as somas. Esta técnica de enumeração parece razoável para n não muito grande, já que o número de subconjuntos possíveis é $C_{n,p}$, onde:

$$C_{n,p} = \frac{n!}{p! (n-p)!}$$

2.2.2 - MÉTODOS HEURÍSTICOS

Vários procedimentos heurísticos foram bem sucedidos na resolução do PPM. Alguns deles são usados para gerar soluções iniciais boas e/ou regras de decisão na escolha de nós, que ajudem na obtenção de convergência mais rápida de algoritmos usando programação matemática.

Um dos primeiros procedimentos heurísticos para o PPM foi desenvolvido por Maranzana (1964). Ele considerou o problema de localização ótima de pontos de abastecimento (estabelecimentos comerciais e fábricas para servir fregueses distribuídos em uma rede de cidades) com relação aos custos de transporte. Se os custos de transporte são uniformes e lineares com relação à distância, o custo total de transporte é proporcional a soma das distâncias entre os pontos de abastecimento até as cidades servidas, cada uma ponderada pelo volume de remessa. Sempre é considerado o caminho mais curto de um nó para outro (assume-se que existe algum caminho conectando todos os pares de nós da rede).

Um nó no qual um ponto de abastecimento está localizado é chamado fonte e um nó que possui uma demanda a ser satisfeita é referenciado como destino.

Em termos matemáticos tem-se o seguinte problema:

Dados um conjunto P de n pontos p_1, p_2, \dots, p_n , um conjunto de pesos associados w_1, w_2, \dots, w_n e uma matriz de distâncias não-negativa, n -dimensional e simétrica $[d_{ij}]$, quer-se encontrar p fontes, (p_1, p_2, \dots, p_p) e uma partição associada de P em p subconjuntos de destinos (P_1, \dots, P_p) servidos respectivamente pelas p fontes, tais que:

$$\sum_{i=1}^n \sum_{P_j \in P_j} D_{i,j} w_j \quad (2.8)$$

seja mínima, onde D_{ij} é a distância mínima entre p_i e p_j .

O custo do transporte é proporcional à soma (2.8).

Segue-se uma rápida descrição do método iterativo proposto por Maranzana que pode ser aplicado a uma seleção inicial de p pontos de abastecimento para produzir, sucessivamente, seleções melhores.

O algoritmo começa com uma seleção arbitrária de p fontes (p_{x1}, \dots, p_{xp}) e partição da rede em subconjuntos $(\{P_{x1}, \dots, P_{xp}\})$ onde $P_{xi} = \{p_k; D_{k,xi} \leq D_{k,xj} \text{ p/todo } j\}$ a serem servidos por estas fontes. Isto é acompanhado pela associação de cada ponto com sua fonte mais próxima. Depois, o centro de gravidade de cada conjunto na partição é determinado e as fontes originais são substituídas por estes pontos. Este processo é repetido até que as fontes não mudem mais. Considera-se p_j um centro de gravidade de $Q \subseteq P$ se:

$$\sum_{p_k \in Q} D_{j,k} w_k < \sum_{p_k \in Q} D_{i,k} w_k \quad \text{para todo } i$$

Segue o seguinte exemplo. Seja a matriz de distâncias para um problema com $n = 6$ e $p = 2$. Suponha-se que os pesos já estão devidamente associados na matriz:

$$D = \begin{bmatrix} 0 & 79 & 95 & 75 & 66 & 64 \\ 79 & 0 & 49 & 21 & 86 & 52 \\ 95 & 49 & 0 & 58 & 6 & 5 \\ 75 & 21 & 58 & 0 & 83 & 64 \\ 66 & 86 & 6 & 83 & 0 & 38 \\ 64 & 52 & 5 & 64 & 38 & 0 \end{bmatrix} \quad (2.9)$$

Sejam inicialmente os dois fontes p_1 e p_2 . Associados à p_1 e p_2 determinam-se as partições correspondentes:

$$P_{x1} = \{p_1, p_5\}$$

$$P_{x2} = \{p_2, p_3, p_4, p_6\}$$

Determinam-se os centros de gravidade:

Para P_{x1} --> o centro de gravidade é p_5

Para P_{x2} --> o centro de gravidade é p_3

Consideram-se agora os fontes p_3 e p_5 e associados à eles determinam-se:

$$P_{x5} = \{p_1, p_5\}$$

$$P_{x3} = \{p_2, p_3, p_4, p_5\}$$

Os centros de gravidade são p_5 e p_3 . Atingiu-se a convergência: as medianas são os nós 3 e 5. Maranzana (1964) sugere que se aplique o algoritmo para diferentes valores iniciais para garantir que p_3 e p_5 são os melhores nós que podem ser encontrados (otimalidade).

Embora o algoritmo possa falhar em convergir para uma solução ótima, Maranzana (1964) afirma que repetidas aplicações com valores iniciais alternativos asseguram uma boa solução. Poucos testes computacionais foram desenvolvidos por Maranzana (1964), embora ele indique que seu algoritmo apresentou resultados satisfatórios em problemas amostrais.

Teitz e Bart (1968) apresentaram bons resultados com a utilização de uma heurística de substituição de vértices. É uma abordagem alternativa que se concentra na definição formal dos vértices medianos generalizados e sua matriz de distâncias associada.

Teitz e Bart (1968) consideraram uma rede com n nós e para cada um deles uma dada demanda h_i . Para cada par de nós i, j da rede, a distância mínima $d_{i,j}$ é calculada. Cada vértice v_i no grafo G é ponderado por h_i e cada arco $i-j$ pela distância mínima $d_{i,j}$. Seja D a matriz simétrica $n \times n$ de distâncias (d_{ij}) entre os pares v_i, v_j para um grafo com pesos iguais nos vértices. O vértice mediano v_k será aquele cuja soma dos elementos na coluna correspondente em D seja minimizada:

$$d_j = \sum_{i=1}^n d_{ij} \quad (j = 1, 2, \dots, n) \quad (2.10)$$

Então, v_k é mediana se, somente se:

$$d_k = \text{MIN} (d_1, d_2, \dots, d_n) \quad (2.11)$$

Se o grafo G tem diferentes pesos nos vértices, é necessário redefinir a matriz das distâncias de G :

$$R = [H \cdot D] = [r_{ij}] = [h_i \cdot d_{ij}]$$

A generalização dos vértices medianos seguem logicamente de (2.10) e (2.11) na matriz R .

Considere-se a definição dos vértices medianos generalizados:

$$r_m = \sum_{i=1}^n (r_{ik})$$

$$r_m^* = \text{MIN} [r_1, r_2, \dots, r(C_n, p)]$$

$$r_m^* \leq r_m \quad (m=1, \dots, C_n, p)$$

Para cada conjunto possível de vértices fontes V_{pm} , pode-se construir uma submatriz R_{pm} de R juntando-se as p colunas correspondentes aos vértices v_j em V_{pm} . A fonte da qual qualquer vértice destino v_i é servido é definido como v_k tal que:

$$r_{ik} \leq r_{ij} \quad \text{para todo } v_k, v_j \in V_{pm}$$

Esta é a i -ésima linha mínima em R_{pm} . A distância total r_m para o m -ésimo conjunto de fontes será a soma destas linhas mínimas.

Vários tipos de efeitos resultantes na distância ponderada total podem ocorrer caso troque-se um vértice v_j no conjunto de fontes por outro v_b .

Se r_{ij} não for a i -ésima linha mínima de R_{pm} , então, nenhuma mudança ocorreria na contribuição de r na i -ésima linha. Se r_{ij} for a i -ésima linha mínima, então, sua substituição por r_{ib} pode produzir vários resultados dependentes de:

$$r_{ib} \leq r_{ij} \quad (a)$$

$$\text{ou } r_{ij} \leq r_{ib} \leq r_{iS} \quad (b)$$

$$\text{ou } r_{ij} \leq r_{iS} \leq r_{ib} \quad (c)$$

onde r_{iS} é a distância ponderada de v_i a v_S para a qual

$$r_{ij} \leq r_{iS} \leq r_{iS^*} \quad \text{p/ } v_{S^*} \in V_{pm} \quad \text{e } v_{S^*} \neq v_j, v_S$$

Em outras palavras, r_{iS} é a segunda menor i -ésima linha em R_{pm} .

No caso (a) a contribuição de r na i -ésima linha da substituição de v_b por v_j é agora incrementada por:

$$\begin{aligned} i \Delta b_j &= r_{ij} - r_{ib} \\ i \Delta b_j &\leq 0 \end{aligned}$$

No caso (b) a contribuição de r na i -ésima linha é incrementada por:

$$\begin{aligned} i \Delta b_j &= r_{ij} - r_{ib} \\ i \Delta b_j &\geq 0 \end{aligned}$$

No caso (c) o incremento comparável é:

$$\begin{aligned} i \Delta b_j &= r_{ij} - r_{is} \\ i \Delta b_j &\geq 0 \end{aligned}$$

Se vai ser pior substituir o vértice v_b pelo v_j depende do efeito de rede do incremento somado sobre todas as linhas:

$$\Delta b_j = \sum_{i=1}^n i \Delta b_j$$

Substituir v_b por v_j reduz a distância total somente se:

$$\Delta b_j < 0$$

Estas observações sugerem uma abordagem para encontrar a mediana generalizada que envolve um processo iterativo de substituição de um único vértice, seguindo os seguintes passos:

PASSO 1: Seleciona-se algum subconjunto inicial de vértices fontes; por conveniência, sejam $v_1, v_2, \dots, v_j, \dots, v_p$.

PASSO 2: Para cada vértice v_j encontra-se seu P_{1j} associado (de vértices destinos) como no método da partição (Maranzana, 1964):

$$P_{1j} = \{v_i / r_{ij} < r_{ik}, \text{ qq seja } v_k \in V_1\}$$

e, computa-se a distância total para o sistema r_1 ,
assim:

$$r_1 = \sum_{v_j \in V_1} \left(\sum_{v_i \in P_1} r_{ij} \right)$$

PASSO 3: Seleciona-se algum vértice, v_b , fora do conjunto de fontes.

PASSO 4: Para cada vértice v_j em V_1 substitua v_b e calcule Δ_{bj} .

PASSO 5: Encontra-se o vértice v_k em V_1 tal que:

$$\Delta_{bk} < 0$$

$$\Delta_{bk} = \text{MIN } \Delta_{bj} \quad j=1, \dots, p$$

PASSO 6: Se existe um vértice que satisfaça às condições do PASSO 5, substitui-se v_b por v_k no conjunto de fontes, chama-se o novo conjunto de V_2 e calcula-se r_2 . Se nenhum vértice satisfaz às condições, mantem-se o conjunto de fontes V_1 e segue-se para o PASSO 7.

PASSO 7: Seleciona-se outro vértice que não esteja em V_1 nem em V_2 e não experimentado anteriormente, e repetem-se os PASSOS 4 até 6.

PASSO 8: Quando todos os vértices do complemento de V_1 tiverem sido experimentados, define-se o subconjunto de fontes resultante V_t como um novo V_1 e repetem-se os PASSOS 2 até 7. Chama-se cada repetição desta de ciclo completo.

PASSO 9: Quando um ciclo completo (PASSOS 2 à 8) resultar em nenhuma redução em r , o procedimento termina. O V_t final é uma estimativa dos vértices p -medianos de G .

Seja a matriz de distâncias (2.9) definida anteriormente. Neste caso consideram-se os pesos $h_i=1$ (então $R = [HD] = [D]$). Segue um esboço da primeira parte do primeiro ciclo do algoritmo proposto.

$$V = \{v_1, \dots, v_6\}$$

$$\text{Seja } V_1 = \{v_1, v_2\}$$

$$\text{Para } v_1 \rightarrow P_{11} = \{v_5\}$$

$$\text{Para } v_2 \rightarrow P_{12} = \{v_3, v_4, v_6\}$$

$$r_1 = r_{15} + r_{23} + r_{24} + r_{26} = 188$$

$$\text{Seja } v_b = v_3$$

$$\text{Para } v_1 \rightarrow V_1 = \{v_2, v_3\} \quad \text{e} \quad \Delta b_1 = \sum_{i=1}^n i \Delta b_i$$

$$1 \Delta b_1 = r_{11} - r_{15} = 0 - 64 = -64 \quad (\text{caso c})$$

$$2 \Delta b_1 = 79 - 49 = 30 \quad (\text{caso a})$$

$$3 \Delta b_1 = 95 - 0 = 95 \quad (\text{caso a})$$

$$4 \Delta b_1 = 75 - 58 = 17 \quad (\text{caso a})$$

$$5 \Delta b_1 = 66 - 6 = 60 \quad (\text{caso a})$$

$$6 \Delta b_1 = 66 - 5 = 59 \quad (\text{caso a})$$

$$\Delta b_1 = 64 - 30 - 95 - 17 - 60 - 59 = -197$$

$$\text{Para } v_2 \rightarrow V_1 = \{v_1, v_3\}$$

$$\begin{aligned}
 1 \Delta b_2 &= 79 - 95 = -16 \quad (\text{caso b}) \\
 2 \Delta b_2 &= 0 - 21 = -21 \quad (\text{caso c}) \\
 3 \Delta b_2 &= 49 - 0 = 49 \quad (\text{caso a}) \\
 4 \Delta b_2 &= 59 - 21 = 37 \quad (\text{caso a}) \\
 5 \Delta b_2 &= 86 - 6 = 80 \quad (\text{caso a}) \\
 6 \Delta b_2 &= 52 - 5 = 47 \quad (\text{caso a})
 \end{aligned}$$

$$\Delta b_2 = 16 + 21 - 49 - 37 - 80 - 47 = -176$$

Como v_1 em V_1 satisfaz as condições:

$$\begin{aligned}
 \Delta b_1 &< 0 \\
 \Delta b_1 &= \text{MIN} (\Delta b_1, \Delta b_2).
 \end{aligned}$$

Substitui-se o vértice v_3 pelo vértice v_1 : $V_2 = \{v_2, v_3\}$ e $r_2 = 111$. Agora seleciona-se outro vértice que não esteja contido nem em V_1 nem em V_2 (e não experimentado anteriormente) e repetem-se os PASSOS 4 a 6, e assim por diante.

À primeira vista este procedimento parece trabalhoso em comparação com o método de Maranzana (1964). Entretanto, os passos são simples e o tempo de processamento é razoável. Em nenhum dos casos analisados por Teitz e Bart (1968) houve mais que 4 ciclos até encontrar as p -medianas. Como no Método de Maranzana (1964), não há segurança de que V_t e r_t sejam valores ótimos globais.

2.2.3 - MÉTODOS EXATOS E PROGRAMAÇÃO MATEMÁTICA

Dentre os métodos exatos encaixam-se os procedimentos do tipo "branch and bound". Jarvinen et al. (1972) desenvolveram um algoritmo deste tipo para resolver o PPM. Sejam:

- V_p o conjunto de p pontos $\{v_1, \dots, v_p\}$ no grafo G
- $d(V_p, v_j) = \min \{d(v_1, v_j), d(v_2, v_j), \dots, d(v_p, v_j)\}$
- $d(v_i, v_j)$ o tamanho do menor caminho entre v_i e v_j , $v_i \in V_p$

- a matriz de distâncias D ($n \times n$)
- o conjunto V_{0p} é uma p -mediana de G se, para todo V_{kp} em G :

$$\sum_{j=1}^n d(V_{0p}, v_j) \leq \sum_{j=1}^n d(V_{kp}, v_j)$$

- $D_{ij} = d(v_i, v_j)$
- Para o conjunto de p pontos V_{0p} :

$$\sum_{j=1}^n d(V_{0p}, v_j) = \sum_{j=1}^n (\min D_{ij}) = S$$

Eles observaram que (1) na soma S existe somente um elemento de cada coluna de D , (2) todos os termos em S estão localizados em somente p linhas de D , e (3) a soma S consiste de pelo menos p termos nulos que correspondem aos D_{ii} na diagonal principal. O algoritmo apresentado por eles baseia-se principalmente na observação (2) e objetiva escolher $n-p$ vértices que não pertençam a V_{0p} . A regra de partição adotada é a seguinte: tira-se primeiro um vértice do conjunto e depois $2, 3, 4, \dots, n-p$. Para calcular o limitante inferior da soma S , assume-se que r vértices $v_{K1}, v_{K2}, \dots, v_{Kr}$ foram tirados do conjunto ($1 \leq r \leq n-p$). Então tem-se $n-r$ vértices dos quais p vértices devem ser escolhidos. Conseqüentemente, tem-se dois conjuntos de vértices e os correspondentes conjuntos de índices:

$$\begin{aligned} V_r &= \{v_{K1}, v_{K2}, \dots, v_{Kr}\} & \text{e} & & V_{n-r} &= \{v_{J1}, v_{J2}, \dots, v_{J(n-r)}\} \\ K &= \{K1, K2, K3, \dots, Kr\} & \text{e} & & J &= \{J1, J2, \dots, J(n-r)\} \end{aligned}$$

Para as colunas da matriz D , que correspondem ao conjunto K , calcula-se para a coluna $k \in K$:

$$s_k = \min_{i \in J} D_{ik} \quad \text{para } i \in J$$

E para outra coluna $j \in J$:

$$s_j = \min_{i \in J, i \neq j} D_{ij}$$

O limite inferior da soma S é:

$$LB(K) = SK + SJ, \text{ onde:}$$

$$S_k = \sum_{k \in K} s_k \quad e$$

S_j é a soma dos $(n-p-r)$ menores s_j ($j \in J$).

O algoritmo possui os seguintes passos:

PASSO 1: Seja $r = 1$, $S = \infty$. Gera-se o conjunto de índices $K = \{1\}, \{2\}, \dots, \{n\}$. Segue-se para o PASSO 3.

PASSO 2: Seja $K' = \{K_1, K_2, \dots, K_r\}$. Seja $r = r + 1$. Inativa-se o limitante inferior $LB(K')$ e gera-se um novo conjunto de índices K onde todos os índices do conjunto consistem dos índices de K' e de um novo índice.

PASSO 3: Calcula-se $LB(K)$ para todos os índices.

PASSO 4: Se $r < n - p$ escolhe-se o menor $LB(K)$, chama-se este conjunto de K' e segue-se para o PASSO 2.

PASSO 5: Se $r = n - p$ tem-se uma solução viável para o problema. Seja $LB(K')$ o menor $LB(K)$ do novo conjunto de índices. Se $LB(K') < S$, então faz-se $S = LB(K')$, colocam-se as p -medianas correspondentes na memória e destiva-se o limitante inferior cujo $LB(K) \geq S$. Se após isto não existirem mais conjuntos ativos, o algoritmo termina e a soma mínima é S . Caso contrário, escolhe-se o menor $LB(K)$ do conjunto de limitantes inferiores ativos, chama-se este conjunto de K' e vai-se para o PASSO 2.

Seguem os cálculos indicados nos passos do algoritmo. A matriz de distâncias é a definida em (2.9).

$$\begin{aligned}
 r &= 1 & n - r &= 5 & n - r - p &= 3 \\
 V1 &= \{v1\} & e & & V5 &= \{v2, v3, v4, v5, v6\} \\
 LB(1) &= 64 + 5 + 6 + 5 = 80 \\
 LB(2) &= 21 + 51 + 6 + 5 = 83 \\
 LB(3) &= 5 + 21 + 21 + 38 = 85 \\
 LB(4) &= 21 + 5 + 6 + 5 = 37 \\
 LB(5) &= 6 + 5 + 5 + 21 = 37 \\
 LB(6) &= 5 + 6 + 6 + 21 = 38
 \end{aligned}$$

Como $r < n - p$, continua-se. O menor $LB(K)$ é $LB(4) = 37 = LB(5)$

$$K' = \{4\} \quad r = 2$$

$$K = \{4, 1\} \quad LB(K) = 21 + 5 + 5 = 31$$

$$n - r - p = 2$$

$$K = \{4, 2\} \quad LB(K) = 21 + 5 + 5 = 31$$

$$K = \{4, 3\} \quad LB(K) = 5 + 38 + 38 = 81$$

$$K = \{4, 5\} \quad LB(K) = 6 + 5 + 5 = 16$$

$$K = \{4, 6\} \quad LB(K) = 5 + 6 + 6 = 17$$

$$r = 2 \quad n - p = 4 \quad e \quad K' = \{4, 5\}$$

E assim por diante, são calculados os $LB(K)$ até que $r = n - p \dots$

Jarvinen et al. (1972) fornecem também uma heurística para obter uma solução inicial para o método de substituição proposto

por Teitz e Bart (1968). Eles afirmaram que este procedimento melhorou a execução do método de substituição. Segundo Handler e Mirchandani (1979) isto não é surpreendente, já que, a combinação de heurísticas é eficiente na resolução do PPM. Os procedimentos heurísticos são igualmente importantes quando usados em conjunto com alguns algoritmos exatos, pois além de fornecerem soluções iniciais viáveis boas, uma solução heurística também fornece um limitante superior do valor ótimo da função objetivo, ajudando na convergência mais rápida dos algoritmos exatos.

Revelle e Swain (1970) modificando a formulação do problema de localização de armazéns (PLA), apresentaram uma formulação de programação inteira para resolução do PPM, a mesma adotada neste trabalho (descrita na Seção 2.1).

Os algoritmos descritos a seguir são baseados em uma formulação dual do problema de programação matemática (P). Relaxação lagrangeana é uma técnica, baseada no dual, que tem provado sucesso na resolução de problemas de programação inteira. Tendo em vista que esta técnica é amplamente empregada, optou-se por fazer uma breve exposição teórica a respeito.

Muitos pesquisadores consideram a Relaxação Lagrangeana vantajosa para resolução de problemas com estruturas especiais, já que, relaxar um conjunto de restrições pode produzir um problema lagrangeano de fácil resolução, cujo valor ótimo é um limitante inferior (para o problema de minimização) do valor ótimo do problema original.

Segundo Fisher (1981) o nascimento da relaxação lagrangeana, como ela existe hoje, ocorreu em 1970 quando Held e Karp utilizaram um procedimento de relaxação para a solução aproximada de um problema de programação linear relacionado ao problema do caixeiro-viajante. Logo após o método foi aplicado em problemas de "scheduling" e problemas de programação inteira em geral.

Esta técnica foi amplamente discutida por Geoffrion (1974) e Held et al. (1974).

Surgem três questões quando se usa a abordagem lagrangeana: (1) quais restrições devem ser relaxadas, (2) como calcular bons multiplicadores e (3) como deduzir uma solução viável para o problema original dada a solução do problema relaxado.

Para Fisher (1985), a relaxação deve ser feita de modo a facilitar o problema e, ele sugere que, para calcular bons multiplicadores, existe um procedimento de propósito geral chamado método de subgradientes (uma variação do método de gradientes) que vem sendo utilizado em grande escala nos últimos anos e com bastante sucesso. Uma primeira abordagem deste método foi usada por Poljak (1967). Subseqüentemente, Held et al. (1974) apresentaram a formulação teórica do método e resultados computacionais aplicados aos problemas de atribuição e caixeiro-viajante. Maiores detalhes serão apresentados a seguir, no decorrer da apresentação do algoritmo.

Segundo Handler e Merchandani (1979), primeiro Diehr (1972) e mais tarde Narula et al. (1977) e Cornuejols et al. (1977), aplicaram especificamente esta técnica (relaxação lagrangeana em conjunto com um método de otimização por subgradientes) para resolver o PPM.

A seguir, descrevem-se os passos na resolução do problema (P) descrito na Seção 2.1, relaxando a restrição (2.2):

Para qualquer vetor $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_n) \geq 0$, formar o seguinte problema lagrangeano (PL):

$$Z_d(\lambda) = \text{MIN} \left(\sum_{i=1}^n \left(\sum_{j=1}^n d_{ij} x_{ij} \right) - \sum_{j=1}^n \lambda_j \left(\sum_{i=1}^n x_{ij} - 1 \right) \right) \quad (2.12)$$

$$\text{Sujeito } \tilde{a}: \quad x_{ii} \leq x_{ij} \quad (2.13)$$

$$\sum_{i=1}^n x_{ii} = p \quad (2.14)$$

$$x_{ij} \in \{0,1\}, \quad i, j = 1, 2, \dots, n \quad (2.15)$$

cuja função objetivo pode ser reescrita como:

$$Z_d(\lambda) = \text{MIN} \sum_{j=1}^n \left(\sum_{i=1}^n (d_{ij} - \lambda_j) x_{ij} \right) + \sum_{j=1}^n \lambda_j \quad (2.16)$$

Tal problema para um dado λ pode ser resolvido por inspeção, ignorando momentaneamente a restrição (2.14) e decompondo-o sobre o índice i , obtendo n subproblemas da seguinte forma:

$$\text{Minimizar} \quad \sum_{j=1}^n (d_{ij} - \lambda_j) x_{ij}$$

$$\text{Sujeito } \tilde{a} \quad x_{ij} \leq x_{ii} \quad i, j = 1, 2, \dots, n$$

$$x_{ij} \in \{0,1\} \quad i, j = 1, 2, \dots, n$$

Cada subproblema é resolvido por inspeção. Seja:

$$\alpha_i = \sum_{j=1}^n [\text{MIN}(0, d_{ij} - \lambda_j)]$$

e seja I o conjunto de índices dos p menores α_i 's (aqui a restrição (2.14) é tratada implicitamente). Então, uma solução $\{x_{ij}^*\}$ para o problema lagrangeano é:

$$x_{ii}^* = \begin{cases} 1 & \text{se } i \in I \\ 0 & \text{caso contrário} \end{cases}$$

e para todo $i \neq j$:

$$x_{ij}^* = \begin{cases} 1 & \text{se } i \in I \text{ e } d_{ij} - \lambda_j \geq 0 \\ 0, & \text{caso contrário} \end{cases}$$

A solução $\{x_{ij}^*\}$ não é necessariamente viável para o PPM original, uma vez que a condição (2.2) pode não estar sendo atendida. Todavia, o conjunto I identifica o conjunto de p nós que pode sempre oferecer uma possível solução viável e logo um limitante superior. Se $\lambda \geq 0$, então $Z_d(\lambda)$ é menor ou igual a Z (o valor ótimo da função objetivo do PPM original).

Assim o problema dual (D) é encontrar o melhor limitante inferior para Z , ou seja:

$$(D) \quad \text{Maximizar } Z_d(\lambda) \quad (\lambda \geq 0) \quad (2.17)$$

Para obter um bom vetor λ , sugere-se o uso de um método de subgradientes que é uma técnica de atualização progressiva dos multiplicadores de Lagrange, de maneira sistemática, com o objetivo de maximizar o valor do problema dual lagrangeano.

Assume-se que o problema lagrangeano tenha sido resolvido para um dado λ e seja:

$$S_j = \sum_{i=1}^n x_{ij}^* - 1$$

Logo, S_j indica o número de medidas em excesso para as quais o vértice v_j está alocado na solução dual $\{x_{ij}^*\}$. Observa-se que $S=(S_1, S_2, \dots, S_n)$ é um subgradiente de Z_d em λ e pode ser usado como direção a fim de alterá-lo. Assim:

- Se $S_j < 0$, λ_j é diminuído
- Se $S_j > 0$, λ_j é aumentado
- Se $S_j = 0$, λ_j permanece inalterado

Para se determinar o "tamanho do passo" (t_k), sugere-se as regras dadas por Held et al. (1974):

$$\text{Seja a seqüência: } \lambda_{jk+1} = \lambda_{jk} + t_k S_{jk}$$

Pode-se assegurar a convergência de $Z_d(\lambda)$ ao seu valor máximo sob as seguintes condições (Poljak, 1967):

$$\text{Se } k \rightarrow \infty, \quad t_k \rightarrow 0 \quad \text{e} \quad \sum_{i=1}^n t_i \rightarrow \infty$$

O "tamanho do passo" usado mais comumente é (Held e Karp, 1970):

$$t_k = \frac{\pi_k (Z^* - Z_d(\lambda_k))}{\|S_k\|^2}$$

onde π_k é um escalar que satisfaz a $0 \leq \pi_k \leq 2$, Z^* o valor da função objetivo em seu melhor valor viável para (P) e $\|S_k\|^2$ é qualquer norma (neste caso, norma Euclideana) de S.

Freqüentemente a seqüência π_k é determinada começando com $\pi_0 = 2$ e reduzindo π_k por um fator 2 sempre que $Z_d(\lambda)$ falhar em crescer em um número específico de iterações. O valor Z^* , inicialmente, pode ser calculado usando qualquer heurística para o PPM (Teitz e Bart, por exemplo) e depois atualizado usando as soluções que são obtidas nas iterações em que a solução do problema lagrangeano devolve uma solução viável para o problema original (P). A menos que se obtenha um λ_k para o qual $Z_d(\lambda) = Z^*$, não existe maneira de provar a otimalidade do método dos subgradientes. Para resolver esta dificuldade, o método é usualmente encerrado depois de atingir um limite específico de iterações.

Narula et al. (1977) utilizam a metodologia acima definindo o problema (P) como definido na Seção 2.1 (equações (2.1)-(2.5)), e os problemas (PL - equações (2.12)-(2.15)) e (D - equação (2.17)).

O algoritmo (chamado Algoritmo 1, para futuras referências) para resolver o problema (D), ou seja, maximizar $Z_d(\lambda)$ pode ser estabelecido como segue:

PASSO 1: Escolher um λ_0 inicial. Uma boa escolha é $\lambda_{j0} = \text{MIN}\{d_{ij}\}$, para $i \neq j$. Faz-se $k=0$.

PASSO 2: Para o λ_k escolhido, o valor de $Z_d(\lambda_k)$ é obtido como se segue: para cada i , calcula-se

$$\alpha_i = \sum_{j=1}^n (\text{MIN}(0, d_{ij} - \lambda_j))$$

Selecionam-se os p menores α_i e seja I o conjunto de tais índices. Calcula-se

$$Z_d(\lambda_k) = \sum_{i \in I} \alpha_i + \sum_{j=1}^n \lambda_j$$

Para obter o valor do correspondente Z^* , calcula-se para cada j , $D_{jk} = \text{MIN} \{d_{ij}\}$, $i \in I$. A soma dos $n-p$ maiores D_{jk} dá o valor de Z^* .

PASSO 3: A j -ésima componente do subgradiente de $Z_d(\lambda_k)$ em λ_k é

$$S_j = \sum_{i=1}^n x_{ij}^* - 1, \text{ onde}$$

$$x_{ij}^* = \begin{cases} 1 & \text{se } i \in I \text{ e } (d_{ij} - \lambda_j) < 0 \\ 0, & \text{caso contrário.} \end{cases}$$

Termina a busca se todo $S_j = 0$ ou o valor de $Z_d(\lambda_k)$ igualar ao valor de Z . Caso contrário, calcula-se o "tamanho do passo" t_k . Faz-se $\lambda_{k+1} = \lambda_k + t_k S_k$ e $k=k+1$. Vai-se para o PASSO 2.

Nesse trabalho (Narula et al., 1977), os autores apresentam resultados comparativos com outros algoritmos para problemas com $n=10$ ($p=2, 4, 6, 8$), $n=20$ ($p=2, 4, \dots, 18$), $n=30$ ($p=2, 4, \dots, 28$). A técnica utilizada apresentou excelentes resultados relativos.

Christofides e Beasley (1982) também utilizaram relaxação lagrangeana, tentando dois limites para o PPM. Para um destes limites a relaxação foi relativa às mesmas restrições consideradas por Narula et al. (1977), só que, neste caso foram incluídos testes de penalidades baseados nos limites obtidos. No segundo limite estudado a relaxação foi relativa às restrições:

$$\sum_{j=1}^n a_{ij} x_{ij} \leq n_i x_{ii} \quad i, j=1, \dots, n \quad i \neq j$$

que substituíram as restrições $x_{ij} \leq x_{ii}$ da formulação anterior. Neste caso considerou-se $a_{ij} \geq 0$ para todo i e j e $a_{ij} = 0$ se e somente se j não pode ser alocado a i ($d_{ij} = \infty$).

Também neste caso foram incluídos testes de penalidade sobre o limite. Um procedimento de busca em árvore é descrito e são apresentados os resultados computacionais para problemas com número arbitrário de medianas num total de até 200 nós.

O trabalho de Christofides e Beasley (1982) mostrou que a relaxação conforme considerada por Narula et al. (1977) é mais eficiente. Os testes de penalidade incluídos serviram para a redução do problema, isto é, fixando algumas variáveis x_{ij} no seu valor ótimo zero ou um reduzindo a dimensão do problema.

Em uma publicação posterior, Beasley (1985) mostrou ser possível melhorar seu algoritmo, resolvendo problemas com até 900 nós, com o uso de um super-computador com capacidade de processamento vetorial.

Raggi e Galvão (1982) trataram o PPM com custos fixos, isto é, um problema de localização de recursos em redes no qual os custos fixos de instalação variam ao longo da rede. Eles apresentaram um algoritmo com base na relaxação lagrangeana da formulação de programação zero-um do problema. O uso deste método para problemas de custo fixo é uma extensão dos métodos usados por Narula et al. (1977) e Christofides e Beasley (1982). O algoritmo foi testado em vários problemas gerados aleatoriamente, relativos a redes de até 100 vértices. Para todos os problemas testados a solução ótima foi obtida.

Olivo e Senne (1988) apresentaram a implementação, em micro-computador do tipo IBM-PC, de um método de subgradientes associado à relaxação lagrangeana e concluíram que este pode ser considerado uma excelente heurística na obtenção de bons limitantes. Eles sugerem o uso destes limitantes em um algoritmo do tipo "branch and bound" para solucionar, de modo exato, problemas de grande porte.

Neste trabalho segue-se a sugestão de Olivo e Senne (1988): aproveita-se a abordagem de Christofides e Beasley (1982), incorporando-se a busca em árvore e implementando-se o algoritmo em micro-computador do tipo IBM-PC.

CAPÍTULO 3

ALGORITMO PROPOSTO

3.1 - INTRODUÇÃO

No capítulo anterior, descreveu-se o problema das p-medianas e suas aplicações. Foram destacados alguns dos algoritmos mais importantes na resolução do PPM. Além disso, foram fornecidos alguns resultados teóricos importantes (relaxação lagrangeana e otimização por subgradientes), que serão úteis na formulação do algoritmo utilizado neste trabalho.

Neste trabalho enfoca-se a resolução do PPM de uma forma clássica: aplica-se uma relaxação lagrangeana ao problema de modo que permita a resolução analítica do problema lagrangeano e, em seguida, busca-se o ótimo da função dual usando um método de subgradientes. Se uma solução ótima primal não for encontrada em um determinado número de iterações lança-se mão de um esquema de "branch and bound" (procedimento de busca em árvore).

Neste capítulo, inicialmente, é apresentado o algoritmo enfocando a relaxação lagrangeana e um método de subgradientes. A seguir, após a apresentação de uma visão geral do método "branch and bound", descreve-se a sua inclusão no algoritmo.

3.2 - ALGORITMO DE SUBGRADIENTES

Como já foi descrito anteriormente, o PPM pode ser formulado como um problema de programação linear inteira zero-um (problema (P) - Seção 2.1). A maior dificuldade encontrada na resolução de (P) reside na determinação do valor das variáveis x_{ii} , que define a localização das medianas na rede. Supondo-se que x_{ii}^* representem os valores de x_{ii} na solução ótima de (P), a determinação das demais variáveis x_{ij} , $i \neq j$ - chamada de problema da alocação dos nós às medianas - pode ser realizada sem dificuldade a partir de x_{ii}^* .

Se $Q = \{i: x_{ii}^* = 1\}$ é o conjunto das medianas da solução ótima, então os x_{ij}^* estão definidos, para cada $j \in V-Q$, pela seguinte regra:

$$x_{ij}^* = \begin{cases} 1 & \text{para um nó } i \in Q \text{ tal que } d_{ij} = \text{MIN } d_{ik} \text{ (} k \in Q \text{)} \\ 0 & \text{caso contrário.} \end{cases}$$

O problema lagrangeano é o (PL) descrito no capítulo anterior, equações (2.12)-(2.15). A constante α_i , também definida anteriormente, pode ser considerada como o "custo" de localizar uma mediana no nó i . Assim, a resolução do problema lagrangeano reduz-se a determinar o conjunto I dos nós correspondentes aos p menores α_i , $i \in V$ e fazer $x_{ii} = 1$ se $i \in I$ e $x_{ii} = 0$, caso contrário.

O problema dual correspondente a (P) é o problema (D) definido pela equação (2.17). Para resolver (D) utiliza-se um método de subgradientes, já descrito anteriormente.

A seguir, baseado no Algoritmo 1 descrito no Capítulo 2, formaliza-se o algoritmo de subgradientes usado. Determina-se um valor inicial para LS (o limitante superior no problema). Isto pode ser feito usando qualquer heurística para o PPM (Teitz e Bart, 1968 por exemplo). Neste trabalho, por economia de tempo e recursos computacionais, optou-se por inicializar LS com um valor grande (maior número inteiro permitido pela linguagem de programação utilizada). Logo na primeira iteração este valor é atualizado pelo valor da solução viável do primal. Seja Zd_{max} o valor do limitante inferior máximo. Seja Zd_{art} uma heurística usada quando não há melhora no LS, naquela iteração, servindo, assim, para acelerar a convergência do algoritmo. Este valor não pode superar LS e quando isso acontece Zd_{art} é feito igual a Zd_{max} .

ALGORITMO DE SUBGRADIENTES:

Dados λ e LS.

PASSO 1: Faz-se $Zd_art \leftarrow 0$ e $Zd \leftarrow 0$.

PASSO 2: Enquanto (a) $S_j \neq 0$, para algum j , ou

(b) $LS - Zd_max \geq 0.05$, ou

(c) $\pi > 0.005$,

Resolvem-se os PASSOS 3 a 6.

PASSO 3: Resolve-se (PL) obtendo:

x_{ij}^* ,

$$Zd(\lambda) \leftarrow \sum_{i \in I} \alpha_i + \sum_{j=1}^n \lambda_j$$

$$Z^* \leftarrow \sum_{j=1}^n (\text{MIN}_{i \in I} d_{ij})$$

PASSO 4: Calculam-se os subgradientes:

$$S_j \leftarrow \sum_{i=1}^n x_{ij}^* - 1, \quad j=1, \dots, n$$

PASSO 5: Atualizam-se os limitantes:

Se $Zd(\lambda) > Zd_max$, então $Zd_max \leftarrow Zd(\lambda)$;

Se $Z^* < LS$, então $LS \leftarrow Z^*$ e $Zd_art \leftarrow Zd_max$

Caso contrário, faz-se:

$$Zd_art \leftarrow Zd_art + 0.2(LS - Zd_art);$$

Se $Zd_art > LS$, então $Zd_art \leftarrow Zd_max$;

PASSO 6: Determina-se o novo "tamanho do passo":

$$t \leftarrow \frac{\pi (LS - Zd_art)}{\|S\|^2}$$

e atualizam-se os multiplicadores de Lagrange:

$$\lambda_j \leftarrow \text{MAX} \{0, \lambda_j + tS_j\}, \quad j = 1, \dots, n$$

Para escolher o valor de π , segue-se a abordagem de Held et al. (1974) fazendo $\pi = 2$ para $2n$ iterações. Depois π é dividido ao meio a cada 5 iterações seguidas em que não houver melhora no Zd_max .

Como se pode observar executa-se este algoritmo de subgradientes até que uma ou mais das condições de saída abaixo sejam satisfeitas:

- a- Todos os subgradientes sejam nulos
- b- A solução viável mínima (LS) e o limitante inferior máximo Zd_max coincidem (dentro de uma precisão preestabelecida, 5% neste caso), ou seja, LS corresponde a uma solução ótima.
- c- π alcance o valor 0.005.

Estes valores, 5% e 0.005, são fixados empiricamente.

Segundo Narula et al. (1977), caso o algoritmo não forneça uma solução ótima para (D), o método de "branch and bound" pode ser usado para encontrar uma solução ótima inteira. O limitante de cada nó seria obtido maximizando $Zd(\lambda)$ usando o algoritmo proposto, com um conjunto de variáveis fixadas em zero ou um.

Beasley (1985) segue este mesmo procedimento, implementando-o e refinando-o. Basicamente as melhoras no algoritmo envolvem:

- (1) O valor inicial de π e a regra para divisão de seu valor: $\pi = 2$ inicialmente e é dividido ao meio se Zd_{max} parar de crescer em trinta iterações consecutivas do subgradiente.
- (2) Dentro da árvore de busca, inicialmente $\pi = 1$ e é dividido ao meio a cada cinco iterações seguidas em que não houver melhora de Zd_{max} .
- (3) Na resolução de grandes problemas, Beasley (1985) concluiu ser vantajoso abandonar a árvore de busca depois de um certo estágio e recommear o problema. Se em qualquer estágio da árvore, encontrar-se uma solução viável melhor, ou seja LS (LS_inicial e que ainda não é ótima pois $LS \neq Zd_{max}$, então recommea-se o problema da "linha de saída", ou seja, com um novo nó inicial da árvore.

Além disso, Beasley (1985) sugeriu uma heurística para geração do LS inicial. Ele concluiu que estas mudanças geraram um "gap" de dualidade menor no nó inicial da árvore em menos iterações do subgradiente, além de gerarem (quase sempre) menos nós na árvore de busca.

3.3 - ALGORITMO DE BRANCH AND BOUND

Coloca-se a seguir o procedimento geral para se resolver problemas de programação inteira pela técnica "branch and bound". Esta técnica pode ser considerada como um procedimento de enumeração implícita, onde apenas uma fração das soluções viáveis é examinada.

A idéia básica desta técnica é a seguinte. Suponha-se o problema de minimização de uma função objetivo cujo limitante superior do valor ótimo esteja disponível. O primeiro passo é a partição do conjunto de todas as soluções viáveis em vários subconjuntos, e, para cada um, obtem-se um limitante inferior do valor da função objetivo dentro do subconjunto. Aqueles subconjuntos, cujo limitante inferior exceder o limitante superior corrente da função objetivo, são excluídos de futuras considerações. Um subconjunto que é excluído por isso ou por outras razões legítimas é chamado "esgotado". Em um dos subconjuntos restantes, naquele com o menor limitante inferior, é feita uma partição em vários subconjuntos. Seus limitantes inferiores são obtidos e usados como anteriormente para excluir alguns dos subconjuntos de considerações futuras. De todos os subconjuntos que ficarem, outro é selecionado para a próxima partição e assim por diante. Este processo é repetido até que uma solução viável seja encontrada tal que o valor correspondente da função objetivo não seja maior que o limitante inferior de qualquer subconjunto. Esta solução viável deve ser ótima já que nenhum dos subconjuntos apresentou uma melhor.

É importante que se defina uma regra de ramificação para selecionar um dos subconjuntos que ficarem (aqueles nem esgotados nem divididos). Cada novo subconjunto é excluído de considerações futuras (é esgotado) se: (1) o limitante inferior calculado exceder o limitante superior em questão, (2) o subconjunto não possui soluções viáveis e (3) a melhor solução viável no subconjunto foi identificada (se esta solução não exceder o limitante superior, armazena-se o seu valor como solução incumbente), e reaplica-se o teste de esgotamento

(1) para todos os subconjuntos restantes. Deve-se parar quando não existirem subconjuntos inesgotados, e então, a solução incumbente é ótima.

Para o PPM, onde todas as variáveis (x_{ij}) estão restritas a dois valores (0 ou 1), constroi-se uma árvore binária, passo a passo, cujo percurso é feito em profundidade. Fixam-se nós como medianas e não medianas baseado na seguinte estratégia para ramificação: fixa-se a variável x_{ii} para i correspondente a: $\alpha_i = \text{MIN}(\alpha_j)$ para $j \in I$. Em qualquer momento da árvore, uma variável é selecionada e dois subproblemas são gerados - um no qual aquela variável (x_{ii}) é igualada a zero, e outro no qual a variável é igualada a um. Como o percurso da árvore é feito em profundidade, primeiramente examinam-se os nós, fixando-os em um (nós da esquerda). Os testes de esgotamento são feitos. Sempre que um nó é esgotado volta-se para o anterior e ramifica-se considerando aquele último como não mediana ($x_{ii} = 0$, nós da direita).

O limitante considerado (Zd_{\max}) é o obtido pela relaxação lagrangeana. O procedimento dos subgradientes é executado até trinta iterações para cada nó da árvore ou até que uma de suas condições de saída ocorra. Adotam-se as sugestões (2) e (3) de Beasley (1985).

Tem-se então o seguinte:

- Após executar inicialmente o Algoritmo de Subgradientes, se $S_j = 0$, para todos os j , ou $Zd_{\max} - LS < 0.05$, então a solução ótima é encontrada para o primal e dual. Do contrário, será preciso construir a árvore de busca.
- Dentro da árvore, se $S_j = 0$, para todos os j , ou $Zd_{\max} > LS$, então deve-se esgotar o nó atual e, como a busca é em profundidade não se pode concluir otimalidade no primal. Deve-se, portanto, continuar a expandir a árvore até esgotá-la completamente.

Segue a descrição do Algoritmo de "Branch and Bound" utilizado.

ALGORITMO DE "BRANCH AND BOUND":

Dada a raiz da árvore com Zd_{max} e $LS_{inicial}$ obtidos do Algoritmo de Subgradientes:

PASSO 1: Seja $CONTE \leftarrow 0$; $no_arvore \leftarrow raiz$;

PASSO 2: Enquanto (a) todos os subgradientes não são nulos,
 (b) $LS - Zd_{max} > 0.05$ e
 (c) $CONTE > p$

Faz-se:

2.1) $no_arvore \leftarrow filho_esquerdo(no_arvore)$;

2.2) Executa-se o Algoritmo de Subgradientes (até 30 iterações);

2.3) Se a solução ótima não foi encontrada, mas LS ($LS_{inicial}$, então recomeça-se a construção da árvore com uma nova raiz (Zd_{max} e LS), a partir do PASSO 1.

PASSO 3: Esgota-se no_arvore .

PASSO 4: Se $no_arvore = raiz$, termina-se. Caso contrário, faz-se:
 $no_pai \leftarrow pai(no_arvore)$ e $CONTE \leftarrow CONTE - 1$;

Se $no_arvore = filho_direito(no_pai)$, então faz-se
 $no_arvore \leftarrow no_pai$ e volta-se ao PASSO 4.

Caso contrário, faz-se: $no_arvore \leftarrow filho_direito(no_arvore)$
 e volta-se ao PASSO 2.

Segue um exemplo (Figura 3.1) com $n = 20$ e $p = 3$. No início, até começar a busca na árvore, houve 203 iterações e obteve-se $LS = 293$ e $Zd_{max} = 274,02$. Na Figura 3.1 o número x ($-x$) dentro do quadrado representando o nó, implica que o vértice x foi escolhido para ser (não ser) uma mediana. As letras próximas aos nós indicam a ordem do percorrimento da árvore (A primeiro, B segundo, etc). Como não houve melhora no LS (permaneceu 293), a árvore não foi recomeçada. A melhor solução encontrada foi a da raiz (nós 13,1,3).

Segue um outro exemplo (Figura 3.2) com $n = 20$ e $p = 3$, em que houve melhora do LS. No início, até começar a busca na árvore, ocorreram 136 iterações e obteve-se $LS = 353$ e $Zd_{max} = 312,95$. Após 140 iterações, quando fixou-se o nó 2 como não mediana, houve uma melhora no LS. Recomeçou-se a árvore de busca, a partir deste ponto. Após esgotada toda a árvore, a melhor solução encontrada foi a da segunda raiz (nós 17,2,16) onde $LS = 336$.

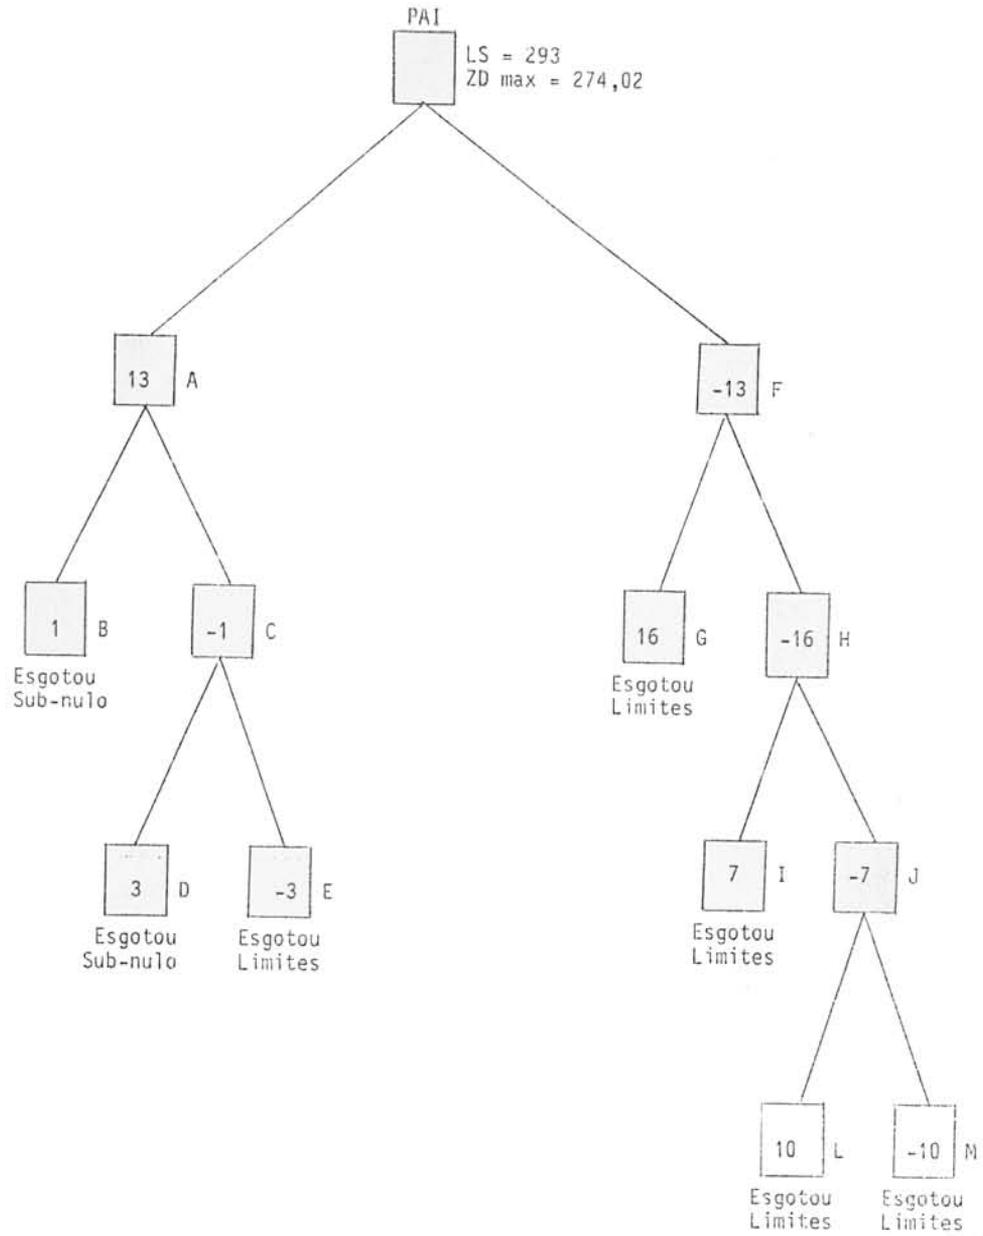


Fig. 3.1 - Exemplo com $n = 20$ e $p = 3$ (sem recomeço).

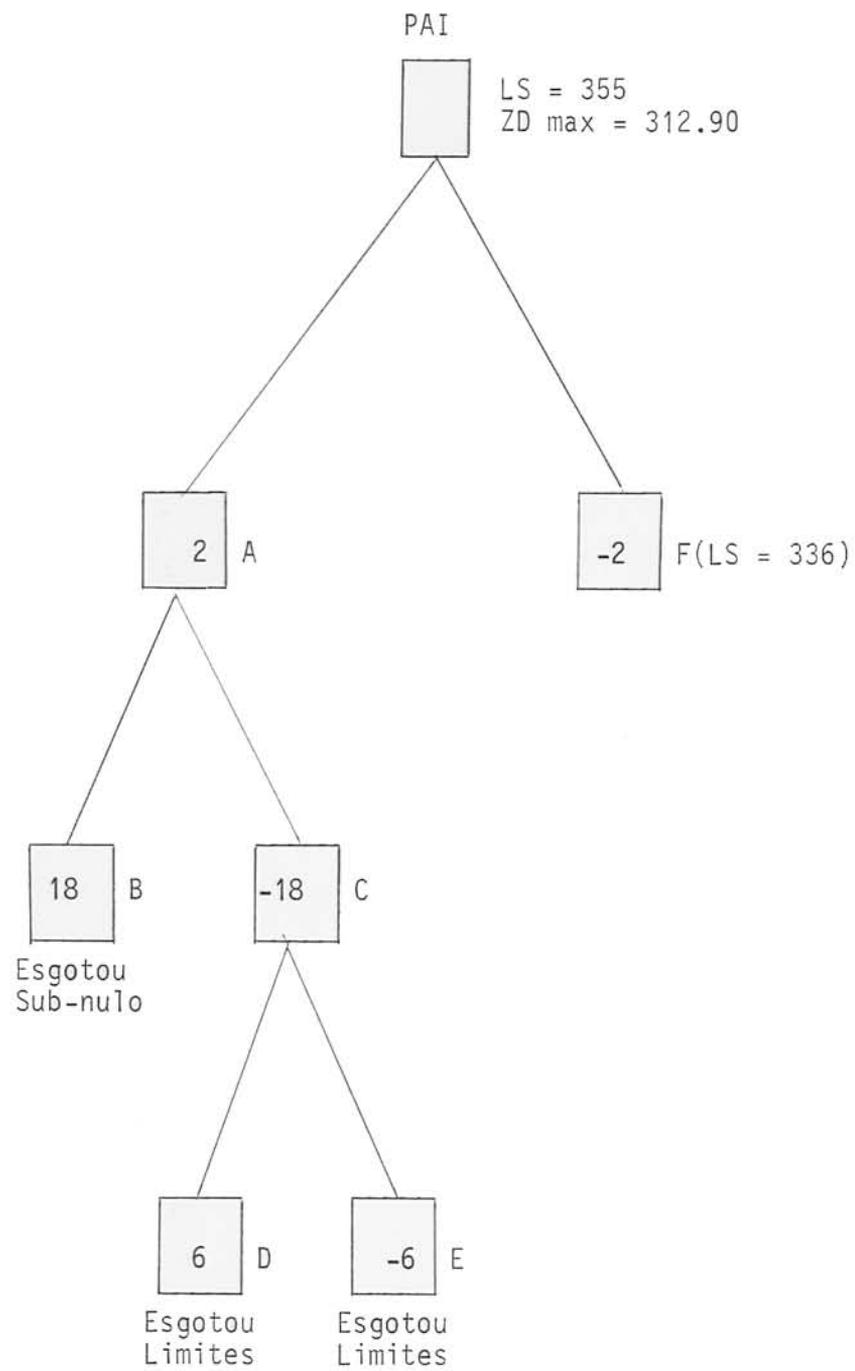


Fig. 3.2 - Exemplo com $n = 30$ e $p = 3$ (com um recomeço).

(continua)

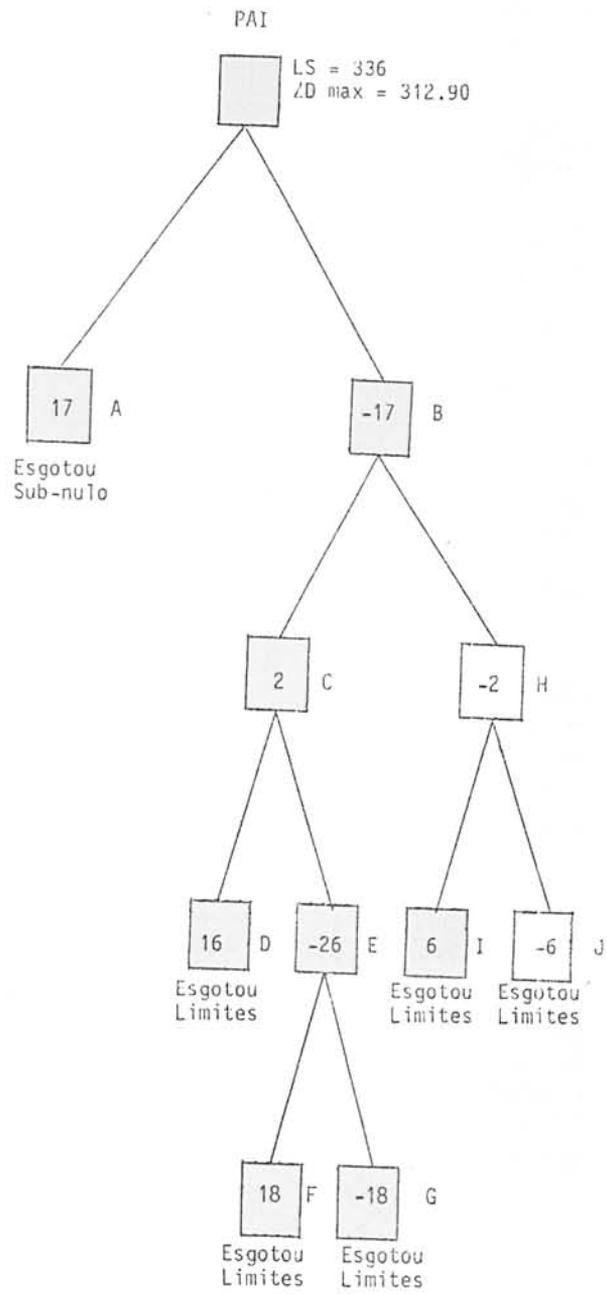


Fig. 3.2 - Conclusão.

CAPÍTULO 4

IMPLEMENTAÇÃO E TESTES

4.1 - INTRODUÇÃO

O algoritmo proposto foi implementado em TURBO-PASCAL (versão 3.0) usando um microcomputador tipo IBM-PC-AT. O programa pode ainda ser facilmente adaptado para uso em computadores de grande porte. A linguagem escolhida para programação, Pascal, é adequada quando se quer usar estruturas especiais de dados como listas e árvores (caso deste trabalho).

Uma consideração importante em qualquer implementação é sua eficiência cuja avaliação está relacionada ao tempo de execução do código final e a quantidade de espaço (memória) envolvido na execução. Estes dois fatores, espaço e tempo, encontram-se relacionados (nos sistemas que não implementam multiprocessamento) de tal forma que a redução de um deles implica na ampliação do outro e vice-versa.

Como um dos objetivos deste trabalho é a implementação de um algoritmo para o PPM em micro-computadores, a eficiência deste programa está basicamente relacionada com o espaço. Procurou-se economizar ao máximo o número de variáveis e matrizes (principalmente os tamanhos destas) de modo que o programa pudesse ser executado para um número total de nós (n) maior possível. Assim, obteve-se um programa que consegue suportar até 205 nós.

Um exemplo de otimização de espaço é o armazenamento da matriz de distâncias do problema. Como ela é simétrica, pode-se armazenar apenas a parte acima da diagonal principal em um vetor ($d(k)$), onde k é a posição que cada elemento desta parte da matriz ocupa em d . Cria-se um outro vetor (e) formado por ponteiros (tantos quantas forem as linhas da matriz de distâncias, menos um) que apontam, de acordo com sua ordem, para o início de cada linha (relativa à sua ordem). Por exemplo, $e(1)$ aponta para o primeiro elemento em d da primeira linha da matriz de distâncias, $e(2)$ aponta para o primeiro elemento em d da segunda linha da matriz de distâncias e assim sucessivamente. Para determinar o elemento que ocupa a posição i,j da matriz de distâncias, utiliza-se a seguinte expressão:

SE $i < j$ ENTÃO $k(i,j) = e(i) + j - i - 1$ e $\text{dist}(i,j) = d(k(i,j))$

CASO CONTRÁRIO

SE $i > j$ ENTÃO $k(i,j) = e(j) + i - j - 1$ e $\text{dist}(i,j) = d(k(i,j))$

CASO CONTRÁRIO $\text{dist}(i,j) = 0$

onde: $e(i)$ é a posição no vetor d onde começa a linha i .

Um exemplo é ilustrado a seguir. Seja a matriz de distâncias (para $n=4$):

$$\text{dist} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \\ a_{41} & a_{42} & a_{43} & a_{44} \end{bmatrix}$$

O vetor d e os respectivos k serão:

$d: (a_{12} \ a_{13} \ a_{14} \ a_{23} \ a_{24} \ a_{34})$

$k: \ 1 \ 2 \ 3 \ 4 \ 5 \ 6$

$e(1)$ aponta para $k=1$

$e(2)$ aponta para $k=4$

$e(3)$ aponta para $k=6$

Para saber o elemento que ocupa a posição $i=3$ e $j=2$ executa-se:

$$k(3,2) = e(2) + 3 - 2 - 1 = 4 + 3 - 2 - 1 = 4$$

logo, $d_{32} = d(4) = a_{23}$

A listagem do programa encontra-se no Apêndice A deste trabalho.

4.2 - DESCRIÇÃO DOS TESTES

O algoritmo foi testado com problemas gerados aleatoriamente com d_{ij} no intervalo $[5,100]$. O tamanho das redes (n) variou de 15 a 200 e o número de medianas de 5 a $n/3$ (a literatura indica que para $n/3$ medianas o problema torna-se mais difícil). Devido ao grande número de testes e tempo de execução de cada um, fixou-se o número de iterações em 1000 (em alguns casos, 2000).

Foram realizados cinco tipos de testes e cada um deles possui uma entrada e seus objetivos específicos, a saber:

TESTE 1

ENTRADA - Para cada $n = 25, 50, 75, 100$ e 125 gerou-se a matriz de distâncias e realizaram-se os testes com número de medianas igual a 5, 10 e $n/3$.

OBJETIVOS - Tempo total de cada teste e comparação entre os resultados obtidos antes de entrar pela primeira vez na árvore e após sair do programa (solução ótima ou 1000 iterações).

TESTE 2

ENTRADA - Para $n = 25$ foram geradas cinco matrizes diferentes e para cada matriz realizaram-se os testes com número de medianas igual a 5, 8 e 10.

OBJETIVOS - Observação da variação dos resultados e comparação entre os tempos de execução.

TESTE 3

ENTRADA - Para $n = 15$ foram geradas cinco matrizes diferentes e para cada matriz realizaram-se os testes com número de medianas igual a 5. As iterações foram limitadas em 1000 e no último caso em 2000.

OBJETIVOS - Semelhante ao anterior, mas tentando comparar a solução encontrada antes do "branch and bound" e depois, quando a árvore fica completamente esgotada. O número de iterações foi aumentado com o objetivo de mostrar que, neste caso, a solução ótima foi encontrada.

TESTE 4

ENTRADA - Para $n = 200$ e número de medianas igual a 5.

OBJETIVOS - Teste da capacidade de processamento do programa, tempo de execução e diferença entre os resultados antes de entrar pela primeira vez na árvore e após sair do programa (solução ótima ou 1000 iterações).

TESTE 5

ENTRADA - Para $n = 50$ foram realizados quatro testes para p variando em torno de $n/3$ ($p = 15, 16, 17, 18$).

OBJETIVOS - Verificação da performance do programa para $p = n/3$.

4.3 - APRESENTAÇÃO DOS RESULTADOS

Os tempos indicados excluem o tempo necessário para gerar a matriz de distâncias ou lê-la, caso se considere uma já existente. Os resultados dos testes encontram-se nas Tabelas 4.1, 4.2, 4.3, 4.4 e 4.5 que contêm:

- Número de nós (n).
- Número de medianas (p).
- Limitante superior (LS) antes e depois de entrar no "branch and bound".
- Limitante inferior (Zd_max).
- Tipo de solução que está classificada em: Ótima, Não Ótima e Incumbente. Dentro da Rotina de Subgradiente tem-se:
 - . Solução Ótima implicando em término do programa;
 - . Solução Não Ótima implicando em continuação do programa com a Rotina de Branch and Bound.
- Dentro da Rotina de Subgradiente com Branch and Bound tem-se:
 - . Solução Ótima implicando em término do programa;
 - . Solução Incumbente implicando em alteração (diminuição) do limitante superior (LS) proporcionando uma solução viável melhor;
 - . Solução Não Ótima quando não há alteração no LS.
- Número de iterações na Rotina de Subgradiente e número de iterações total (incluindo as duas rotinas).
- "Gap" de Dualidade inicial e final calculado pela equação:

$$\text{"gap"} = \frac{\text{LS} - \text{Zd_max}}{\text{LS}} \times 100\%$$

- Tempo total (incluindo as duas rotinas).
- Número de recomeços da árvore de busca.

As Tabelas 4.1 e 4.2 apresentam os resultados do Teste 1 e 2, respectivamente. Pode-se notar uma variação enorme dos resultados. Para 25 e 5, por exemplo, em duas repetições ocorreu a

solução ótima no nó inicial e em três houve entrada no "branch and bound". Os resultados de tempo podem ter alguma correlação se considerar-se, apenas, quando o algoritmo entra na árvore e quando não entra, separadamente.

A Tabela 4.3 apresenta alguns casos, nos testes mostrados, em que o algoritmo entra no "branch and bound" e sai com uma solução ótima. Vale comparar os dois últimos exemplos, pois, quando o número de iterações foi aumentado para 2000 (último exemplo), o algoritmo convergiu para o ótimo. Portanto, nota-se que, se não houvesse limitação no número de iterações (penúltimo exemplo), a solução ótima seria encontrada (que poderia ser a própria solução incumbente).

A Tabela 4.4 mostra um caso de maior exigência do sistema onde $n = 200$. Como houve limitação de iterações em 1000 não houve convergência para o ótimo. Pode-se notar, no entanto, que a solução incumbente encontrada é melhor do que a solução no início da árvore.

A Tabela 4.5 apresenta o estudo de $p = n/3$ e sua vizinhança. Em nenhum dos casos o algoritmo convergiu para o ótimo. Como esse comportamento verificou-se para outros valores de p , os resultados deste teste não são conclusivos.

Observou-se, durante a execução dos testes, que à medida em que p cresce em relação a n , há uma diminuição da convergência de Zd_{max} em relação à LS.

Seguem as tabelas 4.1, 4.2, 4.3, 4.4 e 4.5.

TABELA 4.1

TESTE 1

NUM. NOS	NUM. MED.	ROTINA DE SUBGRADIENTE					ROTINA DE SUBGRADIENTE COM BRANCH AND BOUND					
		LS	ZD MAX	SOLUCAO	N. ITER	GAP INICIAL (%)	LS	RECOMECOS	SOLUCAO	N. ITER	TEMPO (seg)	GAP FINAL (%)
25	5	232	141	N. OTIMA	91	39,22	228	1	INCUMBENT	1000	445	38,16
	10	141	95	OTIMA	31	32,62					13	
	8	169	113	OTIMA	23	33,14					10	
50	5	603	531	N. OTIMA	186	11,94	603		N. OTIMA	1000	1294	11,94
	10	368	289	N. OTIMA	264	21,47	368		N. OTIMA	1000	1330	21,47
	17	284	177	N. OTIMA	141	37,68	261	5	INCUMBENT	1000	1465	32,18
75	5	943	781	N. OTIMA	242	17,18	943		N OTIMA	1000	2627	17,18
	10	562	477	N. OTIMA	296	15,12	542	1	INCUMBENT	1000	2670	11,99
	25	333	259	N. OTIMA	191	22,22	333		N OTIMA	1000	3410	22,22

(continua)

Tabela 4.1 - Conclusão.

NUM. NOS	NUM. MED.	ROTINA DE SUBGRADIENTE					ROTINA DE SUBGRADIENTE COM BRANCH AND BOUND					
		LS	ZD MAX	SOLUCAO	N.ITER	GAP INICIAL (%)	LS	RECOMECOS	SOLUCAO	N.ITER	TEMPO (seg)	GAP FINAL (%)
100	5	1388	1132	N. OTIMA	242	18,44	1388		N OTIMA	1000	4247	18,44
	10	877	699	N. OTIMA	241	20,30	857	1	INCUMBENT	1000	4262	18,44
	33	430	347	N. OTIMA	241	19,30	430		N OTIMA	1000	6173	19,30
125	5	1811	1462	N. OTIMA	358	19,24	1811		N OTIMA	1000	7057	19,24
	10	1156	890	N. OTIMA	292	23,01	1106	4	INCUMBENT	1000	6693	19,53
	42	482	415	N. OTIMA	291	13,90	482		N OTIMA	1000	10677	13,90

TABELA 4.2

TESTE 2

NUM. NOS	NUM. MED.	ROTINA DE SUBGRADIENTE					ROTINA DE SUBGRADIENTE COM BRANCH AND BOUND					
		LS	ZD MAX	SOLUCAO	N. ITER	GAP INICIAL (%)	LS	RECOMECOS	SOLUCAO	N. ITER	TEMPO (seg)	GAP FINAL (%)
25	5	240	152	N. OTIMA	93	36,67	205	2	INCUMBENT	1000	446	25,85
	10	180	81	N. OTIMA	91	55,00	129	6	INCUMBENT	1000	466	37,21
	8	166	99	N. OTIMA	91	40,36	161	1	INCUMBENT	1000	474	38,51
25	5	306	258	OTIMA	139	15,65					121	
	10	214	112	OTIMA	34	47,66					36	
	8	223	134	OTIMA	44	39,91					42	
25	5	216	130	OTIMA	17	39,81					18	
	10	143	87	OTIMA	28	39,16					22	
	8	178	103	OTIMA	31	42,13					19	
25	5	251	213	N. OTIMA	104	15,14	247	1	INCUMBENT	1000	441	13,77
	10	191	98	N. OTIMA	91	48,69	164	2	INCUMBENT	1000	521	40,24
	8	228	120	N. OTIMA	91	47,37	192	4	INCUMBENT	1000	475	37,50
25	5	191	155	N. OTIMA	97	18,45	191		OTIMA	619	260	18,45
	10	146	87	OTIMA	40	40,41					23	
	8	170	101	N. OTIMA	91	40,49	164		INCUMBENT	1000	474	38,41

TABELA 4.3

TESTE 3

NUM. NOS	NUM. MED.	ROTINA DE SUBGRADIENTE					ROTINA DE SUBGRADIENTE COM BRANCH AND BOUND					
		LS	ZD MAX	SOLUCAO	N. ITER	GAP INICIAL (%)	LS	RECOMECOS	SOLUCAO	N. ITER	TEMPO (seg)	GAP FINAL (%)
15	5	131	61	N. OTIMA	71	53,44	104	4	OTIMA	885	206	41,35
	5	144	71	N. OTIMA	71	50,69	124	2	OTIMA	250	56	42,74
	5	144	90	OTIMA	27	37,50					6	
	5	173	89	N. OTIMA	71	48,55	164	1	INCUMBENT	1000	239	45,73
	5	143	77	N. OTIMA	71	46,15	143		OTIMA	1298	323	46,15

TABELA 4.4

TESTE 4

NUM. NOS	NUM. MED.	ROTINA DE SUBGRADIENTE					ROTINA DE SUBGRADIENTE COM BRANCH AND BOUND					
		LS	ZD MAX	SOLUCAO	N. ITER	GAP INICIAL (%)	LS	RECOMECOS	SOLUCAO	N. ITER	TEMPO (seg)	GAP FINAL (%)
200	5	3150	2329	N. OTIMA	441	26,06	3056	5	INCUMBENT	1000	16461	23,79

TABELA 4.5

TESTE 5

NUM. NOS	NUM. MED.	ROTINA DE SUBGRADIENTE					ROTINA DE SUBGRADIENTE COM BRANCH AND BOUND					
		LS	ZD MAX	SOLUCAO	N. ITER	GAP INICIAL (%)	LS	RECOMECOS	SOLUCAO	N. ITER	TEMPO (seg)	GAP FINAL (%)
50	15	303	189	N. OTIMA	141	37,62	293	1	INCUMBENT	1000	1424	35,49
	16	270	183	N. OTIMA	141	32,22	270		N.OTIMA	1000	1437	32,22
	17	284	177	N. OTIMA	141	37,68	261	5	INCUMBENT	1000	1465	32,18
	18	272	171	N. OTIMA	141	37,13	267	1	INCUMBENT	1000	1482	35,96

CAPÍTULO 5

COMENTÁRIOS FINAIS

O objetivo deste trabalho foi estudar o problema das p -medianas e os métodos (heurísticos e exatos) existentes para sua resolução. Desenvolveu-se um algoritmo para resolução exata do problema, utilizando uma formulação de programação inteira e um método de subgradientes associado à relaxação lagrangeana. Este método comprovadamente obtém bons limitantes que usados em um algoritmo do tipo "branch and bound" tornam possível solucionar de modo exato problemas de grande porte.

De acordo com os resultados computacionais apresentados pode-se concluir que, apesar de não se ter esgotado a árvore na maioria dos casos, houve uma redução nos "gaps" de dualidade quando o "branch and bound" foi executado. Então, mesmo sem garantir uma solução ótima pode-se garantir, nestes casos, uma melhor solução. Em uma situação prática convém deixar o algoritmo executar até o fim, sem limitar o número de iterações, para avaliar realmente suas vantagens.

Quando as matrizes são diferentes, mesmo que para um mesmo n e p , nada se pode inferir, ou seja, não existe um comportamento padrão (o que era de se esperar já que as matrizes são geradas aleatoriamente). Em alguns casos o ótimo é alcançado sem entrar na árvore; em outros, dentro da árvore, o ótimo pode ou não ser alcançado dependendo do número de iterações.

Há que se avaliar o problema quando n se aproxima de 200 pois neste caso o tempo de processamento é elevado.

Neste algoritmo não se usou nenhuma heurística para o cálculo do limitante superior inicial. A literatura indica que para um bom LS inicial, o "gap" de dualidade é menor no início da árvore e portanto há menos nós na árvore.

REFERÊNCIAS BIBLIOGRÁFICAS

- BEASLEY, J.E. A note on solving large P-MEDIAN problems. **European Journal of Operational Research**, 21:270-273, 1985.
- BOFFEY, T.B.; KARKAZIS, J. p-Medians and Multi-Medians. **Journal of the Operational Research Society**, 35(1):57-64, 1984.
- CHRISTOFIDES, N.; BEASLEY, J.E. A tree search algorithm for the p-median problem. **European Journal of Operational Research**, 10(2):196-204, 1982.
- CORNUEJOLS, G.; FISHER, M.L.; NEMHAUSER, G.L. Location of bank accounts to optimize float : an analytic study of exact and approximate algorithms. **Management Science** 23:789-810, 1977.
- DIEHR, G. An algorithm for the p-median problem. Los Angeles, CA. Western Man. Sci. Institute, University of California, 1972. (**Working paper 191**).
- EVERETT III, H. Generalized lagrange multiplier method for solving problems of optimum allocation of resources. **Operations Research**, 11:399-417, 1963.
- EFROYMSON, M.A.; RAY, T.L. A branch-bound algorithm for plant location. **Operations Research**, 14:361-368, 1966.
- FISHER, M.L. The lagrangean relaxation method for solving integer programming problems. **Management Science**, 27(1):1-18, 1981.
- FISHER, M.L. An application oriented guide to lagrangean relaxation. **Interfaces**, 15(2):10-21, 1985.
- GARFINKEL, R.S.; NEEBE, A.W.; RAO, M.R. An Algorithm for the m-median plant location problem. **Transportation Science**, 8:217-236, 1974.

- GEOFFRION, A.M. Lagrangian relaxation and its uses in integer programming. **Mathematical Programming Study**, 2:82-114, 1974.
- HAKIMI, S.L. Optimum locations of switching centers and the absolute centers and medians of a graph. **Operations Research**, 12:450-459, 1964.
- HAKIMI, S.L. Optimum distribution of switching centers in a communication network and some related graph theoretic problems. **Operations Research**, 13:462-475, 1965.
- HANDLER, G.Y.; MIRCHANDANI, P.B. Location on networks theory and algorithms. Cambridge, MA. The MIT Press, 1979.
- HELD, M.; KARP, R.M. The traveling salesman problem and minimum spanning trees. **Operations Research**, 18:1138-1162, 1970.
- HELD, M.; WOLFE, P.; CROWDER, H.P. Validation of subgradient optimization. **Mathematical Programming**, 6(1):62-88, 1974.
- JARVINEN, P.; RAJALA, J.; SINERVO, H. A branch and bound algorithm for seeking the p-median. **Operations Research**, 20:173-178, 1972.
- KHUMAWALA, M.B.; NEEBE, A.W.; DANNENBRING, D.G. A note on El-Shaieb's new algorithm for location sources among destinations. **Management Science**, 21(2):230-233, 1974.
- KUSIAK, A.; VANNELLI, A.; KUMAR, K.R. Clustering analysis: models and algorithms. In School on Combinatorial Optimization, Rio de Janeiro, 8-19 jul. 1985.
- MARANZANA, F.E. On the location of supply points to minimize transport costs. **Operational Research Quarterly**, 15:261-270, 1964.
- MULVEY, J.M. Multivariate stratified sampling by optimization. **Management Science**, 29(6):715-724, 1983.

- NARULA, S.C.; OGBU, U.I.; SAMUELSSON, H.M. An algorithm for the p-median problem. **Operations Research**, 25:709-713, 1977.
- NEEBE, A.W. A branch and bound algorithm for the p-median transportation problem. **Journal of the Operational Research Society**, 29(10):989-995, 1978.
- OLIVO, A.A.; SENNE E.L.F. Implementação de um método de subgradientes para o problema das p-medianas. In: CONGRESSO NACIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL (CNMAC), 11., Ouro Preto, ago. 1988. **Resumo dos Trabalhos**. [Rio de Janeiro], SBMAC, 1988. p. 8-10.
- POLJAK, B.T. A general method for solving extremum problems. **Soviet Mathematics Dokl.**, 8(3):593-597, 1967.
- RAGGI, L.A.; GALVÃO, R.D. Um algoritmo para o problema das p-medianas com custos fixos. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL (SOBRAPO), 15. Rio de Janeiro, 8-11 nov. 1982. **Anais**. [Rio de Janeiro], SOBRAPO, 1982. p. 320-334.
- REVELLE, C.; SWAIN, R.W. Central facilities location. **Geographical Analysis**, 2:30-42, 1970.
- TEITZ, M.B.; BART, P. Heuristic methods for estimating the vertex median of a weighted graph. **Operations Research**, 16:955-961, 1968.
- TENENBAUM, A.M.; AUGENSTEIN, M.J. **Data structures using Pascal**. Englewood Clifles, NJ. Prentice-Hall, 1981.

APÊNDICE A

LISTAGEM DO PROGRAMA

```
{SR+,U+}
program k_mediana;

const
  dim_n = 205;          (* dim_n = n          *)
  dim_p = 9384;        (* dim_p = (n - p).p    *)
  dim_d = 20910;       (* dim_d = (n.n - n) div 2 *)
type
  nopt = ^tipono;
  tipono = record
    pl,
    pm      : real;
    valor   : integer;
    ant,
    filhoe,
    filhod  : nopt;
  end;
var
  ch      : char;
  i,
  j,
  k,
  n,
  p,
  ls,
  val,
  d_min,
  conte,
  ls_incumb,
  ls_inicial,
  status,
  tam_arv,
```

```

rec,
iter_inicial,
itertot  : integer;
fim,
arvore,
documenta : boolean;
zd,
tempo,
zd_max_inicial,
zd_max   : real;
d        : array [0..dim_d] of integer;
pos      : array [1..dim_p] of integer;
e,
posmed,
posicao   : array [1..dim_n] of integer;
sub,
lambda   : array [1..dim_n] of real;
pp,
pq,
pai      : nopt;
arq      : text;

function RELOGIO : real;

(* Retorna o tempo atual em segundos *)
(* ----- *)
var
  regs : record
    AX,BX,CX,DX,BP,SI,DI,DS,ES,flags : integer;
  end;
  hor,
  min,
  seg : real;
begin
  with regs do
    begin

```

```
    AX := $2C00;
    msdos (regs);
    hor := hi(CX);
    min := lo(CX);
    seg := hi(DX);
    relógio := 3600*hor + 60*min + seg;
end;
end;

function ENDER (i,j : integer) : integer;
begin
    if i < j then
        ender := e[i] + j - i - 1
    else
        if i > j then
            ender := e[j] + i - j - 1
        else
            ender := 0;
        end;
    end;
end;

procedure ESPERA;
var
    x : char;
begin
    if ch = 'v' then
        begin
            write('Aperte uma tecla... ');
            readln(x);
        end;
    end;
end;
```

A.4

```
function MAKETREE (VAL : integer) : NOPT;  
var  
  pp : nopt;  
begin  
  new(pp);  
  tam_arv := tam_arv + 1;  
  pp^.valor := val;  
  pp^.ant := nil;  
  pp^.filhoe := nil;  
  pp^.filhod := nil;  
  maketree := pp;  
end;
```

```
procedure CRIAFILHOE (VAR PP : NOPT; VAL : INTEGER);  
var  
  pq : nopt;  
begin  
  if pp = nil then  
    writeln(arq,'** Criacao invalida - No = NIL')  
  else  
    if pp^.filhoe <> nil then  
      writeln (arq,'** Criacao invalida - Ja existe filho a esquerda')  
    else  
      begin  
        pq := maketree(val);  
        pq^.ant := pp;  
        pp^.filhoe := pq;  
        pp := pq;  
      end;  
end;  
end; (* CRIAFILHOE *)
```

A.5

```
procedure CRIAFILHOD (VAR PP : NOPT ; VAL : INTEGER);
var
  pq : nopt;
begin
  if pp = nil then
    writeln(arq,'** Criacao invalida - No = NIL')
  else
    if pp^.filhod <> nil then
      writeln (arq,'** Criacao invalida - Ja existe filho a direita')
    else
      begin
        pq := maketree(val);
        pq^.ant := pp;
        pp^.filhod := pq;
        pp := pq;
      end;
END; (* CRIAFILHOD *)

procedure TITULO;
begin
  clrscr;
  textcolor(0);
  textbackground(7);
  writeln(' ':30,' PROGRAMA K-MEDIANA ',' ':30);
  textcolor(7);
  textbackground(0);
  writeln;
end;

procedure ATUALIZA_LIMITES(pp : nopt);
begin
  pp^.pl := zd_max;
  pp^.pm := zd;
end;
```

```
procedure INICIALIZA_ARVORE;  
begin  
  if ls < ls_incumb then  
    begin  
      TITULO;  
      rec := rec + 1;  
    end;  
  ls_incumb := ls;  
  zd_max := zd_max_inicial;  
  for i := 1 to p do  
    posmed[i] := pos[i];  
  pai := MAKETREE(0);  
  ATUALIZA_LIMITES(pai);  
  pp := pai;  
  arvore := true;  
  conte := 0;  
end;
```

```
procedure MOSTRA_ARVORE;  
var  
  pq : nopt;  
begin  
  pq := pp;  
  write('*** Arvore: ');  
  while pq <> pai do  
    begin  
      write(pq^.valor, '  ');  
      pq := pq^.ant;  
    end;  
  writeln;  
end;
```

```
procedure QUICKSORT (L,R : INTEGER);
var
  x,w   : real;
  i,j,k : integer;
begin  (* QuickSort *)
  i:=l;
  j:=r;
  x:=sub[(l+r) div 2];
  repeat
    while sub[i] < x do i:=i+1;
    while x < sub[j] do j:=j-1;
    if i <= j then
      begin
        w:=sub[i];
        sub[i]:=sub[j];
        sub[j]:=w;
        k:=pos[i];
        pos[i]:=pos[j];
        pos[j]:=k;
        i:=i+1;
        j:=j-1;
      end
    until i > j;
    if l < j then QUICKSORT (L,J);
    if i < r then QUICKSORT (I,R);
end;  (* QUICKSORT *)
```

A.8

```
function ACHA_POSICAO(v : integer) : integer;
var
  i      : integer;
  achei  : boolean;
begin
  i := 1;
  achei := false;
  while not achei do
    if pos[i] = v then
      achei := true
    else
      i := i + 1;
  achaposicao := i;
end;
```

```
procedure SUBGRADIENTE;
var
  i,j,k,l,z,
  iter,
  np,
  pass      : integer;
  viavel    : boolean;
  pi,
  teta,
  zd_art,
  subgrad   : real;
  med       : array [1..dim_n] of integer;
begin
  pass := 0;
  iter := 0;
  if arvore then
    pi := 1
  else
    pi := 2;
  if not documenta then
    TITULO;
```

```

repeat
  iter := iter + 1;
  pass := pass + 1;
  if documenta then
    writeln(arq,'----':10,' Iteracao ',iter,' ---- ','Pass ',
            pass,' ----')
  else
    begin
      gotoxy(5,3);
      clreol;
      write('*** Iteracao ',iter,' Pass ',pass);
      if arvore then
        write(' No ',tam_arv,' Recomecos : ',rec);
      end;
    end;

(* Resolver problema lagrangeano *)
(* ----- *)
d[0] := 0;
for i := 1 to n do
  begin
    sub[i] := 0;
    pos[i] := i;
    med[i] := 9999;
    for j := 1 to n do
      begin
        k := ENDER(i,j);
        if d[k] < lambda[j] then
          sub[i] := sub[i] + d[k] - lambda[j];
        end;
      end;
  end;
if documenta then
  begin
    (* Custos = D(i,j) *)
    (* ----- *)
    writeln(arq,'*** custos:');
  end;

```

```

    for i := 1 to n do
        writeln(arq,' ':6,'c[' ,i,'] = ',sub[i]:1:3);
    end;

(* Ordena a matriz de custos e pos(i) *)
(* ----- *)
QUICKSORT(1,n);

if arvore then
    if not documenta then
        begin
            gotoxy(5,14);
            MOSTRA_ARVORE;
        end;

(* Acertar o conjunto de medianas *)
(* ----- *)
if arvore then
    begin

        (* Retira os filhos direitos *)
        (* ----- *)
        pq := pp;
        while pq <> pai do
            begin
                val := pq^.valor;
                if val < 0 then
                    begin
                        val := - val;
                        j := acha_posicao(val);
                        subgrad := sub[j];
                        for i := j+1 to n do
                            begin
                                pos[i-1] := pos[i];
                                sub[i-1] := sub[i];
                            end;
                    end;
            end;
    end;

```

```

pos[n] := val;
sub[n] := subgrad;
if documenta then
begin
for i := 1 to p do
write(arq, ' ', pos[i], ' ');
writeln(arq);
ESPERA;
end;
end;
pq := pq^.ant;
end;

(* Inclui os filhos esquerdos *)
(* ----- *)
pq := pp;
np := p;
while pq <> pai do
begin
val := pq^.valor;
if val > 0 then
begin
j := acha_posicao(val);
subgrad := sub[j];
pos[j] := pos[np];
sub[j] := sub[np];
pos[np] := val;
sub[np] := subgrad;
np := np - 1;
end;
pq := pq^.ant;
end;
end;
end;

```

```

(* Calculo do Dual --> ZD *)
(* ----- *)
zd := 0;
for i := 1 to p do
  begin
    med[pos[i]] := -1;
    zd := zd + sub[i];
  end;
for i := 1 to n do
  zd := zd + lambda[i];
if documenta then
  writeln(arq,'*** zd = ',zd:1:3);

(* Atualiza o limite inferior --> ZD_MAX *)
(* ----- *)
if zd > zd_max then
  begin
    pass := 0;
    zd_max := zd;
    zd_art := zd_max;
  end;

(* Calcular subgradientes para verificar viabilidade *)
(* e calculo do primal *)
(* ----- *)

viavel := true;
d[0] := 9999;
z := 0;

```

```

for i := 1 to n do
  begin
    sub[i] := 1;
    if med[i] = -1 then
      sub[i] := 0
    else
      begin
        for j := 1 to p do
          begin
            k := ENDER(i, pos[j]);
            if d[k] < lambda[i] then
              sub[i] := sub[i] - 1;
            if d[k] < med[i] then
              med[i] := d[k];
          end;
        z := z + med[i];
      end;
    if sub[i] <> 0 then viavel := false;
  end;

if documenta then
  begin
    writeln(arq, '*** subgradientes:');
    for i := 1 to n do
      writeln(arq, ' ':6, 'sub[' , i, ']' = ', sub[i]:1:3);
    writeln(arq, '*** z = ', z);
  end;

(* Atualizacao do limitante superior --> LS *)
(* ----- *)
if z < ls then
  begin
    ls := z;
    zd_art := zd_max;
  end
else

```

```

(* Nao houve melhora no ls *)
(* ----- *)
zd_art := zd_art + 0.2*(ls - zd_art);

(* zd_art nao pode superar ls *)
(* ----- *)
if zd_art > ls then
  zd_art := zd_max;
if not documenta then
  begin
    gotoxy(5,6);
    clreol;
    writeln('*** limite superior: ',ls);
  end
else
  writeln(arq,'*** limite superior: ',ls);
if not documenta then
  begin
    gotoxy(5,8);
    clreol;
    writeln('*** zd: ',zd:1:4,'    zd_max: ',zd_max:1:4);
  end
else
  writeln(arq,'*** zd: ',zd:1:4,'    zd_max: ',zd_max:1:4);

(* pi = 2 para 2*n iteracoes. *)
(* Depois e' dividido ao meio a cada 5 iteracoes *)
(* ----- *)
if not viavel then
  begin
    if (iter > 2*n) or (arvore) then
      if pass > 4 then
        begin
          pi := pi/2;

```

```

    if documenta then
        writeln(arq,'*** pi corrigido para ',pi,
            ' apos ',pass,' iteracoes.');
```

$$\text{pass} := 0;$$

```

    end;
if not documenta then
    begin
        gotoxy(5,10);
        clreol;
        writeln('*** pi: ',pi:1:6);
    end
else
    writeln(arq,'*** pi: ',pi:1:6);
teta := 0;
for i := 1 to n do
    teta := teta + sub[i] * sub[i];
if not arvore then
    teta := pi * (ls - zd_art) / teta
else
    teta := pi * (ls - zd) / teta;
if documenta then
    writeln(arq,'*** teta = ',teta);
if not documenta then
    begin
        gotoxy(5,12);
        clreol;
        writeln('*** teta: ',teta:1:6);
    end;
for i := 1 to n do
    begin
        lambda[i] := lambda[i] + teta * sub[i];
        if lambda[i] < 0 then
            lambda[i] := 0;
    end;
end;
```

```

if documenta then
begin
  writeln(arq,'*** lambda corrigido:');
  for i := 1 to n do
    writeln(arq,' ':6,'lambda[' ,i,'] = ',lambda[i]:1:5);
  end;
end;

(* Caso tenha entrado na arvore, *)
(* so vai executar 30 iteracoes do subgradiente. *)
(* ----- *)
if arvore then
  if iter > 29 then
    pi := 0.004;
    itertot := itertot + 1;
until (viavel) or (pi < 0.005) or (ls - zd_max <= 0.05) or
  (ls < ls_incumb) or (itertot > 999);
if viavel then
  status := 0
else
if (zd_max <= ls) and (ls - zd_max <= 0.05) then
  status := 1
else
if ls < ls_incumb then
  status := 2
else
  status := 3;

```

```

if documenta then
  begin
    writeln(arq,'*** Numero de nos: ',n);
    writeln(arq,'*** Numero de medianas: ',p);
  end
else
  begin
    gotoxy(5,14);
    write(arq,'*** Status da solucao: ');
    if not arvore then
      case status of
        0: writeln(arq,'OTIMA - SUBGRADIENTE NULO');
        1: writeln(arq,'OTIMA');
        3: writeln(arq,'NAO OTIMA');
      end
    else
      case status of
        0: writeln(arq,'SUBGRADIENTE NULO - NO ESGOTADO');
        1: writeln(arq,'NO ESGOTADO - POR LIMITES');
        2: writeln(arq,'RECOMECA A ARVORE');
        3: writeln(arq,'NAO OTIMA');
      end;
      writeln(arq,'*** Valor da solucao, ls = ',ls,
        '      z = ',z,'      zd = ',zd:1:2,
        '      (dual: ',zd_max:1:2,')');
      writeln(arq,'*** Numero de iteracoes: ',iter);
      writeln(arq,'*** Alocacao das medianas: ');
      write(arq,pos[1]);
      for i := 2 to p do
        write(arq,', ',pos[i]);
      writeln(arq);
    end;
  if ((not arvore) and (status < 2)) or (itertot > 999) then
    fim := true;
end;    (* SUBGRADIENTE *)

```

```

procedure CALCULA_ALFA (var d_min : integer);
const
  infinito = 1.0e+30;
var
  pq      : nopt;
  alfa    : array [1..dim_n] of real;
  alfa_min : real;
begin
  if documenta then
    begin
      gotoxy(1,16);
      for i := 1 to p do
        write(arq,'POS[' ,i,'] = ',pos[i],' ');
      ESPERA;
    end;
    for i := 1 to p do
      begin
        alfa[pos[i]] := 0;
        for j := 1 to n do
          begin
            k := ENDER(pos[i],j);
            if d[k] < lambda[j] then
              alfa[pos[i]] := alfa[pos[i]] + d[k] - lambda[j];
          end;
        end;
      end;
    pq := pp;
    while pq <> pai do
      begin
        if pq~.valor > 0 then
          alfa[pq~.valor] := infinito;
        pq := pq~.ant;
      end;
    alfa_min := alfa[pos[1]];
    d_min := pos[1];

```

```

for i := 2 to p do
  begin
    if alfa[pos[i]] < alfa_min then
      begin
        alfa_min := alfa[pos[i]];
        d_min := pos[i];
      end;
    end;
END;   (* Calcula_Alfa *)

(*****
                                     PROGRAMA PRINCIPAL
*****
)

begin
  TITULO;
  gotoxy(1,10);
  write('  Numero de medianas ..... ');
  readln(p);
  write('  (L)er ou (g)erar os dados? ..... ');
  readln(ch);
  if ch = 'l' then
    begin
      assign(arq,'a:dados25.med');
      reset(arq);
      readln(arq,n,k);
      for i := 1 to n-1 do
        read(arq,e[i]);
        readln(arq);
        for i := 1 to k do
          read(arq,d[i]);
        end
      end;
    else
      begin
        write('  Numero de nos ..... ');
        readln(n);

```

```

write('    Gravar os dados em arquivo? (s/n): ');
readln(ch);
randomize;
k := 0;
for i := 1 to n-1 do
  begin
    e[i] := k + 1;
    for j := i+1 to n do
      begin
        k := k + 1;
        d[k] := random(96)+5;
      end;
    end;
if ch = 's' then
  begin
    assign(arq,'a:dados25.med');
    rewrite(arq);
    writeln(arq,n,' ',k);
    for i := 1 to n-1 do
      write(arq,e[i],' ');
    writeln(arq);
    for i := 1 to k do
      write(arq,d[i],' ');
    close(arq);
  end;
end;
write('    Documentacao completa? (s/n) ..... ');
readln(ch);
documenta := ch = 's';
write('    (V)ideo ou (i)mpressora? ..... ');
readln(ch);
assign(arq,'con');
if ch = 'i' then
  assign(arq,'prn');
rewrite(arq);

```

```

if documenta then
begin
  writeln(arq,'*** distancias:');
  d[0] := 0;
  for i := 1 to n do
  begin
    for j := 1 to n do
    begin
      k := ENDER(i,j);
      write(arq,d[k]:4);
    end;
    writeln(arq);
  end;
  ESPERA;
end;
d[0] := 9999;
for i := 1 to n do
begin
  d_min := 9999;
  for j := 1 to n do
  begin
    k := ENDER(i,j);
    if d[k] < d_min then
      d_min := d[k];
    end;
  lambda[i] := d_min;
end;
ls := 32767;          (* Maior inteiro = infinito *)
rec := 0;             (* Numero de recomecos na arvore *)
ls_incumb := 0;
itertot := 0;
tam_arv := 0;
zd_max := 0;
fim := false;
arvore := false;

```

```

(* CHAMADA DA PROCEDURE PARA CALCULO DO SUBGRADIENTE *)
(* ----- *)
tempo := RELOGIO;
SUBGRADIENTE;

clrscr;
writeln(arq,'** LIMITE SUPERIOR   = ',LS);
writeln(arq,'** ZD_MAX           = ',ZD_MAX:1:2);
writeln(arq,'** TOTAL ITERACOES   = ',ITERTOT);
writeln(arq,'** ALOCACAO DAS MEDIANAS:');
for i := 1 to p do
  write(arq,'  ',pos[i]);
writeln(arq);
iter_inicial := itertot;
ls_inicial := ls;
zd_max_inicial := zd_max;
ls_incumb := 0;
INICIALIZA_ARVORE;

while (not fim) do
  begin
    if conte < p then
      begin
        CALCULA_ALFA(va1);
        CRIAFILHOE(PP,va1);
        conte := conte + 1;
        SUBGRADIENTE;
        if status = 2 then
          INICIALIZA_ARVORE
        else
          ATUALIZA_LIMITES(pp);
      end;
  end;

```

```

while ((status < 2) or (zd_max > 1s) or (conte = p))
    and (not fim) do
begin
    (* verifica se vem de um filho direito *)
    (* ----- *)
    val := pp^.valor;
    if val > 0 then
        conte := conte - 1;
    pp := pp^.ant;
    zd_max := pp^.pl;
    zd := pp^.pm;
    while (pp <> pai) and (pp^.filhod <> nil) do
        begin
            val := pp^.valor;
            if val > 0 then
                conte := conte - 1;
            pp := pp^.ant;
            zd_max := pp^.pl;
            zd := pp^.pm;
        end;
    if pp = pai then
        if pp^.filhod <> NIL then
            fim := true;
    if not fim then
        begin
            CRIAFILHOD(pp,-val);
            SUBGRADIENTE;
            if status = 2 then
                INICIALIZA_ARVORE
            else
                ATUALIZA_LIMITES(pp);
        end;
    end;
end;
end;

```

```
TITULO;
writeln(arq,** LIMITE SUPERIOR INICIAL = ',ls_inicial);
writeln(arq,** LIM.SUP.INCUMBENTE     = ',ls_incumb);
writeln(arq,** LIMITE INFERIOR INICIAL = ',trunc(zd_max_inicial));
writeln(arq,** ITERACOES NO INICIO    = ',iter_inicial);
writeln(arq,** TOTAL ITERACOES       = ',itertot);
writeln(arq,** TAMANHO DA ARVORE     = ',tam_arv);
writeln(arq,** ALOCACAO DAS MEDIANAS:');
for i := 1 to p do
  write(arq,' ',posmed[i]);
writeln(arq);
tempo := RELOGIO - tempo;
writeln(arq,** TEMPO                  = ',tempo:1:2,'
           segundos.');
```

```
writeln(arq,** NUMERO DE RECOMECOS    = ',rec);

end.
```