

UNIVERSIDADE FEDERAL FLUMINENSE
INSTITUTO DE COMPUTAÇÃO
DEPARTAMENTO DE CIÊNCIA DA COMPUTAÇÃO

Gabriel Machado Vianna

**Uma heurística híbrida com mineração de dados para o
problema das p -Medianas**

Niterói
2009

Gabriel Machado Vianna

Uma heurística híbrida com mineração de dados para o problema das *p*-Medianas

**Monografia apresentada ao Departamento
de Ciência da Computação da Universidade
Federal Fluminense como parte dos requisi-
tos para obtenção do Grau de Bacharel em
Ciência da Computação.**

Orientadores: Alexandre Plastino e Simone de Lima Martins

Niterói

2009

Gabriel Machado Vianna

Uma heurística híbrida com mineração de dados para o problema das *p*-Medianas

Monografia apresentada ao Departamento de Ciência da Computação da Universidade Federal Fluminense como parte dos requisitos para obtenção do Grau de Bacharel em Ciência da Computação.

Aprovado em Dezembro de 2009

BANCA EXAMINADORA

Prof. Alexandre Plastino, D.Sc.
Orientador
UFF

Profa. Simone de Lima Martins, D.Sc.
Orientadora
UFF

Profa. Isabel Cristina Mello Rosseti, D.Sc.
UFF

Puca Huachi Vaz Penna, M.Sc.
UFF

Niterói
2009

RESUMO

Dados um conjunto F de m potenciais instalações, um conjunto U de n clientes, o problema das p -medianas consiste em encontrar um subconjunto de F com p instalações tal que o custo de servir todos os clientes seja minimizado. A incorporação de técnicas de mineração de dados em heurísticas tem apresentado bons resultados na obtenção de melhores soluções e na aceleração do processo heurístico. Este trabalho tem por objetivo apresentar um módulo de mineração de dados em uma heurística híbrida desenvolvida para problema das p -medianas visando melhorar tanto a qualidade das soluções obtidas quanto o tempo de execução. Os resultados empíricos sobre instâncias da literatura evidenciam a melhora gerada pela incorporação da mineração de dados na heurística híbrida.

Palavras Chave:

GRASP, Mineração de Dados, Metaheurística Híbrida, Problema das p -medianas.

ABSTRACT

Given a set F of m potential facilities and a set U of n customers, the p -median problem consists in finding a subset of F with p facilities such that the cost of serving all customers is minimized. The incorporation of data mining techniques into heuristics has achieved good results, obtaining better solutions and accelerating the heuristic process. This work has the objective to incorporate a data mining module to a hybrid heuristic for the p -median problem to improve both the quality of the obtained solutions and the execution time. Experimental results show the improvement produced by the incorporation of data mining into the hybrid heuristic.

Keywords:

GRASP, Data Mining, Hybrid Metaheuristic, p -median Problem.

LISTA DE ACRÔNIMOS

GRASP:	<i>Greedy Randomized Adaptive Search Procedure</i>
HH:	Heurística híbrida
DM-HH:	Heurística híbrida com <i>Mineração de Dados</i>
LRC:	Lista Restrita de Candidatos
MCF:	Mineração de Conjuntos Freqüentes

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	5
CAPÍTULO 2 - A HEURÍSTICA HÍBRIDA	7
CAPÍTULO 3 - A HEURÍSTICA HÍBRIDA COM MINERAÇÃO DE DADOS	10
CAPÍTULO 4 - RESULTADOS	13
CAPÍTULO 5 - CONCLUSÕES	20
REFERÊNCIAS BIBLIOGRÁFICAS	21

LISTA DE FIGURAS

FIGURA 1: PSEUDOCÓDIGO DA HEURÍSTICA HÍBRIDA	8
FIGURA 2: PSEUDOCÓDIGO DA HEURÍSTICA HÍBRIDA COM MINERAÇÃO DE DADOS	11
FIGURA 3: PSEUDOCÓDIGO DO ALGORITMO CONSTRUTIVO COM MINE- RAÇÃO DE DADOS	12

LISTA DE TABELAS

TABELA 1: CONSOLIDADO AGRUPADO POR CLASSE DE INSTÂNCIA	15
TABELA 2: RESULTADOS FINAIS DA INSTÂNCIA RL5934, CONJUNTO ELITE DE TAMANHO 8 E SUPORTE MÍNIMO 5.	16
TABELA 3: RESULTADOS FINAIS DA INSTÂNCIA PCB3038, CONJUNTO ELITE DE TAMANHO 8 E SUPORTE MÍNIMO 5.	16
TABELA 4: RESULTADOS FINAIS DA INSTÂNCIA FL1400, CONJUNTO ELITE DE TAMANHO 8 E SUPORTE MÍNIMO 5.	17
TABELA 5: RESULTADOS FINAIS DA CLASSE ORLIB, CONJUNTO ELITE DE TAMANHO 8 E SUPORTE MÍNIMO 5.	17
TABELA 6: RESULTADOS FINAIS DA CLASSE SL, CONJUNTO ELITE DE TAMANHO 8 E SUPORTE MÍNIMO 5.	18
TABELA 7: RESULTADOS FINAIS DA CLASSE GR, CONJUNTO ELITE DE TAMANHO 8 E SUPORTE MÍNIMO 5.	18
TABELA 8: RESULTADOS FINAIS DA CLASSE RW, CONJUNTO ELITE DE TAMANHO 8 E SUPORTE MÍNIMO 5.	18
TABELA 9: RESULTADOS FINAIS DA INSTÂNCIA RL5934, CONJUNTO ELITE DE TAMANHO 8 E SUPORTE MÍNIMO 4.	19
TABELA 10: RESULTADOS FINAIS DA INSTÂNCIA PCB3038, CONJUNTO ELITE DE TAMANHO 8 E SUPORTE MÍNIMO 4.	19

CAPÍTULO 1 - INTRODUÇÃO

Metaheurísticas representam uma importante ferramenta para obtenção de soluções de qualidade, em tempo viável, para problemas de otimização computacionalmente intratáveis de forma exata [15]. Pesquisas demonstram que a hibridização desses métodos com técnicas e conceitos de outras áreas tem o potencial de melhorar o desempenho e a robustez dos mesmos [23]. A metaheurística DM-HH (Heurística híbrida com Mineração de dados) é uma versão híbrida da metaheurística GRASP (*Greedy Randomized Adaptive Search Procedure*) desenvolvida em [17] que incorpora técnicas de mineração de dados e que tem apresentado resultados promissores [18, 19, 20, 21, 6].

A metaheurística GRASP já foi aplicada com sucesso a diversos problemas [5]. Nesse método, a busca por soluções é realizada por meio de um processo iterativo, no qual cada iteração é composta de duas fases: construção e busca local. Na fase de construção, uma solução completa é gerada. Essa solução não representa garantidamente um ótimo local, o que serve de motivação para a realização da fase seguinte. Na fase de busca local, a vizinhança dessa solução é explorada até que se obtenha uma solução que seja ótima localmente.

Processos de mineração de dados são caracterizados pela extração automática de informações úteis, implícitas em bases de dados, sob a forma de regras e padrões [9]. No contexto do DM-HH, um algoritmo de mineração é utilizado para reconhecer padrões em soluções sub-ótimas, os quais são utilizados para guiar a busca por melhores soluções.

A metaheurística híbrida DM-HH é dividida em duas partes. Na primeira, um conjunto de $\lfloor \text{graspit} \div 2 \rfloor$ iterações, como definidas no GRASP, é executado, sendo graspit o número total de iterações. Em seguida, um algoritmo de mineração de dados é executado sobre o conjunto das melhores soluções obtidas para extrair os padrões que caracterizam as soluções sub-ótimas. Na segunda fase, são executadas outras $\lfloor \text{graspit} \div 2 \rfloor$ iterações adaptadas, nas quais os padrões são utilizados para guiar a construção das soluções.

Essa proposta híbrida foi utilizada com sucesso em três problemas de otimização combinatoria: problema de empacotamento de conjuntos [18], problema da maximização da diversidade [21] e o problema de replicação de servidores em transmissão *multicast* confiável [20, 6].

A heurística híbrida apresentada para o problema das p -medianas em [17] apresentou ex-

celentes resultados para diferentes tipos de instâncias e se mostrou competitivo com relação às melhores heurísticas da literatura. O objetivo deste trabalho é incorporar a mineração de dados na heurística híbrida proposta em [17] na tentativa de obter melhores soluções em um menor tempo computacional, tornando a proposta de [17] ainda mais competitiva.

A mediana ou centróide de um grafo $G(V, E)$ é um vértice para o qual a soma das distâncias aos demais vértices é mínima. Problemas que têm como solução uma única mediana (um único vértice) são chamadas de 1-mediana. Casos em que existem mais de uma mediana como solução são chamados de 2-medianas, 3-medianas, ou p -medianas de um modo geral. O problema das p -medianas é um dos mais populares problemas de localização de instalações, útil para modelar várias situações no mundo real para localização de instalações públicas ou industriais, armazéns [4, 10] e outros [12].

O problema das p -medianas é definido da seguinte maneira. Dado um conjunto F com m potenciais instalações, um conjunto U com n clientes (ou usuários), uma função de distância $d : U \times F \rightarrow R$ e uma constante $p \leq m$, deve-se encontrar um subconjunto $S \subseteq F$ com p instalações a fim de minimizar a soma de todas as distâncias de cada cliente à instalação mais próxima. O problema modela uma situação de minimização e pertence à classe de problemas NP-Difíceis. [11].

Este trabalho está organizado da seguinte forma. No Capítulo 2, é apresentado a heurística híbrida proposta em [17]. O Capítulo 3 apresenta o módulo de mineração de dados e sua incorporação na heurística híbrida. O Capítulo 4 apresenta os resultados experimentais obtidos e no Capítulo 5 são apresentadas as conclusões e considerações finais.

CAPÍTULO 2 - A HEURÍSTICA HÍBRIDA

Neste capítulo, será apresentado a heurística híbrida proposta em [17] e suas características com a finalidade da incorporação do módulo de mineração de dados.

Esta heurística utiliza conceitos desenvolvidos em várias metaheurísticas "puras" tais como GRASP, busca tabu e algoritmos genéticos.

A metaheurística GRASP é um método para obtenção de soluções de boa qualidade para problemas de otimização combinatória. Desde sua criação, essa metaheurística vem sendo utilizada com considerável sucesso em diversos problemas computacionalmente intratáveis [5].

Sua idéia central é combinar um algoritmo guloso com um componente aleatório. Algoritmos gulosos são geralmente iterativos e, a cada iteração, incluem na solução em construção o elemento que traz o melhor incremento na sua qualidade. Apesar de levarem a boas soluções, normalmente não atingem soluções ótimas. Métodos aleatórios incluem elementos à solução aleatoriamente, o que, apesar de gerar soluções de baixa qualidade média, permite bastante diversificação.

O GRASP é um processo iterativo, sendo cada iteração composta de duas fases: construção e busca local. Na primeira fase, uma solução é construída, sem que seja necessariamente um ótimo local. Na segunda fase, a vizinhança dessa solução é percorrida em busca de melhores soluções. O processo é repetido até que um critério de parada seja atingido. A melhor solução encontrada dentre todas as iterações é retornada como resultado.

A heurística híbrida proposta em [17] difere do GRASP tradicional pois utiliza um método de construção por amostragem e estratégias de intensificação com a técnica de *path-relinking* [7]. As estratégias de intensificação são utilizadas após o algoritmo de busca local e ao final da execução de todas as iterações.

A Figura 1 apresenta o pseudo código da heurística híbrida. Na linha 1, é gerada a semente que será utilizada na fase de construção da solução. Na linha 2, ocorre a inicialização do conjunto elite utilizado pelas estratégias de intensificação. O bloco de instruções entre as linhas 3 e 12 são executados iterativamente. A fase de construção é executada na linha 4 e, na linha 5, a busca local é aplicada a solução construída. Na linha 6, é selecionada uma solução do conjunto elite e armazenada em S' . Esta seleção utiliza como parâmetro a solução S , pois busca

no conjunto elite uma solução não seja parecida S. Caso seja selecionada uma solução, na linha 8, é executado o *path-relinking* entre as soluções obtidas pela busca local e pela solução obtida do conjunto elite. Caso as condições de diversidade e de qualidade de solução sejam atendidas, o conjunto elite é atualizado com a solução resultante da técnica de *path-relinking* (linha 9) e o conjunto elite é atualizado com a solução produzida pelo algoritmo de busca local (linha 11). Na linha 13, é executado o método de pós-otimização.

```
função Heurística Híbrida(semente, grspit, tamelite)
01.   gera (semente);
02.   inicializar (elite, tamelite);
03.   para i = 1 até graspit faça
04.     S  $\leftarrow$  construção();
05.     S  $\leftarrow$  buscaLocal(S);
06.     S'  $\leftarrow$  selecione (elite, S);
07.     se (S' ≠ NULL) então
08.       S'’  $\leftarrow$  pathRelinking(S, S');
09.       adicione(elite, S');
10.     fim se
11.     adicione (elite, S);
12.   fim para
13.   S  $\leftarrow$  posOptimização(elite);
14.   retorne S;
```

Figura 1: Pseudocódigo da heurística híbrida

Um algoritmo guloso muito utilizado para o problema das *p*-medianas [3, 25] inicia com uma solução vazia e adiciona instalações por vez, escolhendo a mais lucrativa em cada iteração. O método construtivo utilizado na heurística híbrida é realizado por amostragem. Esse método é similar ao algoritmo guloso, no entanto, ao invés de selecionar a melhor dentre todas as opções, apenas são consideradas $q < m$ possíveis inserções (escolhidas aleatoriamente) em cada iteração, onde m é o número de potenciais instalações e $q = \lceil \log_2(m/p) \rceil$. A mais lucrativa dentre estas é selecionada. Esse método foi escolhido entre outros métodos construtivos desenvolvidos em [17] porque apresenta um menor tempo de execução para a construção de soluções iniciais e também garante um maior grau de aleatoriedade nas soluções que será útil para as estratégias de intensificação.

O procedimento padrão de busca local, proposto em [24] para o problema das *p*-medianas é baseado na troca de instalações. Dada uma solução inicial *S*, o procedimento determina para cada instalação $f \notin S$, qual instalação $g \in S$ melhoraria a solução ao máximo se f e g fossem trocadas (isto é, se f fosse inserida e g fosse retirada da solução). Se existir pelo menos uma troca que melhore, f e g são trocados. O processo continua até que nenhuma melhora possa ser feita, o que significa que um *mínimo local* foi alcançado.

A exploração de uma determinada região do espaço amostral ou da vizinhança de boas

soluções que já tenham sido encontradas é chamada de intensificação, e possui um caráter local. As estratégias de intensificação da heurística híbrida ocorrem em dois pontos e para isso é mantido um conjunto elite de soluções, composto por soluções de alta qualidade encontradas durante a execução. No primeiro, em cada iteração há um passo de intensificação após a busca local, onde as soluções geradas são combinadas com uma solução do conjunto elite. O outro ponto é na fase de pós-otimização, onde todas as soluções do conjunto elite são combinadas entre si e, em seguida, a nova solução gerada é adicionada no conjunto elite de soluções, representando uma nova geração. O algoritmo continua sua execução até criar uma nova geração onde não haja nenhuma melhora na qualidade da solução com relação a geração anterior. Em ambos os estágios a estratégia para combinar as soluções é feita por meio da técnica de *path-relinking* [13], sendo que na etapa de intensificação após a busca local, o *path-relinking* utiliza uma combinação *best to worst*, onde a melhor solução é transformada na pior e na fase de pós-otimização é utilizada uma combinação *worst to best*, onde a pior solução é transformada na melhor.

CAPÍTULO 3 - A HEURÍSTICA HÍBRIDA COM MINERAÇÃO DE DADOS

Processos de mineração de dados são caracterizados pela extração automática de informações úteis a partir de bases de dados, na forma de regras e padrões. A idéia que motiva sua aplicação em conjunto com o GRASP é a possibilidade de se encontrar padrões que representem características das melhores soluções geradas, o que pode auxiliar a busca por soluções mais próximas do valor ótimo em um menor tempo computacional.

A versão híbrida do GRASP que incorpora um módulo de mineração de dados é dividida em duas etapas: na primeira, chamada fase de geração do conjunto elite, é executada uma determinada quantidade de iterações do GRASP, $\lfloor \text{graspit} \div 2 \rfloor$, onde graspit é o número de iterações, e um conjunto de soluções, chamado conjunto elite, é criado para armazenar as melhores soluções encontradas ao longo dessas iterações. Apesar da heurística híbrida estudada construir um conjunto elite durante suas iterações, foi necessário criar um novo conjunto para ser utilizado pela mineração de padrões, pois o conjunto original possuía critérios específicos para manter sua diversidade.

Em seguida, é executado o algoritmo de mineração de dados denominado Mineração de Conjuntos Frequentes (MCF) para extrair padrões das soluções desse conjunto elite. Na etapa seguinte, chamada fase híbrida, são executadas novas iterações do GRASP. Nessas iterações, a fase de construção é modificada para usar os padrões encontrados como soluções iniciais parciais. A fase de busca local permanece inalterada.

A versão híbrida do GRASP que incorpora o módulo de mineração de dados, denominada DM-HH, encontra-se ilustrada na Figura 2. Na linha 1, é gerada a semente que será utilizada na fase de construção da solução. Na linha 2, ocorre a inicialização do conjunto elite utilizado pelas estratégias de intensificação. No laço entre as linhas 3 e 22, são executadas iterações do GRASP. A inclusão do módulo de mineração de dados é feito com linhas de 4 a 11 e 19 a 21, onde entre as linhas 4 e 11 o método construtivo foi modificado e entre as linhas 19 e 21 o conjunto elite a ser minerado é construído. Na linha 4, é verificado qual método construtivo será executado, dependendo de qual iteração está sendo executada. Na linha 5, o método construtivo original é executado para as primeiras $\lfloor \text{graspit} \div 2 \rfloor$ iterações. Na linha 8 é executado o algoritmo de

MCF tomando como base de dados o conjunto elite antes da iteração $\lfloor \text{graspit} \div 2 \rfloor + 1$. Na linha 10, a partir da iteração $\lfloor \text{graspit} \div 2 \rfloor + 1$ é executado o método de construção adaptado, onde a solução construída é inicializada contendo todos os elementos do padrão passado como parâmetro. Em seguida, novos elementos são adicionados, como na fase de construção original, até que a solução seja completamente construída. Na linha 12, é executada a busca local, que permanece inalterada. As linhas 19 e 21 são referentes à atualização do conjunto elite utilizado pelas estratégias de intensificação e do conjunto elite minerado. Na linha 23, é realizada a pós-otimização. Na linha 24, a melhor solução encontrada é retornada.

```

função DM-HH(semente, graspit, tamelite)
01. randomize(semente)
02. inicialize(elite, tamelite);
03. para i = 1 até graspit faça
04.     se (i ≤  $\lfloor \text{graspit} \div 2 \rfloor$ ) então
05.         S ← construção();
06.     senão
07.         se (i =  $\lfloor \text{graspit} \div 2 \rfloor + 1$ ) então
08.             padrões = FPMax(eliteMD);
09.         fim se
10.         S ← construçãoMD(padrões);
11.     fim se
12.     S ← buscaLocal(S);
13.     S' ← seleciona(elite, S);
14.     se (S' ≠ NULL) então
15.         S' ← pathRelinking(S, S');
16.         adicone(elite, S');
17.     fim se
18.     adicone(elite, S);
19.     se (i ≤  $\lfloor \text{graspit} \div 2 \rfloor$ ) então
20.         adicone(eliteMD, S);
21.     fim se
22. fim para
23. S ← posOptimização(elite);
24. retorne S;

```

Figura 2: Pseudocódigo da heurística híbrida com Mineração de Dados

A Figura 3 ilustra o pseudo-código do método construtivo utilizado após a execução do módulo de mineração de dados. Na linha 1, um padrão é selecionado dentre os obtidos pelo algoritmo de MCF, o critério de seleção do padrão é do tipo *round-robin*, isto é, o conjunto de padrões minerados é tido como uma lista circular, onde a cada iteração é selecionado um padrão da lista e caso esta lista chegue ao final, a seleção é reiniciada, voltando a ser feita do início do conjunto de padrões. Esse critério circular é utilizado no caso do número dos padrões extraídos ser menor do que o número de iterações. Na linha 2, o padrão é utilizado como solução inicial parcial para, na linha 3, o método construtivo construir uma solução completa a partir desta. Na linha 4, a solução é retornada.

```
função ConstruçãoMD(padroes, supmin)
1. padrão = seleçãoCircular(padrões);
2. S  $\leftarrow$  padrão;
3. S  $\leftarrow$  construção(S);
4. return S;
```

Figura 3: Pseudocódigo do algoritmo construtivo com Mineração de Dados

Na implementação do DM-HH para o problema, foi utilizado o algoritmo FPmax* [8] para extrair conjuntos freqüentes maximais – padrões – do conjunto elite. Esse algoritmo é executado *tamelite - supmin* vezes, onde *tamelite* é o tamanho do conjunto elite e *supmin* é o valor do suporte mínimo que indica o número mínimo de vezes que um trecho de solução deve aparecer para ser considerado um padrão. Todos os padrões encontrados em cada execução são agrupados em um conjunto *F* e os $\lfloor \text{graspit} \div 2 \rfloor$ padrões maximais com o maior número de elementos obtidos de *F* são escolhidos para integrar o conjunto de padrões utilizados na fase híbrida. O conjunto elite minerado foi utilizado com dois tamanhos diferentes, onde foram feitos testes com as quatro ou oito melhores soluções obtidas.

CAPÍTULO 4 - RESULTADOS

Neste capítulo, são apresentados os resultados obtidos com a heurística híbrida original (HH) e com a heurística com o módulo de mineração de dados incorporado (DM-HH). As instâncias para o problema das p -medianas e parâmetros foram os mesmos utilizados em [17]. Para o DM-HH foram utilizados diferentes parâmetros de suporte mínimo e tamanho do conjunto elite de padrões.

Foram utilizadas cinco classes de instâncias: **TSP** [16], **ORLIB** [2], **SL** [22], **GR** [1] e **RW** [17]. São conhecidos os valores ótimos para as intâncias das classes **ORLIB**, **SL** e **GR**. Para a classe **TSP**, até a publicação do artigo original [17], são conhecidos os melhores valores da literatura. Para as instâncias da classe **RW**, os melhores resultados são do artigo original [17] pois é uma classe recente que não foi tratada por outros trabalhos.

As instâncias da classe **TSP** são pontos em um plano. Foram propostas inicialmente para o problema do caixeiro viajante e foram disponibilizadas na **TSPLIB** [16]. Cada ponto dessa instância é considerado tanto uma potencial instalação quanto um cliente, e o custo de atribuir um cliente c a uma instalação f é simplesmente a distância euclidiana entre os pontos c e f . Nessa classe, são consideradas três instâncias: fl1400, pcb3038 e rl5934, com respectivamente 1400, 3038 e 5934 nós, cada uma com diferentes valores para p .

As instâncias da classe classe **ORLIB** são grafos, cada um com seu correspondente valor de p . Todo nó é um cliente e uma potencial instalação e o custo de atribuir um cliente a uma instalação é o comprimento do caminho mínimo entre os nós correspondentes. O número de nós nessa classe varia de 100 a 900, e os valores de p de 5 a 200.

A terceira classe considerada é a **SL**, uma extensão da classe **ORLIB** onde são introduzidas três novas instâncias baseadas nos grafos da **ORLIB**. A instância sl700 utiliza o mesmo grafo da instância pmed34, mas com o valor de $p = 233$. A instância sl800 utiliza o mesmo grafo da instância pmed37, mas com o valor de $p = 267$. E a instância sl900 utiliza o mesmo grafo da instância pmed40, mas com o valor de $p = 300$.

A quarta classe é a **GR**, na qual estão contidos dois grafos com 100 e 150 nós, respectivamente. Os valores de p variam de 5 a 50.

A última classe é a **RW** que foi introduzida pelos próprios autores da heurística híbrida em

[17] e são matrizes de distâncias. Nessas instâncias, o número de potenciais instalações (m) é igual ao número de potenciais clientes (n). A distância entre cada instalação e cada cliente tem um valor inteiro escolhido aleatoriamente do intervalo $[1, n]$. Quatro valores diferentes para n foram utilizados: 100, 250, 500 e 1000. Em cada caso diferentes valores de p foram testados.

Para fins de comparação, HH e DM-HH foram executados com os mesmos parâmetros do artigo onde a heurística híbrida foi proposta [17]. Para cada instância são realizadas nove execuções, com diferentes sementes variando de 1 a 9, e para cada execução, são realizadas 32 iterações. Para o DM-HH foram feitas execuções variando os parâmetros de suporte mínimo e tamanho do conjunto elite utilizado na mineração, onde para o conjunto elite de tamanho quatro foram utilizados os suportes mínimos de 2 a 4 e para o conjunto elite de tamanho oito foram utilizados os suportes mínimos de 4 a 8.

Os testes foram executados em um computador com processador Intel Core2 Duo com dois núcleos num total de 2.33GHz em um sistema operacional Debian GNU/Linux versão 4.0. Os algoritmos foram desenvolvidos em C++ e compilados através do GCC versão 4.3.4 com a flag -O3. Todos os tempos de execução apresentados são tempos de CPU medidos por meio da função getrusage. O gerador de números aleatórios utilizado foi o Mersenne Twister [14].

A Tabela 1 apresenta um quadro com o resumo consolidado dos resultados obtidos das execuções de HH e do DM-HH sobre todas as instâncias de [17]. A primeira coluna se refere à classe da instância, onde entre parênteses é apresentado o número de instâncias da classe, a segunda ao tamanho do conjunto elite utilizado para realizar a mineração de dados, a terceira é o valor do suporte mínimo utilizado na mineração de dados. As colunas 4 a 6 são referentes à execução do HH e as colunas 7 a 9 à execução do DM-HH, onde são apresentados: o número de vezes que a classe obteve o melhor valor de qualidade de solução com o erro percentual (%Dif), o número de vezes que a classe obteve a melhor média de qualidade de solução com o erro percentual (%Dif) e o número de vezes que cada classe obteve a menor média de tempo de execução do algoritmo. O erro percentual é a diferença em relação à melhor solução da literatura.

Observa-se que, em termos de tempo computacional, o número de vezes em que o DM-HH foi melhor que o HH foi significativamente superior.

Em termos de qualidade da solução, nota-se que, para a classe de instância TSP, o DM-HH obteve sempre um resultado superior, independentemente do tamanho do conjunto elite e do suporte mínimo utilizado. No caso da classe ORLIB, o DM-HH superou HH apenas quando utilizado o conjunto elite de tamanho 8 e suporte mínimo 8. O mesmo aconteceu com a classe SL para a qual DM-HH superou HH com conjunto elite de tamanho 4 e suporte mínimo 2. Para

as classes GR e RW, para vários valores de tamanhos de conjunto elite e de suporte mínimo, DM-HH obteve um desempenho superior. O melhor desempenho para a classe GR foi obtida pelo DM-HH com conjunto elite de tamanho 8 e suporte mínimo 8 e, para a classe RW, o melhor desempenho foi obtido com conjunto elite 8 e suporte mínimo 4.

Classe	Tam	Sup	Dados HH			DM-HH		
			#Melhores (%Dif)	#Média (%Dif)	#Tempo	#Melhores (%Dif)	#Média (%Dif)	#Tempo
TSP (74)	4	2	22 (0,0061)	19 (0,03534)	6	32 (0,00429)	47 (0,03371)	68
		3	21 (0,0061)	26 (0,03534)	5	30 (0,00627)	41 (0,03186)	69
		4	28 (0,0061)	30 (0,03534)	10	24 (0,00550)	38 (0,03089)	64
	8	4	25 (0,0061)	32 (0,03534)	36	29 (0,00566)	36 (0,03230)	38
		5	22 (0,0061)	31 (0,03534)	21	32 (0,00514)	34 (0,03279)	53
		6	21 (0,0061)	23 (0,03534)	17	33 (0,00455)	43 (0,03402)	57
		7	21 (0,0061)	30 (0,03534)	22	31 (0,00399)	36 (0,03268)	52
		8	22 (0,0061)	29 (0,03534)	17	29 (0,00554)	33 (0,03362)	57
ORLIB (40)	4	2	0 (0,00000)	2 (0,00037)	2	0 (0,00000)	0 (0,00054)	38
		3	0 (0,00000)	2 (0,00037)	2	0 (0,00000)	0 (0,00059)	38
		4	0 (0,00000)	3 (0,00037)	1	0 (0,00000)	0 (0,00073)	39
	8	4	0 (0,00000)	3 (0,00037)	7	0 (0,00000)	1 (0,00047)	33
		5	0 (0,00000)	1 (0,00037)	4	0 (0,00000)	1 (0,00043)	34
		6	0 (0,00000)	2 (0,00037)	3	0 (0,00000)	0 (0,00054)	37
		7	0 (0,00000)	2 (0,00037)	2	0 (0,00000)	1 (0,00043)	38
		8	0 (0,00000)	1 (0,00037)	2	0 (0,00000)	1 (0,00033)	38
SL (3)	4	2	0 (0,00000)	0 (0,00348)	0	0 (0,00000)	1 (0,00000)	3
		3	0 (0,00000)	0 (0,00348)	0	0 (0,00000)	0 (0,00348)	3
		4	0 (0,00000)	1 (0,00348)	0	0 (0,00000)	0 (0,00529)	3
	8	4	0 (0,00000)	1 (0,00348)	3	0 (0,00000)	1 (0,00362)	0
		5	0 (0,00000)	1 (0,00348)	0	0 (0,00000)	0 (0,00696)	3
		6	0 (0,00000)	1 (0,00348)	0	0 (0,00000)	0 (0,00522)	3
		7	0 (0,00000)	1 (0,00348)	0	0 (0,00000)	0 (0,00522)	3
		8	0 (0,00000)	2 (0,00348)	0	0 (0,00000)	0 (0,00721)	3
GR (16)	4	2	0 (0,00000)	4 (0,01507)	5	0 (0,00000)	3 (0,01579)	11
		3	0 (0,00000)	4 (0,01507)	2	0 (0,00000)	3 (0,01468)	13
		4	0 (0,00000)	4 (0,01507)	5	0 (0,00000)	2 (0,01855)	10
	8	4	0 (0,00000)	4 (0,01507)	9	0 (0,00000)	5 (0,01265)	6
		5	0 (0,00000)	4 (0,01507)	9	0 (0,00000)	4 (0,01240)	7
		6	0 (0,00000)	2 (0,01507)	7	0 (0,00000)	5 (0,00929)	9
		7	0 (0,00000)	4 (0,01507)	7	0 (0,00000)	4 (0,00779)	9
		8	0 (0,00000)	3 (0,01507)	10	0 (0,00000)	2 (0,01400)	5
RW (28)	4	2	3 (0,00838)	10 (0,13917)	2	4 (-0,01818)	5 (0,15796)	26
		3	3 (0,00838)	8 (0,13917)	3	5 (-0,01853)	8 (0,14714)	25
		4	3 (0,00838)	8 (0,13917)	2	3 (-0,00681)	6 (0,15059)	26
	8	4	1 (0,00838)	7 (0,13917)	18	4 (-0,03335)	10 (0,10853)	9
		5	3 (0,00838)	5 (0,13917)	13	6 (-0,01973)	11 (0,12645)	14
		6	4 (0,00838)	7 (0,13917)	11	1 (0,03530)	7 (0,15416)	17
		7	2 (0,00838)	4 (0,13917)	5	3 (0,00328)	9 (0,13844)	22
		8	1 (0,00838)	4 (0,13917)	8	5 (-0,01352)	10 (0,12340)	19

Tabela 1: Consolidado agrupado por classe de instância

Para ilustrar melhor os experimentos que foram realizados a seguir serão apresentados com mais detalhes os resultados obtidos com a seguinte combinação de parâmetros: tamanho do conjunto elite 8 e suporte mínimo 5.

As Tabelas 2, 3, 4, 5, 6, 7 e 8 apresentam os resultados respectivamente, para a instância RL5934 da classe TSP, a instância PCB3038 da classe TSP, a instância FL1400 da classe TSP, as instâncias da classe ORLIB, as instâncias da classe SL, as instâncias da classe GR e as instâncias da classe RW. São apresentados os valores médios, a média percentual de erro (indica o quanto

a média obtida está acima do melhor valor conhecido na literatura) e tempo de execução em segundos, para os algoritmos HH e DM-HH.

Nestas tabelas, pode-se verificar o comportamento dos algoritmos em relação às características das instâncias. Em termos de tempos computacionais DM-HH apresenta menores tempos computacionais. Em relação à qualidade das soluções, pode-se verificar que existe um comportamento variável em relação às características das instâncias.

Nome	Instância		Melhor Conhecido	HH	Media (%Dif)	Tempo	Melhor (%Dif)	DM-HH	Media (%Dif)	Tempo
	p	Melhor								
RL5934	10	9794951,00	9794973,65 (0,0002)	9794973,65 (0,0002)	792,9566	9794973,65 (0,0002)	9794973,65 (0,0002)	840,5288		
RL5934	20	6718848,19	6718848,19 (0,0000)	6718958,30 (0,0016)	507,2600	6718848,19 (0,0000)	6719066,29 (0,0032)	456,9311		
RL5934	30	5374936,14	5374936,14 (0,0000)	5375613,12 (0,0126)	413,4366	5374936,14 (0,0000)	5375634,27 (0,0130)	444,1222		
RL5934	40	4550364,60	4550327,09 (-0,0008)	4550415,43 (0,0011)	253,8266	4550327,09 (-0,0008)	4550442,41 (0,0017)	259,3566		
RL5934	50	4032379,97	4032379,97 (0,0000)	4032857,64 (0,0118)	240,9022	4032379,97 (0,0000)	4032678,57 (0,0074)	238,7822		
RL5934	60	3642397,88	3642064,7 (-0,0091)	3642968,54 (0,0157)	241,7611	3642064,7 (-0,0091)	3643058,33 (0,0181)	219,5133		
RL5934	70	3343712,45	3344669,26 (0,0286)	3344939,68 (0,0367)	229,2144	3343987,78 (0,0082)	3344934,65 (0,0366)	211,9644		
RL5934	80	3094824,49	3094605,63 (-0,0071)	3095841,50 (0,0329)	193,7588	3094550,03 (-0,0089)	3095414,04 (0,0190)	173,7888		
RL5934	90	2893362,39	2893297,83 (-0,0022)	2895402,27 (0,0705)	195,6666	2893938,74 (0,0199)	2895124,44 (0,0609)	164,5433		
RL5934	100	2725180,81	2725067,34 (-0,0042)	2726827,46 (0,0604)	149,8466	2724937,5 (-0,0089)	2726543,53 (0,0500)	159,1711		
RL5934	150	2147881,53	2147863,31 (-0,0008)	2149142,92 (0,0587)	107,5877	2147812,98 (-0,0032)	2148604,44 (0,0337)	107,9044		
RL5934	200	1808179,07	1808423,86 (0,0135)	1809157,30 (0,0541)	101,9488	1808257,39 (0,0043)	1808844,72 (0,0368)	98,6566		
RL5934	250	1569941,34	1569967,46 (0,0017)	1570812,55 (0,0555)	98,7511	1570119,62 (0,0114)	1570843,78 (0,0575)	86,4433		
RL5934	300	1394115,39	1394278,15 (0,0117)	1394704,10 (0,0422)	82,5066	1394262,23 (0,0105)	1394537,14 (0,0303)	78,8688		
RL5934	350	1256844,04	1256795,35 (-0,0039)	1257497,24 (0,0520)	83,4977	1257228,31 (0,0306)	1257551,54 (0,0563)	76,9422		
RL5934	400	1145669,38	1145765,09 (0,0084)	1146166,04 (0,0434)	90,3455	1145973,86 (0,0266)	1146378,56 (0,0619)	85,4366		
RL5934	450	1053363,64	1053564,91 (0,0191)	1054027,69 (0,0630)	87,8066	1053462,45 (0,0094)	1053960,15 (0,0566)	84,2077		
RL5934	500	973995,18	974019,92 (0,0025)	974455,34 (0,0472)	85,0722	974099,78 (0,0107)	974405,38 (0,0421)	78,4344		
RL5934	600	848283,85	848421,86 (0,0163)	848660,09 (0,0444)	91,6877	848374,24 (0,0107)	848656,58 (0,0439)	84,7555		
RL5934	700	752068,38	752301,57 (0,031)	752449,98 (0,0507)	100,3744	752130,63 (0,0083)	752332,17 (0,0351)	89,7722		
RL5934	800	676795,78	676935,96 (0,0207)	677101,29 (0,0451)	103,6744	676884,32 (0,0131)	677072,87 (0,0409)	96,3044		
RL5934	900	613367,44	613497,92 (0,0213)	613547,55 (0,0294)	115,0988	613506,73 (0,0227)	613592,63 (0,0367)	106,0011		
RL5934	1000	558802,38	558853,74 (0,0092)	558970,00 (0,0300)	113,9822	558875,6 (0,0131)	558984,42 (0,0326)	116,6777		
RL5934	1100	511813,19	511872,05 (0,0115)	512027,71 (0,0419)	121,1633	511809,99 (-0,0006)	512000,88 (0,0367)	125,2766		
RL5934	1200	470295,38	470388,23 (0,0197)	470486,17 (0,0406)	128,5722	470393,65 (0,0209)	470447,69 (0,0324)	139,1944		
RL5934	1300	433597,44	433663,61 (0,0153)	433703,01 (0,0243)	143,5011	433617,22 (0,0046)	433792,29 (0,0449)	146,0944		
RL5934	1400	401853,00	401912,84 (0,0149)	401972,73 (0,0298)	147,7311	401943,76 (0,0226)	401974,07 (0,0301)	166,1066		
RL5934	1500	374014,57	374043,2 (0,0077)	374083,48 (0,0184)	153,3822	374044,4 (0,0088)	374119,24 (0,0280)	167,4966		
	# vezes melhor			10	12	11	12	15	17	

Tabela 2: Resultados finais da instância RL5934, conjunto elite de tamanho 8 e suporte mínimo 5.

Nome	Instância		Melhor Conhecido	HH	Media (%Dif)	Tempo	Melhor (%Dif)	DM-HH	Media (%Dif)	Tempo
	p	Melhor								
PCB3038	10	1213082,03	1213082,03 (0,0000)	1213082,03 (0,0000)	162,6133	1213082,03 (0,0000)	1213082,03 (0,0000)	142,4144		
PCB3038	20	840844,53	840844,53 (0,0000)	840852,71 (0,0010)	107,7166	840844,53 (0,0000)	840873,15 (0,0034)	97,7333		
PCB3038	30	677306,76	677272,22 (-0,0051)	677648,38 (0,0504)	88,1677	677272,22 (-0,0051)	677693,97 (0,0572)	81,5133		
PCB3038	40	571887,75	571887,75 (0,0000)	571891,10 (0,0006)	51,2366	571887,75 (0,0000)	571911,37 (0,0041)	51,0944		
PCB3038	50	507582,13	507558,16 (-0,0047)	507602,97 (0,0041)	51,6255	507558,16 (-0,0047)	507640,81 (0,0116)	50,1211		
PCB3038	60	460771,87	460772,03 (0,0000)	460873,27 (0,0220)	43,6066	460771,87 (0,0000)	460831,80 (0,0130)	40,8522		
PCB3038	70	426068,24	426068,24 (0,0000)	426146,01 (0,0183)	42,4955	426068,24 (0,0000)	426172,84 (0,0246)	426172,84 (0,0246)	43,6744	
PCB3038	80	397529,25	397504,97 (-0,0061)	397641,81 (0,0283)	38,0922	397497,26 (-0,0088)	397605,82 (0,0193)	42,5511		
PCB3038	90	373248,08	373241,86 (-0,0017)	373340,78 (0,0516)	40,0944	373248,08 (0,0000)	373360,33 (0,0301)	38,1911		
PCB3038	100	352628,35	352649,37 (0,006)	352802,03 (0,0493)	38,3911	352627,17 (0,0003)	352786,19 (0,0448)	38,0766		
PCB3038	150	281193,96	281219,83 (0,0092)	281384,25 (0,0677)	30,3688	281202,87 (0,0032)	281317,87 (0,0441)	29,4000		
PCB3038	200	238373,26	238418,23 (0,0189)	238480,12 (0,0448)	28,1333	238416,71 (0,0182)	238524,71 (0,0635)	238588,26 (0,0436)	28,5988	
PCB3038	250	209241,25	209274,8 (0,016)	209341,81 (0,0481)	29,8277	209284,34 (0,0206)	209330,45 (0,0426)	29,4666		
PCB3038	300	187712,12	187738,45 (0,014)	187792,04 (0,0426)	30,1622	187709,84 (-0,0012)	187778,23 (0,0352)	28,7277		
PCB3038	350	170973,34	170961,4 (-0,0072)	171017,63 (0,0259)	33,2866	170961,45 (-0,007)	170990,52 (0,0100)	31,4844		
PCB3038	400	157030,46	157060,47 (0,0191)	157084,45 (0,0344)	32,2044	157059,78 (0,0187)	157086,65 (0,0358)	29,3533		
PCB3038	450	145384,18	145378,94 (-0,0036)	145397,06 (0,0089)	34,6400	145388,8 (0,0032)	145417,90 (0,0232)	31,0733		
PCB3038	500	135467,85	135495,22 (0,0202)	135528,59 (0,0448)	33,0188	135481,01 (0,0104)	135509,64 (0,0308)	32,1600		
PCB3038	550	126863,30	126874,79 (0,0091)	126894,18 (0,0243)	36,8500	126894,18 (0,0243)	126880,16 (0,0133)	35,9711		
PCB3038	600	119107,99	119096,58 (-0,0096)	119154,91 (0,0394)	40,5888	119133,86 (0,0217)	119147,01 (0,0328)	39,1855		
PCB3038	650	112063,73	112060,7 (-0,0027)	112093,59 (0,0266)	39,5011	112056,53 (-0,0064)	112081,15 (0,0155)	41,6177		
PCB3038	700	105854,40	105844,63 (-0,0092)	105888,13 (0,0319)	41,9777	105859,67 (0,005)	105877,98 (0,0223)	40,0233		
PCB3038	750	100362,55	100384,46 (0,0218)	100398,05 (0,0354)	44,9666	100361,46 (-0,0011)	100403,27 (0,0406)	44,6366		
PCB3038	800	95411,78	95404,85 (-0,0073)	95433,84 (0,0231)	42,8888	95408,86 (-0,0031)	95425,58 (0,0145)	43,2844		
PCB3038	850	91003,62	91013,73 (0,0111)	91033,70 (0,0331)	45,9144	91005,35 (0,0019)	91034,42 (0,0338)	42,2000		
PCB3038	900	86984,10	87002,05 (0,0206)	87012,94 (0,0332)	48,2522	86990,67 (0,0076)	87010,12 (0,0299)	48,7700		
PCB3038	950	83278,78	83283,54 (0,0057)	83302,12 (0,0280)	50,8288	83280,8 (0,0024)	83302,29 (0,0282)	50,7966		
PCB3038	1000	79858,79	79858,04 (-0,0009)	79879,06 (0,0254)	49,6644	79864,38 (0,007)	79879,91 (0,0264)	49,8422		
	# vezes melhor			8	12	7	14	15	21	

Tabela 3: Resultados finais da instância PCB3038, conjunto elite de tamanho 8 e suporte mínimo 5.

Nome	Instância			HH			DM-HH		
	p	Melhor	Conhecido	Melhor (%Dif)	Media (%Dif)	Tempo	Melhor (%Dif)	Media (%Dif)	Tempo
FL1400	10	101249,47		101249,55 (0,0001)	101249,55 (0,0001)	10,8966	101249,55 (0,0001)	101249,55 (0,0001)	6,7622
FL1400	20	57857,55		57857,94 (0,0007)	57857,94 (0,0007)	7,7644	57857,94 (0,0007)	57857,94 (0,0007)	5,4900
FL1400	30	44013,48		44013,48 (0,0000)	44013,48 (0,0000)	11,0522	44013,48 (0,0000)	44013,48 (0,0000)	8,6100
FL1400	40	35002,52		35002,52 (0,0000)	35004,09 (0,0045)	9,7488	35002,52 (0,0000)	35004,45 (0,0055)	8,9077
FL1400	50	29089,78		29090,23 (0,0015)	29090,23 (0,0015)	6,8022	29090,23 (0,0015)	29090,23 (0,0015)	6,0600
FL1400	60	25161,12		25161,12 (0,0000)	25163,04 (0,0076)	9,8111	25161,12 (0,0000)	25163,04 (0,0076)	9,2122
FL1400	70	22125,53		22126,03 (0,0023)	22126,03 (0,0023)	6,6700	22126,03 (0,0023)	22126,03 (0,0023)	6,1433
FL1400	80	19872,72		19870,85 (-0,0094)	19874,63 (0,0096)	7,5144	19872,72 (0,0000)	19875,84 (0,0157)	6,7377
FL1400	90	17987,94		17988,6 (0,0037)	17990,20 (0,0126)	6,8833	17988,6 (0,0037)	17988,60 (0,0037)	7,0111
FL1400	100	16551,20		16552,38 (0,0071)	16558,43 (0,0437)	8,5466	16552,24 (0,0063)	16558,66 (0,0451)	8,1955
FL1400	150	12026,47		12029,04 (0,0214)	12036,46 (0,0831)	9,5411	12033,09 (0,055)	12037,86 (0,0947)	9,4600
FL1400	200	9359,15		9357,97 (-0,0126)	9361,24 (0,0223)	9,5055	9359,97 (0,0088)	9361,91 (0,0295)	8,7722
FL1400	250	7741,51		7743,62 (0,0273)	7746,50 (0,0645)	10,2066	7741,45 (-0,0008)	7746,55 (0,0651)	9,1366
FL1400	300	6620,92		6624,17 (0,0491)	6627,40 (0,0979)	11,4788	6620,69 (-0,0035)	6627,40 (0,0979)	11,3100
FL1400	350	5720,91		5723,06 (0,0376)	5729,20 (0,1449)	13,1977	5724,93 (0,0703)	5730,11 (0,1608)	12,9800
FL1400	400	5006,83		5006,76 (-0,0014)	5012,02 (0,1037)	11,4788	5006,75 (-0,0016)	5011,55 (0,0943)	11,2522
FL1400	450	4474,96		4473,3 (-0,0371)	4478,33 (0,0753)	13,6688	4473,29 (-0,0373)	4476,48 (0,0340)	14,1100
FL1400	500	4047,90		4048,53 (0,0156)	4051,27 (0,0833)	14,5488	4046,88 (-0,0252)	4050,76 (0,0707)	15,4511
# vezes melhor				4	7	3	6	4	15

Tabela 4: Resultados finais da instância FL1400, conjunto elite de tamanho 8 e suporte mínimo 5.

Nome	Instância			HH			DM-HH		
	n	p	Valor Ótimo	Melhor (%Dif)	Media (%Dif)	Tempo	Melhor (%Dif)	Media (%Dif)	Tempo
PMED01	100	5	5819,00	5819,00 (0,0000)	5819,00 (0,0000)	0,0422	5819,00 (0,0000)	5819,00 (0,0000)	0,0333
PMED02	100	10	4093,00	4093,00 (0,0000)	4093,00 (0,0000)	0,0355	4093,00 (0,0000)	4093,00 (0,0000)	0,0377
PMED03	100	10	4250,00	4250,00 (0,0000)	4250,00 (0,0000)	0,0388	4250,00 (0,0000)	4250,00 (0,0000)	0,0322
PMED04	100	20	3034,00	3034,00 (0,0000)	3034,00 (0,0000)	0,0444	3034,00 (0,0000)	3034,00 (0,0000)	0,0377
PMED05	100	33	1355,00	1355,00 (0,0000)	1355,00 (0,0000)	0,0388	1355,00 (0,0000)	1355,00 (0,0000)	0,0422
PMED06	200	5	7824,00	7824,00 (0,0000)	7824,00 (0,0000)	0,1644	7824,00 (0,0000)	7824,00 (0,0000)	0,1077
PMED07	200	10	5631,00	5631,00 (0,0000)	5631,00 (0,0000)	0,1100	5631,00 (0,0000)	5631,00 (0,0000)	0,0955
PMED08	200	20	4445,00	4445,00 (0,0000)	4445,00 (0,0000)	0,0966	4445,00 (0,0000)	4445,00 (0,0000)	0,0866
PMED09	200	40	2734,00	2734,00 (0,0000)	2734,00 (0,0000)	0,1133	2734,00 (0,0000)	2734,00 (0,0000)	0,1100
PMED10	200	67	1255,00	1255,00 (0,0000)	1255,00 (0,0000)	0,1144	1255,00 (0,0000)	1255,00 (0,0000)	0,1144
PMED11	300	5	7696,00	7696,00 (0,0000)	7696,00 (0,0000)	0,2911	7696,00 (0,0000)	7696,00 (0,0000)	0,2111
PMED12	300	10	6634,00	6634,00 (0,0000)	6634,00 (0,0000)	0,2322	6634,00 (0,0000)	6634,00 (0,0000)	0,1600
PMED13	300	30	4374,00	4374,00 (0,0000)	4374,00 (0,0000)	0,1866	4374,00 (0,0000)	4374,00 (0,0000)	0,1477
PMED14	300	60	2968,00	2968,00 (0,0000)	2968,00 (0,0000)	0,2222	2968,00 (0,0000)	2968,00 (0,0000)	0,1977
PMED15	300	100	1729,00	1729 (0,0000)	1729,22 (0,0127)	0,2588	1729 (0,0000)	1729,22 (0,0127)	0,2555
PMED16	400	5	8162,00	8162,00 (0,0000)	8162,00 (0,0000)	0,6088	8162,00 (0,0000)	8162,00 (0,0000)	0,4666
PMED17	400	10	6999,00	6999,00 (0,0000)	6999,00 (0,0000)	0,4422	6999,00 (0,0000)	6999,00 (0,0000)	0,3566
PMED18	400	40	4809,00	4809 (0,0000)	4809,00 (0,0000)	0,3855	4809 (0,0000)	4809,22 (0,0046)	0,3577
PMED19	400	80	2845,00	2845 (0,0000)	2845,00 (0,0000)	0,3988	2845 (0,0000)	2845,00 (0,0000)	0,3711
PMED20	400	133	1789,00	1789 (0,0000)	1789,00 (0,0000)	0,4188	1789 (0,0000)	1789,00 (0,0000)	0,4188
PMED21	500	5	9138,00	9138,00 (0,0000)	9138,00 (0,0000)	0,8566	9138,00 (0,0000)	9138,00 (0,0000)	0,5744
PMED22	500	10	8579,00	8579 (0,0000)	8579,00 (0,0000)	0,7655	8579 (0,0000)	8579,00 (0,0000)	0,5833
PMED23	500	50	4619,00	4619,00 (0,0000)	4619,00 (0,0000)	0,5488	4619,00 (0,0000)	4619,00 (0,0000)	0,5077
PMED24	500	100	2961,00	2961,00 (0,0000)	2961,00 (0,0000)	0,5833	2961,00 (0,0000)	2961,00 (0,0000)	0,5555
PMED25	500	167	1828,00	1828,00 (0,0000)	1828,00 (0,0000)	0,7188	1828,00 (0,0000)	1828,00 (0,0000)	0,7411
PMED26	600	5	9917,00	9917,00 (0,0000)	9917,00 (0,0000)	1,3988	9917,00 (0,0000)	9917,00 (0,0000)	1,0522
PMED27	600	10	8307,00	8307,00 (0,0000)	8307,00 (0,0000)	1,0933	8307,00 (0,0000)	8307,00 (0,0000)	0,8244
PMED28	600	60	4498,00	4498,00 (0,0000)	4498,00 (0,0000)	0,8122	4498,00 (0,0000)	4498,00 (0,0000)	0,7433
PMED29	600	120	3033,00	3033,00 (0,0000)	3033,00 (0,0000)	0,9177	3033,00 (0,0000)	3033,00 (0,0000)	0,8788
PMED30	600	200	1989,00	1989,00 (0,0000)	1989,00 (0,0000)	1,1722	1989,00 (0,0000)	1989,00 (0,0000)	1,2011
PMED31	700	5	10086,00	10086,00 (0,0000)	10086,00 (0,0000)	2,1177	10086,00 (0,0000)	10086,00 (0,0000)	1,5811
PMED32	700	10	9297,00	9297,00 (0,0000)	9297,00 (0,0000)	1,5277	9297,00 (0,0000)	9297,00 (0,0000)	1,1344
PMED33	700	70	4700,00	4700,00 (0,0000)	4700,00 (0,0000)	1,1400	4700,00 (0,0000)	4700,00 (0,0000)	1,0766
PMED34	700	140	3013,00	3013,00 (0,0000)	3013,00 (0,0000)	1,3477	3013,00 (0,0000)	3013,00 (0,0000)	1,3011
PMED35	800	5	10400,00	10400,00 (0,0000)	10400,00 (0,0000)	2,6188	10400,00 (0,0000)	10400,00 (0,0000)	1,7766
PMED36	800	10	9934,00	9934,00 (0,0000)	9934,00 (0,0000)	2,2955	9934,00 (0,0000)	9934,00 (0,0000)	2,0766
PMED37	800	80	5057,00	5057,00 (0,0000)	5057,00 (0,0000)	1,5744	5057,00 (0,0000)	5057,00 (0,0000)	1,3900
PMED38	900	5	11060,00	11060,00 (0,0000)	11060,00 (0,0000)	3,8933	11060,00 (0,0000)	11060,00 (0,0000)	2,5900
PMED39	900	10	9423,00	9423,00 (0,0000)	9423,00 (0,0000)	2,4433	9423,00 (0,0000)	9423,00 (0,0000)	1,7477
PMED40	900	90	5128,00	5128 (0,0000)	5128,11 (0,0021)	2,3588	5128 (0,0000)	5128,00 (0,0000)	2,0633
# vezes melhor				0	1	4	0	1	34

Tabela 5: Resultados finais da classe ORLIB, conjunto elite de tamanho 8 e suporte mínimo 5.

Instância				HH			DM-HH		
Instância	n	p	Valor Ótimo	Melhor (%Dif)	Media (%Dif)	Tempo	Melhor (%Dif)	Media (%Dif)	Tempo
SL700	700	233	1847,00	1847 (0,0000)	1847,00 (0,0000)	1,6888	1847 (0,0000)	1847,00 (0,0000)	1,6222
SL800	800	267	2026,00	2026 (0,0000)	2026,00 (0,0000)	2,4800	2026 (0,0000)	2026,00 (0,0000)	2,4111
SL900	900	300	2106,00	2106 (0,0000)	2106,22 (0,0104)	3,3555	2106 (0,0000)	2106,44 (0,0209)	3,1544
# vezes melhor				0	1	0	0	0	3

Tabela 6: Resultados finais da classe SL, conjunto elite de tamanho 8 e suporte mínimo 5.

Instância			HH			DM-HH		
Nome	p	Valor Ótimo	Melhor (%Dif)	Media (%Dif)	Tempo	Melhor (%Dif)	Media (%Dif)	Tempo
GR100	5	5703,00	5703 (0,0000)	5703,00 (0,0000)	0,0411	5703 (0,0000)	5703,00 (0,0000)	0,0266
GR100	10	4426,00	4426 (0,0000)	4429,11 (0,0703)	0,0800	4426 (0,0000)	4427,56 (0,0352)	0,0866
GR100	15	3893,00	3893 (0,0000)	3893,00 (0,0000)	0,0655	3893 (0,0000)	3893,00 (0,0000)	0,0733
GR100	20	3565,00	3565 (0,0000)	3565,00 (0,0000)	0,0544	3565 (0,0000)	3565,00 (0,0000)	0,0622
GR100	25	3291,00	3291 (0,0000)	3291,11 (0,0033)	0,0600	3291 (0,0000)	3291,00 (0,0000)	0,0577
GR100	30	3032,00	3032 (0,0000)	3032,00 (0,0000)	0,0522	3032 (0,0000)	3032,00 (0,0000)	0,0644
GR100	40	2542,00	2542 (0,0000)	2542,00 (0,0000)	0,0466	2542 (0,0000)	2542,00 (0,0000)	0,0533
GR100	50	2083,00	2083 (0,0000)	2083,00 (0,0000)	0,0433	2083 (0,0000)	2083,00 (0,0000)	0,0500
GR150	5	10839,00	10839 (0,0000)	10839,00 (0,0000)	0,1255	10839 (0,0000)	10839,00 (0,0000)	0,1044
GR150	10	8729,00	8729 (0,0000)	8730,44 (0,0165)	0,1755	8729 (0,0000)	8729,00 (0,0000)	0,1644
GR150	15	7390,00	7390 (0,0000)	7390,78 (0,0106)	0,1477	7390 (0,0000)	7390,00 (0,0000)	0,1588
GR150	20	6454,00	6454 (0,0000)	6458,44 (0,0688)	0,1500	6454 (0,0000)	6459,33 (0,0826)	0,1366
GR150	25	5875,00	5875 (0,0000)	5878,33 (0,0567)	0,1388	5875 (0,0000)	5878,44 (0,0586)	0,1488
GR150	30	5495,00	5495 (0,0000)	5495,00 (0,0000)	0,1288	5495 (0,0000)	5495,00 (0,0000)	0,1255
GR150	40	4907,00	4907 (0,0000)	4907,11 (0,0022)	0,1022	4907 (0,0000)	4907,33 (0,0067)	0,1111
GR150	50	4374,00	4374 (0,0000)	4374,56 (0,0128)	0,1033	4374 (0,0000)	4374,67 (0,0153)	0,0955
# vezes melhor			0	4	9	0	4	7

Tabela 7: Resultados finais da classe GR, conjunto elite de tamanho 8 e suporte mínimo 5.

Instância			HH			DM-HH		
Nome	p	Melhor Conhecido	Melhor (%Dif)	Media (%Dif)	Tempo	Melhor (%Dif)	Media (%Dif)	Tempo
RW100	10	530,00	530 (0,0000)	530,00 (0,0000)	0,1177	530 (0,0000)	530,00 (0,0000)	0,1222
RW100	20	277,00	277,00 (0,0000)	277,00 (0,0000)	0,0577	277,00 (0,0000)	277,00 (0,0000)	0,0577
RW100	30	213,00	213,00 (0,0000)	213,00 (0,0000)	0,0433	213,00 (0,0000)	213,00 (0,0000)	0,0444
RW100	40	187,00	187,00 (0,0000)	187,00 (0,0000)	0,0366	187,00 (0,0000)	187,00 (0,0000)	0,0433
RW100	50	172,00	172,00 (0,0000)	172,00 (0,0000)	0,0311	172,00 (0,0000)	172,00 (0,0000)	0,0433
RW1000	10	67811,00	68136 (0,4793)	68192,00 (0,5619)	22,4922	67811 (0,0000)	68157,56 (0,5111)	20,0755
RW1000	25	24896,00	24923 (0,1085)	25020,44 (0,4998)	17,2411	24923 (0,1085)	24992,11 (0,3860)	16,3144
RW1000	50	11306,00	11275 (-0,2742)	11322,44 (0,1454)	10,0777	11273 (-0,2919)	11335,78 (0,2634)	10,4166
RW1000	75	7161,00	7135 (-0,3631)	7201,78 (0,5695)	7,9411	7154 (-0,0978)	7197,44 (0,5089)	7,1388
RW1000	100	5223,00	5222 (-0,0191)	5238,56 (0,2979)	6,0333	5232 (0,1723)	5239,22 (0,3105)	5,5777
RW1000	200	2706,00	2707 (0,037)	2710,56 (0,1685)	4,3588	2705 (-0,037)	2709,11 (0,1149)	4,2377
RW1000	300	2018,00	2018 (0,0000)	2018,22 (0,0109)	3,5088	2018 (0,0000)	2018,00 (0,0000)	3,2500
RW1000	400	1734,00	1734 (0,0000)	1734,00 (0,0000)	3,2844	1734 (0,0000)	1734,00 (0,0000)	3,7144
RW1000	500	1614,00	1614 (0,0000)	1614 (0,0000)	2,6377	1614 (0,0000)	1614,00 (0,0000)	3,0455
RW250	10	3691,00	3691 (0,0000)	3692,56 (0,0423)	0,9977	3691 (0,0000)	3691,78 (0,0211)	0,9888
RW250	25	1364,00	1364 (0,0000)	1364 (0,0000)	0,4500	1360 (-0,2933)	1363,11 (-0,0652)	0,4900
RW250	50	713,00	713 (0,0000)	714,44 (0,2026)	0,2633	713 (0,0000)	714,67 (0,2337)	0,2588
RW250	75	523,00	523 (0,0000)	523,11 (0,0212)	0,1722	523 (0,0000)	523,00 (0,0000)	0,1677
RW250	100	444,00	444 (0,0000)	444,00 (0,0000)	0,1455	444 (0,0000)	444,00 (0,0000)	0,1466
RW250	125	411,00	411 (0,0000)	411,00 (0,0000)	0,1277	411 (0,0000)	411,00 (0,0000)	0,1344
RW500	10	16108,00	16108 (0,0000)	16150,00 (0,2607)	4,6355	16108 (0,0000)	16143,22 (0,2186)	4,8822
RW500	25	5681,00	5681 (0,0000)	5703,56 (0,3971)	3,2055	5683 (0,0352)	5709,33 (0,4987)	3,0222
RW500	50	2628,00	2635 (0,2664)	2639,22 (0,4269)	1,4277	2626 (-0,0761)	2635,78 (0,2960)	1,6244
RW500	75	1757,00	1757 (0,0000)	1760,11 (0,1770)	0,9666	1757 (0,0000)	1758,67 (0,0950)	0,9366
RW500	100	1380,00	1380 (0,0000)	1381,44 (0,1043)	0,8622	1379 (-0,0725)	1381,89 (0,1370)	0,8311
RW500	150	1024,00	1024 (0,0000)	1024,11 (0,0107)	0,6533	1024 (0,0000)	1024,11 (0,0107)	0,5722
RW500	200	893,00	893 (0,0000)	893,00 (0,0000)	0,5733	893 (0,0000)	893,00 (0,0000)	0,5666
RW500	250	833,00	833 (0,0000)	833,00 (0,0000)	0,4800	833 (0,0000)	833,00 (0,0000)	0,5322
# vezes melhor			3	5	13	6	11	14

Tabela 8: Resultados finais da classe RW, conjunto elite de tamanho 8 e suporte mínimo 5.

As Tabelas 9 e 10 apresentam os resultados para a execução do DM-HH utilizando, como parâmetro de mineração de dados, suporte mínimo 4 e conjunto elite de tamanho 8. Essas tabelas visam ilustrar o crescimento do tempo computacional do DM-HH quando se utiliza um suporte mínimo mais baixo e um valor de p elevado. Isto se deve ao fato de um número potencialmente alto de padrões ser extraído quando o tamanho das soluções (p) a serem mineradas é alto e o suporte mínimo é baixo, ocasionando um aumento no tempo de execução do módulo de mineração de dados, responsável pela extração dos padrões.

Nome	Instância		Melhor Conhecido	HH Media (%Dif)	Tempo	DM-HH		Tempo
	p	Melhor (%Dif)				Melhor (%Dif)	Media (%Dif)	
RL5934	10	9794951.00	9794973.65 (0,0002)	9794973.65 (0,0002)	792,9566	9794973.65 (0,0002)	9794973.65 (0,0002)	765,6077
RL5934	20	6718848.19	6718848.19 (0,0000)	6718958,30 (0,0016)	507,2600	6718848.19 (0,0000)	6719065.00 (0,0032)	463,4166
RL5934	30	5374936.14	5374936.14 (0,0000)	5375613,12 (0,0126)	413,4366	5374936.14 (0,0000)	5375700.82 (0,0142)	423,6900
RL5934	40	4550364.60	4550327.09 (-0,0008)	4550415,43 (0,0011)	253,8266	4550327.09 (-0,0008)	4550373,41 (0,0002)	256,2744
RL5934	50	4032379.97	4032379.97 (0,0000)	4032857.64 (0,0118)	240,9022	4032379.97 (0,0000)	4032746,74 (0,0091)	217,2077
RL5934	60	3642397.88	3642064.7 (-0,0091)	3642968,54 (0,0157)	241,7611	3642064.7 (-0,0091)	3643002.49 (0,0166)	240,9900
RL5934	70	3343712.45	3344669.26 (0,0286)	3344939.68 (0,0367)	229,2144	3343770,69 (0,0017)	3344789.46 (0,0322)	225,5200
RL5934	80	3094824.49	3094605.63 (-0,0071)	3095841.50 (0,0329)	193,7588	3094553,49 (-0,0088)	3095506,44 (0,0220)	191,5544
RL5934	90	2893362.39	2893297,83 (-0,0022)	2895402.27 (0,0705)	195,6666	2894013,49 (0,0225)	2895317,19 (0,0076)	168,1422
RL5934	100	2725180.81	2725067,34 (-0,0042)	2726827.46 (0,0604)	149,8466	2725068.39 (-0,0041)	2726061,90 (0,0323)	168,9577
RL5934	150	2147881.53	2147863.31 (-0,0008)	2149142.92 (0,0587)	107,5877	2147811,00 (-0,0033)	2148452,97 (0,0266)	107,6333
RL5934	200	1808179.07	1808423,86 (0,0135)	1809157,30 (0,0541)	101,9488	1808472.11 (0,0162)	1809443.56 (0,0699)	96,7055
RL5934	250	1569941.34	1569967,46 (0,0017)	1570812.55 (0,0555)	89,7511	1570115,64 (0,0111)	1570572,16 (0,0402)	87,5355
RL5934	300	1394115.39	1394278,15 (0,0117)	1394704,10 (0,0422)	82,5066	1394299,56 (0,0132)	1394834,85 (0,0516)	73,1933
RL5934	350	1256844.04	1256795,35 (-0,0039)	1257497,24 (0,0520)	83,4977	1257096,85 (0,0201)	1257535,95 (0,0551)	75,4933
RL5934	400	1145669.38	1145765,09 (0,0084)	1146166,04 (0,0434)	90,3455	1145750,62 (0,0071)	1146218,41 (0,0479)	85,4833
RL5934	450	1053363,64	1053564,91 (0,0191)	1054027,69 (0,0630)	87,8066	1053412,75 (0,0047)	1054058,88 (0,0660)	85,9611
RL5934	500	973995,18	974019,92 (0,0025)	974455,34 (0,0472)	85,0722	974165,51 (0,0175)	974428,19 (0,0445)	83,2066
RL5934	600	848283,85	848421,86 (0,0163)	848660,09 (0,0444)	91,6877	848448,36 (0,0194)	848616,31 (0,0392)	113,3744
RL5934	700	752068,38	752301,57 (0,031)	752449,98 (0,0507)	100,3744	752147,63 (0,0105)	752310,67 (0,0322)	180,3188
RL5934	800	676795,78	676935,96 (0,0207)	677101,29 (0,0451)	103,6744	676893,53 (0,0144)	677059,27 (0,0389)	228,4688
RL5934	900	613367,44	613497,92 (0,0213)	613547,55 (0,0294)	115,0988	613452,55 (0,0139)	613580,76 (0,0348)	354,4711
RL5934	1000	558802,38	558853,74 (0,0092)	558870,00 (0,0300)	113,9822	558855,39 (0,0095)	558965,10 (0,0291)	650,3011
RL5934	1100	511813,19	511872,05 (0,0115)	512027,71 (0,0419)	121,1633	511909,87 (0,0189)	511971,87 (0,0310)	961,6633
RL5934	1200	470295,38	470388,23 (0,0197)	470486,17 (0,0406)	128,5722	470409,65 (0,0243)	470476,89 (0,0386)	1176,4500
RL5934	1300	433597,44	433663,61 (0,0153)	433703,01 (0,0243)	143,5011	433644,55 (0,0109)	433715,61 (0,0273)	1942,5900
RL5934	1400	401853,00	401912,84 (0,0149)	401972,73 (0,0298)	147,7311	401885,42 (0,0081)	401951,49 (0,0245)	2294,3400
RL5934	1500	374014,57	374043,2 (0,0077)	374083,48 (0,0184)	153,3822	374049,06 (0,0092)	374110,92 (0,0258)	2798,4300
# vezes melhor			12	11	14	10	16	14

Tabela 9: Resultados finais da instância RL5934, conjunto elite de tamanho 8 e suporte mínimo 4.

Nome	Instância		Melhor Conhecido	HH Media (%Dif)	Tempo	DM-HH		Tempo
	p	Melhor (%Dif)				Melhor (%Dif)	Media (%Dif)	
PCB3038	10	1213082,03	1213082,03 (0,0000)	1213082,03 (0,0000)	162,6133	1213082,03 (0,0000)	1213082,03 (0,0000)	131,2300
PCB3038	20	840844,53	840844,53 (0,0000)	840852,71 (0,0010)	107,7166	840844,53 (0,0000)	840860,89 (0,0019)	88,9866
PCB3038	30	677306,76	677272,22 (-0,0051)	677648,38 (0,0504)	88,1677	677272,22 (-0,0051)	677575,97 (0,0397)	80,2822
PCB3038	40	571887,75	571887,75 (0,0000)	571891,10 (0,0006)	51,2366	571887,97 (0,0000)	571905,67 (0,0031)	48,1055
PCB3038	50	507582,13	507558,16 (-0,0047)	507602,97 (0,0041)	51,6255	507558,16 (-0,0047)	507591,93 (0,0019)	48,8322
PCB3038	60	460771,87	460772,03 (0,0000)	460873,27 (0,0220)	43,6066	460771,87 (0,0000)	460827,46 (0,0121)	42,4122
PCB3038	70	426068,24	426068,24 (0,0000)	426146,01 (0,0183)	42,4955	426068,24 (0,0000)	426107,68 (0,0093)	42,1400
PCB3038	80	397529,25	397504,97 (-0,0061)	397641,81 (0,0283)	38,0922	397502,32 (-0,0068)	397601,24 (0,0181)	37,5922
PCB3038	90	373248,08	373241,86 (-0,0017)	373440,78 (0,0516)	40,0944	373294,31 (0,0124)	373393,80 (0,0390)	40,8522
PCB3038	100	352628,35	352649,37 (0,006)	352802,03 (0,0493)	38,3911	352647,5 (0,0054)	352808,63 (0,0511)	37,3711
PCB3038	150	281193,96	281219,83 (0,0092)	281384,25 (0,0677)	30,3688	281216,19 (0,0079)	281313,39 (0,0425)	31,3744
PCB3038	200	238373,26	238418,23 (0,0189)	238480,12 (0,0448)	28,1333	238439,44 (0,0278)	238507,47 (0,0563)	28,2488
PCB3038	250	209241,25	209274,8 (0,016)	209341,81 (0,0481)	29,8277	209252,89 (0,0056)	209333,35 (0,0440)	30,1366
PCB3038	300	187712,12	187738,45 (0,014)	187792,04 (0,0426)	30,1622	187735,14 (0,0123)	187769,78 (0,0307)	28,5311
PCB3038	350	170973,34	170961 (-0,0072)	171017,63 (0,0259)	33,2866	170976,37 (0,0018)	171033,39 (0,0351)	29,9422
PCB3038	400	157030,46	157060,47 (0,0191)	157084,45 (0,0344)	32,2044	157053,7 (0,0148)	157091,86 (0,0391)	30,8388
PCB3038	450	145384,18	145378,94 (-0,0036)	145397,06 (0,0089)	34,6400	145400,15 (0,011)	145414,99 (0,0212)	34,7733
PCB3038	500	135467,85	135495,22 (0,0202)	135528,59 (0,0448)	33,0188	135469,94 (0,0015)	135503,14 (0,0261)	40,6422
PCB3038	550	126863,30	126874,79 (0,0091)	126894,18 (0,0243)	36,8500	126861,64 (-0,0017)	126888,15 (0,0196)	46,7144
PCB3038	600	119107,99	119096,58 (-0,0096)	119154,91 (0,0394)	40,5888	119103,64 (-0,0037)	119161,05 (0,0445)	56,3733
PCB3038	650	112063,73	112060,7 (-0,0027)	112093,59 (0,0266)	39,5011	112058,09 (-0,005)	112096,55 (0,0293)	65,2233
PCB3038	700	105854,40	105844,63 (-0,0092)	105888,13 (0,0319)	41,9777	105866,75 (0,0117)	105891,93 (0,0355)	75,5400
PCB3038	750	100362,55	100384,46 (0,0218)	100398,05 (0,0354)	44,9666	100372,49 (0,0099)	100410,77 (0,0480)	77,6322
PCB3038	800	954411,78	95404,85 (-0,0073)	95433,84 (0,0231)	42,8888	95400,83 (-0,0115)	95424,77 (0,0136)	103,3377
PCB3038	850	91003,62	91013,73 (0,0111)	91033,70 (0,0331)	45,9144	91026,74 (0,0254)	91041,54 (0,0417)	111,9944
PCB3038	900	86984,10	87002,05 (0,0206)	87012,94 (0,0332)	48,2522	86997,24 (0,0151)	87016,36 (0,0371)	159,5833
PCB3038	950	83278,78	83283,54 (0,0057)	83302,12 (0,0280)	50,8288	83285,53 (0,0081)	83307,47 (0,0345)	221,3611
PCB3038	1000	79858,79	79858,04 (-0,0009)	79879,06 (0,0254)	49,6644	79859,5 (0,0009)	79875,91 (0,0214)	312,1711
# vezes melhor			9	14	16	13	13	12

Tabela 10: Resultados finais da instância PCB3038, conjunto elite de tamanho 8 e suporte mínimo 4.

CAPÍTULO 5 - CONCLUSÕES

Este trabalho apresentou a incorporação de um módulo de mineração de dados em uma heurística híbrida para o problema das p -medianas. Seu principal objetivo foi melhorar a qualidade das soluções obtidas por meio da descoberta de padrões que ocorre em um número significativo de soluções, utilizando-os nas construções de novas soluções. A motivação desta proposta se baseou na hipótese de que padrões extraídos de soluções sub-ótimas encontradas ao longo da execução do algoritmo poderiam guiar a busca por melhores soluções.

Os resultados experimentais mostraram que a incorporação da mineração de dados, em média, para várias classes de instâncias, melhora a qualidade da solução obtida. Outro ganho com a utilização de mineração de dados foi a diminuição do tempo gasto nos processos de busca local e de pós-otimização, uma vez que a busca local encontrará seu ótimo local mais rapidamente e a pós-otimização efetuará menos gerações, melhorando o desempenho.

Como trabalho futuro, pretende-se avaliar a ativação do módulo de mineração de dados mais de uma vez ao longo da execução das iterações da heurística híbrida de maneira a refinar os padrões minerados. Em [6], essa iniciativa resultou em soluções de melhor qualidade obtidas em um tempo computacional inferior quando comparadas com as soluções obtidas pela estratégia que realiza a mineração de dados apenas uma vez.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] R. D. Galvão e C. S. ReVelle. A lagrangean heuristic for the maximal covering problem. *European Journal of Operational Research*, pp. 114–123, 1996.
- [2] J. E. Beasley. A note on solving large p-median problems. *European Journal of Operational Research*, 21:270–273, 1985.
- [3] G. Cornuejols, M. L. Fisher e G. L. Nemhauser. Location of bank accounts to optimize float: An analytical study of exact and approximate algorithms. *Management Science*, 23:789–810, 1977.
- [4] N. Cristofides. Graph theory. an algorithm approach. *New York: Academic Press*, 1975.
- [5] P. Festa e M. G. C. Resende. Grasp: An annotated bibliography. Em *Essays and Surveys on Metaheuristics*, pp. 325–367. Kluwer Academic Publishers, 2002.
- [6] E. Fonseca, R. Fuchshuber, L. F. M. Santos, S. L. Martins e A. Plastino. Explorando a metaheurística híbrida dm-grasp para o problema de multicast confiável. *Simpósio Brasileiro de Pesquisa Operacional*, 2008.
- [7] I. F. Glover e M. Laguna. Fundamentals of scatter search and path relinking. *Control and Cybernetics*, 39:653–684, 2000.
- [8] G. Grahe e J. Zhu. Efficiently using prefix-trees in mining frequent itemsets. Em *Proceedings of the IEEE ICDM Workshop on Frequent Itemset Mining Implementations*, 2003.
- [9] J. Han e M. Kamber. *Data Mining: Concepts and Techniques (2nd edition)*. Morgan Kaufmann, 2006.
- [10] P. Hansen e B. Jaumard. Cluster analysis and mathematical programming. *Mathematical Programming*, 79:191–215, 1997.
- [11] O. Kariv e S. L. Hakimi. An algorithmic approach to network location problems. ii: The p-medians. *SIAM Journal of Applied Mathematics*, 37:513–538, 1979.
- [12] J. Krarup e P. Pruzan. The simple plant location problem: survey and synthesis. *European Journal of Operational Research*, 1:36–81, 1983.
- [13] M. Laguna e R. Martí. Grasp and path relinking for 2–layer straight line crossing minimization.
- [14] M. Matsumoto e T. Nishimura. Mersenne twister: A 623-dimensionally equidistributed uniform pseudorandom number generator. *ACM Transactions on Modeling and Computer Simulation*, 8, 1998.

- [15] I. H. Osman e G. Laporte. Metaheuristics: A bibliography. Em *Annals of Operations Research*, volume 63, pp. 513–623, 1996.
- [16] G. Reinelt. Tsplib: A traveling salesman problem library. *ORSA Journal on Computing*, 3:376–384, 1991.
- [17] M. G. C. Resende e R. F. Werneck. A hibrid heuristic for the p-median problem. *Journal of Heuristics*, 10:59–88, 2004.
- [18] M. Ribeiro, A. Plastino e S. L. Martins. Hybridization of grasp metaheuristic with data mining techniques. *Journal of Mathematical Modelling and Algorithms*, 5:23–41, Abril de 2006.
- [19] L. F. Santos, S. L. Martins e A. Plastino. Applications of the dm-grasp heuristic: A survey. *International Transactions in Operational Research*, 15:387–416, 2008.
- [20] L. F. Santos, R. Milagres, C. V. Albuquerque, S. L. Martins e A. Plastino. A hybrid grasp with data mining for efficient server replication for reliable multicast. Em *Proceedings of the GLOBECOM*, 2006.
- [21] L. F. Santos, M. H. Ribeiro, A. Plastino e S. L. Martins. A hybrid grasp with data mining for the maximum diversity problem. Em *Proceedings of the International Workshop on Hybrid Metaheuristics*, pp. 67–78, 2005.
- [22] E. L. F. Senne e L. A. N. Lorena. Langrangean/surrogate heuristics for p -median problems. *Computing Tools for Modeling, Optimization and Simulation: Interfaces in Computer Science and Operations Research*, pp. 115–130, 2000.
- [23] E-G. Talbi. A taxonomy of hybrid metaheuristics. *Journal of Heuristics*, 8:541–564, 2002.
- [24] M. B. Teitz e P. Bart. Heuristic methods for estimating the generalized vertex median of a weighted graph. *Operations Research*, 16:955–961, 1968.
- [25] R. Whitaker. A fast algorithm for the greedy interchange of large-scale clustering and median location prolems. *INFOR*, 21:95–108, 1983.