

UNIVERSIDADE FEDERAL FLUMINENSE

UM ESTUDO DE PROBLEMAS DE CLUSTERIZAÇÃO COM RESTRIÇÕES DE
CAPACIDADE E DE CONEXIDADE

NÁDIA MENDES DOS SANTOS

Niterói

2014

NÁDIA MENDES DOS SANTOS

UM ESTUDO DE PROBLEMAS DE CLUSTERIZAÇÃO COM RESTRIÇÕES DE
CAPACIDADE E DE CONEXIDADE

Tese de Doutorado submetida ao Programa de Pós-Graduação em Computação da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Doutor. Área de Concentração: Algoritmos e Otimização.

Prof. Luiz Satoru Ochi D.Sc. (Orientador)
Universidade Federal Fluminense (IC-UFF)

Niterói
2014

NÁDIA MENDES DOS SANTOS

UM ESTUDO DE PROBLEMAS DE CLUSTERIZAÇÃO COM RESTRIÇÕES DE
CAPACIDADE E DE CONEXIDADE

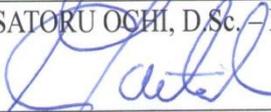
Tese de Doutorado submetida ao Programa de
Pós-Graduação em Computação da
Universidade Federal Fluminense, como
requisito parcial para obtenção do Grau de
Doutor. Área de Concentração: Algoritmos e
Otimização.

Aprovada por:

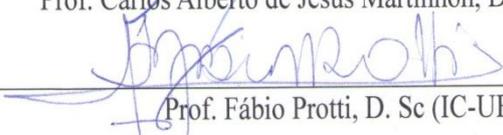
BANCA EXAMINADORA



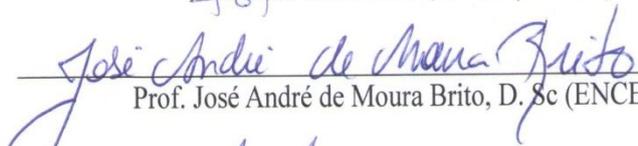
Prof. LUIZ SATORU OCHI, D.Sc. – Presidente (IC-UFF)



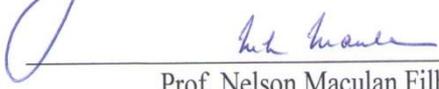
Prof. Carlos Alberto de Jesus Martinhon, D. Sc (IC-UFF)



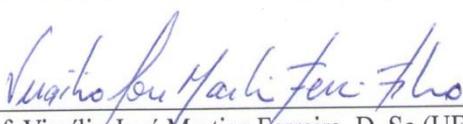
Prof. Fábio Protti, D. Sc (IC-UFF)



Prof. José André de Moura Brito, D. Sc (ENCE-IBGE)



Prof. Nelson Maculan Filho, D. Sc (UFRJ-COPPE)



Prof. Virgílio José Martins Ferreira, D. Sc (UFRJ-COPPE)

Niterói, 25 de Novembro de 2014

A Deus, por ser minha forte rocha e meu refúgio
À minha mãe, por ter me iniciado nos caminhos
dos estudos e por seu amor incondicional.

AGRADECIMENTOS

Primeiramente, a Deus que me deu força e proteção durante as inúmeras viagens à cidade de Niterói, sempre presente nas tribulações. A Deus, minha fé hoje e sempre.

À minha mãe, Maria de Jesus dos Santos Nascimento, por ter me dado amor, carinho e conselhos nas horas mais difíceis da minha vida.

À Ravena Bezerra do Nascimento, por sua paciência e conselhos nas dificuldades encontradas durante o desenvolvimento desta tese.

Ao meu orientador, professor Dr. Luiz Satoru Ochi, pela confiança depositada em mim desde minha inscrição para o programa DINTER-IFPI-UFF, em que logo me aceitou como orientanda. Seu apoio durante os meses de estágio na UFF e os períodos distantes, no estado do Piauí, foram de valiosa contribuição no desenvolvimento desta tese.

Ao professor José André de Moura Brito, sempre dedicado e esclarecedor no desenvolvimento deste trabalho. Sua orientação nesta pesquisa foi de fundamental importância.

Aos companheiros do Doutorado em Computação os quais merecem mérito pelo progresso da pesquisa, Eyder Rios e Gustavo S. Semaan.

E ao IFPI (Instituto Federal de Educação, Ciência e Tecnologia do Piauí) que contribui com o apoio financeiro necessário à realização do convênio DINTER (Doutorado InterInstitucional) junto à UFF (Universidade Federal Fluminense).

“Não há limite para nada, podemos chegar onde quisermos se tivermos dedicação. Com trabalho e esforço é possível”. João H.Vogel, 18 anos aceito na Universidade de Harvard.

RESUMO

O presente trabalho de doutorado traz uma proposta de solução para um Problema de Agrupamento que agrega Restrições de Capacidade e de Conexidade. Trata-se de uma aplicação real que pode ser mapeada em um problema de clusterização em grafos com restrições de capacidade e de conexidade. Em geral, a obtenção de um ótimo global para tal problema é uma tarefa muito difícil, tendo em vista o aspecto combinatório. Procurando-se encontrar soluções de boa qualidade para este problema, foram desenvolvidas versões diferentes de algoritmos heurísticos que utilizam os conceitos das metaheurísticas GRASP e VNS. No que concerne ao algoritmo GRASP (*Greedy Randomized Adaptive Search Procedure*), foram implementadas quatro versões diferentes, a saber: a primeira versão utilizando o modelo clássico, já conhecido na literatura, a segunda foi baseada na técnica de reconexão de caminhos, uma terceira aplicando uma busca através de um procedimento VND (*Variable Neighbourhood Descent*) e uma quarta com uma busca com componentes randômicos através de um módulo RVND (*Random VND*). O algoritmo VNS foi implementado em seu modelo tradicional e com três variações diferentes, ou seja, um VNS (*Variable Neighbourhood Search*) padrão, um GVNS (*General Variable Neighbourhood Search*), um RVNS (*Reduced Variable Neighbourhood Search*) e um SVNS (*Skewed Variable Neighbourhood Search*).

São apresentados testes comparativos com algoritmos da literatura ilustrando a eficiência (tempo) e/ou eficácia dos métodos propostos. Assim, os resultados observados para os experimentos computacionais realizados com instâncias reais do Censo Demográfico 2010 indicam que os algoritmos propostos constituem-se como uma boa alternativa para a resolução do problema que foi o objeto de estudo desta tese.

Palavras-chave: clusterização, capacidade, conexidade, GRASP, VNS.

ABSTRACT

This doctoral work brings a proposed solution to a problem of grouping that adds capacity constraints and connectivity. It is an actual application that is associated with a clustering problem in graphs with capacity constraints and connectivity. In general, to obtain a global optimal for this problem is a very difficult task in view of the combinatorial aspect. Seeking to find good quality solutions to this problem, different versions of heuristic algorithms which use the concepts of metaheuristics GRASP and VNS been developed. With respect to the algorithm GRASP four different versions have been implemented, namely: the first version using the classical model, already known in the literature, the second was based on the path relinking technique, the third by applying an search through VND procedure and the fourth with a search with random components through a module RVND (Random VND). The VNS algorithm is implemented in its traditional model and with three different variations, in other words, a standard VNS (Variable Neighbourhood Search), a GVNS (General Variable Neighbourhood Search), a RVNS (Reduced Variable Neighbourhood Search) and a SVNS (Skewed Variable Neighbourhood Search).

Comparative tests are shown with algorithms from the literature illustrating the efficiency (time) and/or efficacy of the proposed methods. Thus, the results observed for the computational experiments with real instances of the 2010 Population Census indicate that the proposed algorithms constitute themselves as a good alternative to solve the problem that was the object of study of this thesis.

Keywords: clusterizing, capacity, connectedness , GRASP, VNS.

LISTA DE ILUSTRAÇÕES

1.1 Conjunto de Objetos.....	03
2.1 Representação da Distância Euclidiana e de Manhattan.....	13
2.2 Representação Gráfica da Tabela 2.1.....	14
2.3 Classificação dos algoritmos de clusterização.....	16
2.4 Classificação dos algoritmos de clusterização (adaptado de SOARES 2004).....	17
2.5 Grafo de uma Rede Social.....	20
2.6 Clusterização com Restrição de Conexidade e Capacidade Mínima (a) Um único Aglomerado de Setores Censitários (b) Aglomerados Conexos e com Capacidade Mínima.....	20
2.7 Representação (a) Setores Censitários, (b) Grafo Completo e (c) Grafo Original.....	23
2.8 Construção de AGM adaptado de Neves 2003.....	25
2.9 AGM (a) e APONDS (b).....	26
2.10 Exemplo do Cálculo do Custo de remoção de uma aresta.....	27
2.11 Representação da região, grafo, AGM e <i>cluster</i> de BH.....	29
3.1 Pseudo-código do GRASP.....	34
3.2 Representação da Solução.....	35
3.3 Fases de Construtor 1.....	38
3.4 Seleção da subárvore principal da AGM.....	39
3.5 Vértices que estão no caminho entre V_8 e V_9	40
3.6 Exemplificação do vértice V_1 na subárvore principal da AGM.....	40
3.7 Exemplificação do vértice V_6 na subárvore principal da AGM.....	41
3.8 Geração da subárvore principal da AGM.....	41
3.9 Subárvore principal da AGM com os vértices capacitados.....	41
3.10 Fases de Construtor 2.....	43
3.11 Fases de Construtor 3.....	44
3.12 Fases de Construtor 4.....	45
3.13 Fases de Construtor 5 – Solução Inválida.....	46
3.14 Busca Local 1 – possibilidade de migração de vértices.....	47
3.15 Busca Local 1 – proibida a migração de vértices.....	48
3.16 Busca Local 1 – migração de vértices com <i>cluster</i> capacitados.....	48
3.17 Busca Local 2 – possibilidade de migração de vértices.....	50
3.18 Busca Local 2 – proibida a migração de vértices.....	50

3.19 Busca Local 4 – execução	51
3.20 Grafo da União do <i>Cluster 1</i> e <i>Cluster 2</i> utilizado pelo Construtor 3.....	52
3.21 Busca Local 5 – Remoção da aresta <i>a</i>	53
3.22 Busca Local 5 – Remoção da aresta <i>b</i>	53
3.23 Busca Local 5 – Remoção da aresta <i>c</i>	53
3.24 Busca Local 6 – execução	55
3.25 VND com $N^k(s)$ vizinhança	60
3.26 Pseudo-código do algoritmo GRASP com VND.....	62
3.27 Pseudo-código do algoritmo VNS	64
3.28 Procedimento de Perturbação	66
3.29 Comportamento do RVNS com três vizinhanças	68
4.1 Soluções GRASP Padrão.....	80
4.2 Soluções GRASP com Path-Relinking	80
4.3 Soluções GRASP com VND	81
4.4 Soluções GRASP com RVND.....	81
4.5 Soluções VNS Padrão	82
4.6 Soluções GVNS	82
4.7 Soluções RVNS	83
4.8 Soluções SVNS.....	83
4.9 Melhor Solução por Algoritmo.....	84
4.10 Melhor Categoria por Algoritmo	85
4.11 Comparativo Algoritmos SVNS x <i>Software SKATER</i>	86
4.12 Análise probabilística da instância 28 – alvo fácil.....	88
4.13 Análise probabilística da instância 28 – alvo difícil	89
4.14 Análise probabilística da instância 39 – alvo fácil.....	89
4.15 Análise probabilística da instância 39 – alvo difícil	90
4.16 Análise probabilística da instância 60 – alvo fácil.....	91
4.17 Análise probabilística da instância 60 – alvo difícil	92

LISTA DE TABELAS

2.1 Exemplo de Instância	13
3.1 Atributos dos vértices do grafo	36
4.1 Relação das instâncias utilizadas	72
4.2 Sigla dos algoritmos utilizando também o Grafo Original.....	75
4.3 Sigla dos algoritmos utilizando a AGM construída com <i>Kruskal</i> Modificado	75
4.4 Sigla dos algoritmos utilizando a AGM construída com <i>Kruskal</i> Padrão.....	76
4.5 Sigla dos algoritmos utilizando também o Grafo Original.....	77
4.6 Sigla dos algoritmos utilizando a AGM construída com <i>Kruskal</i> Modificado	77
4.7 Sigla dos algoritmos utilizando a AGM construída com <i>Kruskal</i> Padrão.....	77
4.8 Resultado de Análise de Robustez para a instância 28 (pequeno porte), 39 (médio porte) e 60 (grande porte).....	93
4.9 Medidas dos tempos de processamento dos algoritmos (segundos)	94

LISTA DE ABREVIATURAS E SIGLAS

AG	-	Algoritmo Genético
AGM	-	Árvore Geradora Mínima (<i>The Minimum Spanning Tree</i>)
AGT	-	Algoritmo Genético Tradicional
GRASP	-	<i>Greedy Randomized Adaptative Search Procedure</i>
LRC	-	Lista Restrita de Candidatos (<i>Restricted Candidate List</i>)
PR	-	<i>Path-Relinking</i>
RC	-	Reconexão por Caminhos
SB	-	Solução Base
SAT	-	Satisfabilidade
SKATER	-	<i>Spatial 'K'luster Analysisist by Tree Edge Removal</i>
SI	-	Solução Intermediária
SG	-	Solução Guia
VND	-	Descida com Vizinhança Variável (<i>Variable Neighborhood Descent</i>)
VNS	-	<i>Variable Neighbourhood Search</i>
SVNS	-	<i>Skewed Variable Neighbourhood Search</i>
GVNS	-	<i>General Variable Neighbourhood Search</i>
RVNS	-	<i>Reduced Variable Neighbourhood Search</i>

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	1
1.1 Motivação e Justificativa	2
1.2 Objetivos	4
1.3 Metodologia.....	4
1.4 Contribuições.....	5
1.5 Organização.....	6
CAPÍTULO 2 – O PROBLEMA DE CLUSTERIZAÇÃO	8
2.1 Descrição do Problema	8
2.2 Medidas de Similaridade.....	11
2.3 Funções Objetivo	15
2.4 Classificação dos Algoritmos de Clusterização	15
2.5 O Problema de Clusterização com Restrições de Capacidade e Conexidade..(PC- RCC).....	19
2.5.1 Descrição do Problema (PC – RCC).....	19
2.5.2 Modelagem do Problema (PC-RCC)	22
2.6 Revisão Bibliográfica.....	29
CAPÍTULO 3 – HEURÍSTICAS PARA O PROBLEMA DE CLUSTERIZAÇÃO	32
3.1 GRASP.....	32
3.2 Aspectos Comuns aos Algoritmos.....	34
3.2.1 Representação da Solução	35
3.2.2 Etapa de Construção.....	36
3.2.2.1 Construtor 1.....	37
3.2.2.2 Construtor 2.....	39
3.2.2.3 Construtor 3.....	43
3.2.2.4 Construtor 4.....	43
3.2.2.5 Construtor 5.....	45

3.2.3 Procedimento de Busca Local.....	46
3.2.3.1 Busca Local 1	47
3.2.3.2 Busca Local 2	49
3.2.3.3 Busca Local 3	50
3.2.3.4 Busca Local 4	51
3.2.3.5 Busca Local 5	52
3.2.3.6 Busca Local 6	54
3.3 Algoritmos Heurísticos Propostos	55
3.3.1 PATH-RELINKING (PR)	55
3.3.2 GRASP com RECONEXÃO DE CAMINHOS	57
3.3.3 VARIABLE NEIGHBORHOOD DESCENT (VND) ou DESCIDA EM VINHANÇA VARIÁVEL.....	58
3.3.4 GRASP com VND.....	61
3.3.5 RANDOM VARIABLE NEIGHBORHOOD DESCENT (RVND) ou DESCIDA EM VINHANÇA VARIÁVEL COM ORDEM ALEATÓRIA....	62
3.3.6 GRASP com RVND	63
3.3.7 VARIABLE NEIGHBORHOOD SEARCH (VNS) OU BUSCA EM VIZINHANÇA VARIÁVEL.....	63
3.3.7.1 ALGORITMO VNS.....	65
3.3.8 GENERAL VARIABLE NEIGHBORHOOD SEARCH (GVNS) OU BUSCA GERAL EM VIZINHANÇA VARIÁVEL	67
3.3.9 REDUCED VARIABLE NEIGHBORHOOD SEARCH (RVNS) ou BUSCA REDUZIDA EM VIZINHANÇA VARIÁVEL.....	67
3.3.10 SKEWED VARIABLE NEIGHBORHOOD SEARCH (SVNS) OU BUSCA INCLINADA EM VIZINHANÇA VARIÁVEL.....	68
3.3.10.1 ALGORITMO SVNS.....	69
CAPÍTULO 4 – EXPERIMENTOS COMPUTACIONAIS.....	71
4.1 Tecnologias	71

4.2 Instâncias utilizadas	72
4.3 Algoritmos.....	73
4.4 Experimentos Realizados	78
4.4.1 Experimentos com Algoritmos Propostos.....	78
4.5 Avaliação Probabilística dos Resultados	86
4.6 Análise de Robustez dos Resultados	93
CAPÍTULO 5 – CONCLUSÕES E TRABALHOS FUTUROS.....	95
5.1 Conclusões	95
5.2 Trabalhos Futuros	98
REFERÊNCIAS.....	99
APENDICE A	107

CAPÍTULO 1 – INTRODUÇÃO

É crescente o destaque que a área de otimização combinatória e mais geralmente a área de pesquisa operacional (PO) vem apresentando no contexto da Ciência da Computação. Este fato em parte é decorrente de que muitos dos problemas reais que são estudados atualmente em Ciência da Computação, podem ser mapeados como problemas de otimização combinatória, ou de forma mais geral, como problemas de PO pertencentes à classe NP-Difícil.

Em particular, no que diz respeito aos problemas de elevada complexidade computacional, mesmo diante do grande desenvolvimento dos métodos exatos de otimização e da evolução dos computadores, a sua aplicação de forma isolada na solução de muitos problemas NP-Difícil torna-se limitada devido ao dinamismo e a necessidade de, em muitos casos, haver uma resposta em um baixo tempo computacional.

Dentre os vários problemas pertencentes a esta classe, destacamos o problema de agrupamento ou de clusterização. Em linhas gerais, nesse problema deve-se agrupar os n objetos associados a uma base de dados em um número fixo de grupos. Estes grupos, por sua vez, são definidos mediante a avaliação de uma função objetivo e, eventualmente, considerando um conjunto de restrições.

Assim como em outros problemas da área de otimização combinatória, busca-se a implementação de métodos eficientes que produzam soluções viáveis de boa qualidade em tempo computacional factível. Neste caso, soluções de melhor qualidade são obtidas a expensas de métodos de computação mais intensivos, disponíveis na literatura.

Em suma, esses métodos encontram soluções viáveis que são boas o suficiente para serem consideradas úteis para a aplicação em questão. Dentre esses métodos, destacamos as heurísticas e as metaheurísticas.

Neste contexto, no presente trabalho de tese, foram estudadas e utilizadas as seguintes metaheurísticas: GRASP e VNS. Também foram utilizados os procedimentos de RC (Reconexão por Caminhos) e o método VND (Descida em Vizinhança Variável) para a construção de métodos híbridos que estão associados aos algoritmos que serão propostos.

Neste trabalho, esses métodos foram aplicados para a resolução de um problema de clusterização que agrega dois tipos de restrições adicionais, a saber: de capacidade e de conexidade (contiguidade). A restrição de capacidade está associada com um limite inferior L pré-estabelecido, com base em um atributo (característica) dos objetos. Assim, o somatório desse atributo nos objetos pertencentes a um mesmo cluster deve ser menor ou igual a L . E,

quanto à restrição de conectividade do cluster, devem ser observadas relações de vizinhança entre os objetos.

Mais especificamente, quaisquer dois objetos alocados a um mesmo cluster, devem ser vizinhos (fronteira) ou deve existir, pelo menos, um caminho entre dois objetos, passando apenas por objetos pertencentes ao mesmo cluster.

1.1 MOTIVAÇÃO E JUSTIFICATIVA

O problema de categorização de objetos é uma das mais antigas e comuns atividades humanas. Na teoria do desenvolvimento cognitivo de Piaget, o comportamento é controlado através de organizações mentais denominadas “esquemas”, que o indivíduo utiliza para representar o mundo, classificar os grupos e para designar as ações. Supondo que um arquivo de dados possa representar a mente humana, os esquemas são análogos aos registros desse arquivo, ou seja, são as estruturas mentais ou cognitivas pelas quais os indivíduos intelectualmente organizam o meio.

Sendo a ação de agrupar objetos uma atividade própria do ser humano, pode-se verificar claramente que, nos seus primeiros anos de vida, dispõe-se de poucos esquemas, os quais apresentam informações bastante generalizadas acerca do universo ao qual estamos inseridos [PIAGET 1996]. Quando uma criança tem novas experiências (vendo imagens novas ou ouvindo palavras novas), ela tenta adaptar esses novos estímulos às estruturas cognitivas que já possui. Esse processo ocorre através da assimilação, que é o processo cognitivo pelo qual uma pessoa integra (classifica) um novo dado às estruturas cognitivas prévias [WADSWORTH 1996].

Portanto, a assimilação permite que a criança adapte os novos estímulos aos esquemas que ela já possui até aquele momento. Por exemplo, imaginemos que uma criança está aprendendo a reconhecer animais e, até o momento, o único animal que ela conhece e tem organizado esquematicamente é o cachorro. O fato é que o esquema de cachorro é a única estrutura cognitiva conhecida pela criança. Então, quando apresentada a esta criança outro animal que possua alguma semelhança, como um cavalo, ela responderá como se fosse um cachorro (quadrúpede, rabo, pescoço, nariz). Assim, o processo de assimilação, ou seja, a similaridade entre o cavalo e o cachorro ocorre em função da proximidade dos estímulos e da pouca variedade e da qualidade dos esquemas acumulados pela criança até o momento.

A diferenciação do cavalo para o cachorro deverá ocorrer por um processo chamado de acomodação. Assim, gradativamente novos estímulos são assimilados e acomodados na mente humana.

Portanto, a capacidade de diferenciar objetos, e no sentido inverso, processar o agrupamento (ou clusterização) de objetos, é iniciada ainda nos primeiros anos de nossas vidas.

A Figura 1.1 apresenta um conjunto de 4 (quatro) objetos para o qual pode-se formar grupos a partir das similaridades existentes entre eles. É possível agrupá-los conforme os atributos e critérios desejados. Caso o critério utilizado seja o atributo forma, serão formados quatro grupos: um de retângulos, um de elipses, um de pentágonos e um de triângulos. Se o critério utilizado for o atributo numeração obtém-se três grupos: número 1, número 2 e número 3.

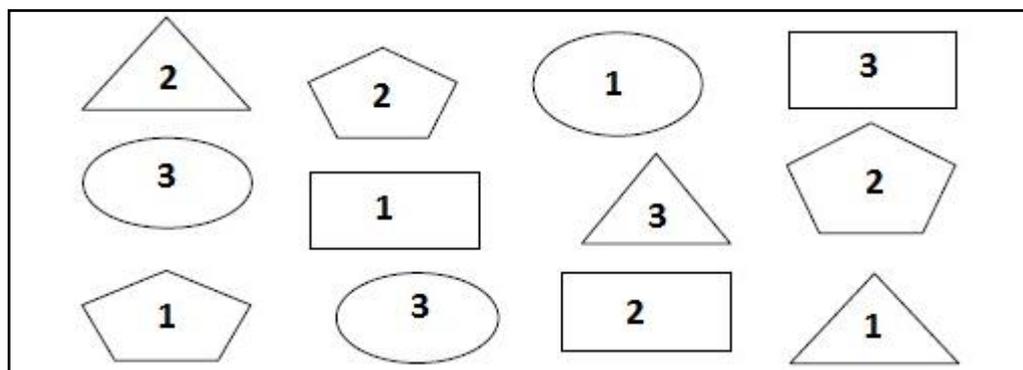


Figura 1.1 Conjunto de Objetos

Neste exemplo, a resolução do problema de clusterização é uma tarefa muito simples uma vez que temos um conjunto de 12 (doze) objetos com duas dimensões (forma e numeração).

Conforme mencionado na introdução, neste trabalho propõe-se resolver um particular problema de clusterização com restrições de capacidade e de conectividade utilizando uma modelagem baseada em grafos.

Há vários trabalhos na literatura [SEMAAN 2010][SEMAAN 2009][SEMAAN 2008][SHIEH AND MAY 2001] em que é salientado que a obtenção de um ótimo global para este problema torna-se impraticável à medida que o número de objetos a serem agrupados aumenta. Ou seja, caso seja aplicado algum método exato de enumeração implícita ou explícita para a resolução desse problema, seriam necessários meses ou anos para que fosse obtido o ótimo global.

Em decorrência desta última observação, a aplicação de métodos de agrupamento baseados em heurísticas e metaheurísticas é justificada e, acima de tudo, de fundamental importância para a resolução desse problema. Esses métodos tendem a produzir soluções viáveis de boa qualidade em um tempo computacional factível.

1.2 OBJETIVOS

A presente tese traz uma proposta de resolução para o problema de clusterização com restrições de capacidade e de conectividade. Mais especificamente, são propostos algoritmos que utilizam os conceitos das metaheurísticas GRASP e VNS e de heurísticas híbridas que incorporam os procedimentos de Reconexão por Caminhos (RC) e de Descida em Vizinhança Variável (VND).

Os resultados computacionais reportados neste trabalho foram obtidos a partir aplicação das metaheurísticas e das heurísticas em um conjunto de instâncias reais do Censo Demográfico de 2010 e da Contagem Populacional [CENSO DEMOGRAFICO 2010] (ambos dados de uso público).

Foram objetivos específicos deste trabalho:

- revisar a literatura em busca de trabalhos sobre o problema de clusterização e uma visão correlata com o problema de clusterização com restrições de capacidade e de conectividade;
- descrever os novos algoritmos que foram implementados a partir do estudo das metaheurísticas GRASP e VNS e do procedimento de Reconexão por Caminhos (RC) e do método de Descida em Vizinhança Variável (VND);
- programar os algoritmos heurísticos (GRASP e VNS) e híbridos com os módulos de (RC e VND) para resolver o problema de clusterização;
- avaliar e comparar (quanto à qualidade da solução e ao tempo de processamento) os algoritmos heurísticos com os algoritmos híbridos utilizando o conjunto de instâncias reais;

1.3 METODOLOGIA

Neste trabalho, faz-se uso das metaheurísticas como GRASP (*Greedy Randomized Adaptive Search Procedure*) [FEO AND RESENDE, 1995][PITSOULIS E RESENDE, 2002][RESENDE E RIBEIRO 2002] e VNS (*Variable Neighborhood Search*) [MLADENOVIC 1995],[GLOVER AND KOCHENBERGER 2002][MLADENOVIC AND HANSEN 1997].

E do módulo de PR (*Path-Relinking*) ou RC (Reconexão por Caminhos) [GLOVER, 1999], [GLOVER ET AL, 2000], [GLOVER ET AL 2004] e do método de VND (*Variable Neighborhood Descent*)[HANSEN; MIDADENOVIC, 2003][CHAVES E LORENA, 2005][HERNÁNDEZ-PÉREZ ET AL 2009] para desenvolver os algoritmos híbridos, visando resolver o problema de clusterização com restrições de capacidade e de conectividade.

Inicialmente, o presente trabalho traz uma descrição do problema de clusterização com suas peculiaridades, quais sejam: medidas de similaridade, critérios de agrupamento, classificação dos algoritmos de clusterização (não hierárquicos e hierárquicos). O problema de clusterização é formalizado com suas restrições de capacidade e de conectividade. Também foi efetuada uma revisão bibliográfica de problemas de clusterização, comparando as ideias e as metodologias propostas nestes trabalhos com as ideias formalizadas neste trabalho de tese.

Foram implementados algoritmos para a resolução problema de clusterização com restrições de capacidade e de conectividade que fizeram uso de metaheurísticas como GRASP e VNS. E para desenvolver as heurísticas híbridas foram feitas combinações das metaheurísticas citadas com o procedimento de Reconexão por Caminhos, com os métodos VND e RVND. Todas as implementações foram feitas na Linguagem C, utilizando o ambiente de desenvolvimento *NetBeans* 7.0.1 com dados reais (de uso público) coletados do Censo Demográfico de 2010 e da Contagem Populacional do IBGE [CENSO DEMOGRAFICO 2010]. De forma a comparar e avaliar os algoritmos propostos foram realizadas execuções sistemáticas e análises probabilísticas.

A parte final desta tese traz um conjunto de resultados computacionais que ratificam a eficácia dos algoritmos heurísticos e híbridos no que se refere à qualidade das soluções produzidas, e quanto à obtenção de soluções que atendessem as restrições de capacidade e conectividade do problema de clusterização.

1.4 CONTRIBUIÇÕES

O presente trabalho de tese tem como contribuição o desenvolvimento de métodos híbridos que combinam metaheurísticas e heurísticas de busca local para resolver o problema de clusterização com restrições de capacidade e conectividade. Assim, os primeiros algoritmos desenvolvidos foram baseados em métodos híbridos (GRASP com *Path-Relinking*, GRASP com Busca Local VND e GRASP com Busca Local RVND) e heurísticas de busca local (VNS, GVNS, RVNS e *Skewed VNS*), introduzindo inovações como novos procedimentos construtores para a solução do problema tratado nesta tese.

É fato conhecido que a combinação de uma metaheurística com outras técnicas de otimização, chamadas de metaheurísticas híbridas, pode proporcionar um comportamento mais eficiente e uma maior flexibilidade quando se trata de problemas do mundo real e em larga escala [BLUM AND ROLI, 2003]. Isto pode ser obtido, por exemplo, combinando uma metaheurística com heurísticas de busca específicas para um problema real, como no caso deste trabalho.

Geralmente, a utilização de diferentes métodos híbridos possibilita a produção de soluções de melhor qualidade quando comparadas às soluções provenientes de algoritmos baseados em apenas metaheurísticas. De fato, a escolha de uma abordagem híbrida adequada, muitas vezes utilizando algoritmos de busca mais especializados que consideram a natureza do problema e/ou informações sobre o espaço de busca, é determinante para alcançar um melhor desempenho computacional na resolução de problemas difíceis [RAIDL, 2006].

Consta também como resultado deste trabalho a realização de experimentos computacionais de modo a comparar o desempenho dos diversos algoritmos desenvolvidos, o que influencia na disponibilização de um algoritmo de solução competitivo para o problema tratado.

Finalmente, propõe-se como trabalhos futuro penalização das soluções; inserir nos algoritmos uma variável referente às eventuais penalidades existentes nos *clusters*; desenvolvimento de uma formulação de programação inteira para o problema de clusterização com restrições de capacidade e de conectividade e implementar uma formulação matemática para utilizar um bom *Upper Bound* gerado a partir de uma solução viável de boa qualidade produzida pela melhor resultado das metaheurísticas aplicadas ao problema de clusterização com restrições de capacidade e de conectividade.

1.5 ORGANIZAÇÃO

Este trabalho de tese está organizado de seguinte forma: O Capítulo 1 traz uma ideia geral do problema tratado nessa tese, considerando a descrição de seus objetivos, da metodologia e contribuições desta pesquisa científica. O Capítulo 2 traz uma descrição detalhada do problema de clusterização e as medidas utilizadas no cálculo da similaridade e possíveis critérios de agrupamento. Apresenta a classificação dos algoritmos de clusterização. Formaliza o problema de clusterização com restrições de capacidade e conectividade, finalizando com uma revisão bibliográfica de problemas de clusterização.

O Capítulo 3 apresenta os algoritmos propostos para a resolução do problema de clusterização com restrições de capacidade e de conectividade que foi o objeto de estudo desta tese. Em particular, tais algoritmos incorporam os conceitos das metaheurísticas como GRASP e VNS. E para construir as heurísticas híbridas foram feitas combinações das metaheurísticas citadas com o procedimento de reconexão por caminhos e também com os métodos VND e RVND.

O Capítulo 4 traz um conjunto de resultados computacionais e faz uma discussão dos algoritmos propostos e de suas versões híbridas, além de fazer uma análise de desempenho

dos algoritmos propostos avaliando-os e comparando-os mediante a utilização de instâncias reais. O Capítulo 5 traz as conclusões do trabalho e aponta algumas direções para os possíveis desdobramentos desta tese.

CAPÍTULO 2 – O PROBLEMA DE CLUSTERIZAÇÃO

Atualmente, muitos pesquisadores da área de computação têm concentrado a sua pesquisa no estudo e o desenvolvimento de várias técnicas de clusterização. Estes estudos têm trazido contribuições significativas para várias áreas, quais sejam: a estatística espacial [MONTEIRO 2009] [RODRIGUES 2001], mineração de dados [SMITH 2003] [TSAI ET. AL 2003], biologia [RECH AND ABSY 2011][BOLSHAKOVA AND AZUAJE 2003], medicina [NEUHAUS 1992][MANLY 2008], ciências ambientais [BROWN AND BOLKER, 2004] [GUO ET. AL 2003], processamento de imagens[DREW AND AU 2003] [FANG ET AL 2003], engenharia de produção industrial [WANG 2003] [TRINDADE E OCHI 2004], dentre outras.

A vantagem desta grande variedade de aplicações reais é que tem-se o envolvimento de muitos pesquisadores e estudiosos com as mais variadas formações e objetivos tratando do problema de clusterização. E como desvantagem destaca-se o uso de diferentes notações e formas de abordagem para as mesmas questões, o que tem dificultado o estabelecimento de metodologias genéricas e taxinomias em função do substancial número de trabalhos e notações concernentes a este tema.

De uma forma geral, os pesquisadores têm encontrado limitações computacionais no que se refere à automação dos processos de clusterização. Essas limitações, por sua vez, são decorrentes da dificuldade em produzir soluções de boa qualidade em um tempo computacional factível para diversas aplicações reais que podem ser mapeadas em um problema de agrupamento. Enfatiza-se que a complexidade computacional intrínseca ao problema de clusterização tem na representação dos dados seu maior desafio seja: pelo número de objetos a serem agrupados, pela mensuração de similaridade/dissimilaridade entre eles, e pelas variadas formas, densidades e tamanhos que os grupos podem apresentar.

2.1 DESCRIÇÃO DE CLUSTERIZAÇÃO

A clusterização corresponde ao processo de tomar um conjunto de n objetos de uma base de dados e agrupá-los em classes de objetos denominadas *clusters*. Portanto, um *cluster* é um conjunto de objetos similares entre si e, ao mesmo tempo, os elementos pertencentes subconjuntos diferentes apresentem alta dissimilaridade sendo a similaridade avaliada em função dos atributos associados aos objetos. [HAN AND KAMBER 2001].

Formalmente, o problema de clusterização pode ser definido da seguinte forma: Dado um conjunto X formado por n objetos $X = \{x_1, x_2, \dots, x_i, \dots, x_n\}$, com cada um dos objetos x_i

possuindo p atributos $x_i = (x_i^1, x_i^2, \dots, x_i^p)$ (características do objeto), deve-se construir k partições CL_i (*clusters*) a partir de X , respeitando às seguintes restrições [HAN AND KAMBER 2001] [HRUSCHKA 2001] [DIAS AND OCHI 2003]:

$$\begin{aligned} CL_i &\neq \emptyset \quad i = 1, \dots, k \\ CL_i \cap CL_j &= \emptyset \quad i, j = 1, \dots, k \text{ e } i \neq j \\ \bigcup_{i=1}^k CL_i &= X \end{aligned}$$

Quando o número de *clusters* é um dado de entrada para o algoritmo, ou seja, quando k é fixado previamente, o problema é conhecido na literatura como problema de k -clusterização ou simplesmente por Problema de Clusterização (PC) [FASULO 1999]. Neste caso, o número total de soluções viáveis pode ser obtido utilizando-se a fórmula apresentada na equação (1) associada ao número de *Stirling* de segundo tipo, a seguir [CHIOU AND LAN 2001]:

$$N(n, k) = \frac{1}{k!} \sum_{i=0}^k (-1)^i \binom{k}{i} (k-i)^n \quad (1)$$

E quando o número de clusters não é definido previamente, tem-se um problema de ainda mais difícil conhecido na literatura como Problema de Clusterização Automática (PCA) [DOVAL ET. AL, 1999]. Neste caso, o total de soluções viáveis é dado pela seguinte equação:

$$N(n, k) = \sum_{k=1}^n \frac{1}{k!} \sum_{i=0}^k (-1)^i \binom{k}{i} (k-i)^n \quad (2)$$

A literatura [WELCH 1983] mostra que estes dois problemas (PC e PCA) de otimização são classificados como NP-Completo.

Então, mediante a descrição do problema de clusterização, é possível concluir que uma boa clusterização é aquela que minimiza a dissimilaridade entre objetos pertencentes a um mesmo cluster (*intra-cluster*) e maximiza a dissimilaridade entre objetos pertencentes a clusters diferentes (*inter-cluster*).

A obtenção de uma boa clusterização depende, ainda, da observação de características importantes por parte dos algoritmos de clusterização, segundo [HAN AND KRAMBER 2001][AGRAWAL ET. AL 1998], quais sejam:

- Escalabilidade: Para a maioria das aplicações reais, exige-se que o algoritmo seja capaz de apresentar boas soluções que independem do tamanho da entrada (número de objetos). Algumas estratégias costumam a ser usadas para diminuir a sensibilidade do algoritmo ao tamanho do conjunto. Portanto, esses algoritmos

podem trabalhar com qualquer massa de dados ou dimensões. Então, possuir uma alta escalabilidade é uma propriedade desejável em um algoritmo de clusterização;

- Seleção de Variáveis: A escolha das variáveis que serão avaliadas para o processo de clusterização implica somente considerá-las ou não. Muitas vezes, a própria aplicação direciona a escolha das variáveis relevantes ao problema;
- Tipos de Variáveis: As variáveis podem ser do tipo quantitativo (discretas ou contínuas) ou do tipo qualitativo (nominais ou ordinais) ou mistas;
- Habilidade para tratar ruídos: Dados com ruídos são comuns em várias aplicações reais. Seja por erros de digitação, ou por uma falha na coleta dos dados, é sempre possível termos em uma base de dados registros cujas informações foram corrompidas, ou seja, consideradas fora do padrão utilizado. Portanto, o desenvolvimento de um algoritmo que seja capaz de tratar os ruídos é um pré-requisito importante.
- Habilidade para processar dados com dimensões elevadas: alguns algoritmos são muito eficientes quando lidam com objetos com duas ou três dimensões (atributos). Não obstante, para bases de dados cujos objetos têm um número elevado de dimensões, a qualidade das soluções apresentadas cai consideravelmente. É importante então, que o número de dimensões da base de dados não interfira negativamente no desempenho do algoritmo.
- Identificação de *clusters* com formas arbitrárias: É desejável que um algoritmo de clusterização seja hábil a encontrar *cluster* de formatos variados como, por exemplo: esféricos, hiper-esféricos, curvilíneos, alongados, já que em muitas aplicações nenhum conhecimento *a priori* sobre a distribuição dos objetos pode ser obtido;
- Existência de restrições: Existem aplicações reais em que será necessário definir os grupos (*clusters*) de forma a satisfazer algumas restrições;
- Mínimo de conhecimento na entrada dos parâmetros: em alguns algoritmos, os resultados são bastante sensíveis aos parâmetros de entradas, tais como as configurações do algoritmo e (os) arquivos de dados. Com frequência, estes parâmetros são difíceis de determinar, especialmente quando se lida com grande volume de dados e com alta dimensionalidade, isto é, com muitos atributos.

- Interpretação dos resultados: Deve ser de fácil interpretação, ou seja, os resultados devem ser simples e de fácil entendimento e úteis para o objetivo ao que ele se propõe.

2.2 MEDIDAS DE SIMILARIDADE

O problema de clusterização requer a definição de uma função objetivo que expresse o grau de homogeneidade dos agrupamentos formados. Esta homogeneidade está diretamente relacionada com a utilização de uma medida de similaridade que permite avaliar se dois objetos são similares entre si no que concerne a um conjunto de atributos. Dessa forma, espera-se que os objetos alocados a um mesmo cluster sejam similares (para estes atributos) e os objetos pertencentes a clusters distintos tenham baixa similaridade. Sendo assim, uma boa clusterização estabelece medidas de qualidade de clusterização, sendo essas medidas correspondentes às distâncias entre dois objetos.

Para se avaliar a semelhança entre dois objetos, verifica-se que, quanto menor for a dissimilaridade entre os mesmos, menor a distância entre eles. Assim, pode-se utilizar uma matriz $D_{n \times n}$ onde são armazenadas as distâncias entre todos os objetos tomados dois a dois, sendo tal matriz construída a partir de uma matriz X . Cada entrada d_{ij} de D (calculada a partir de X) representa a medida de dissimilaridade entre os objetos i e j .

Na maioria dos problemas de clusterização, cada um dos n objetos é descrito por um conjunto de p atributos ou variáveis. Desta forma, o conjunto de dados também pode ser representado por uma matriz $n \times p$:

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \ddots & & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix}$$

onde x_{il} é o valor do atributo l para o objeto i .

Esta matriz aqui denominada de matriz de Medida de Dissimilaridade (D), pode ser referenciada como matriz de Dissimilaridade ou ainda de Proximidade [GORDON, 1981]. Se X é o conjunto de objetos que serão agrupados, a medida de dissimilaridade é tal que:

- (i) $d_{ij} \geq 0$ para todo x_i e x_j pertencente a X ;
- (ii) $d_{ij} = 0$ para todo x_i e x_j pertencente a X tal que $x_i = x_j$;
- (iii) $d_{ij} = d_{ji}$ para todo x_i e x_j pertencente a X ;

(iv) $d_{ij} \leq d_{ih} + d_{hj}$ para todo x_i, x_j e x_h pertencentes a X ;

As propriedades (ii) e (iii) implicam que a *Matriz de Dissimilaridade* pode ser especificada por uma matriz diagonal inferior contendo $n(n-1)/2$ entradas:

$$D = \begin{vmatrix} \dots & \dots & \dots & \dots \\ d_{21} & \dots & \dots & \dots \\ d_{31} & d_{32} & \dots & \dots \\ \vdots & \vdots & \ddots & \dots \\ d_{n1} & d_{n2} & \dots & d_{n,n-1} \end{vmatrix}$$

Dentre as medidas de distância utilizadas, podemos destacar: a distância Euclidiana, de *Manhattan* e a de *Minkowski* [HAN AND KRAMBER, 2001][DIAS 2004].

A matriz de Dissimilaridade (D) pode ser obtida a partir da utilização das expressões matemáticas que denotam as medidas de dissimilaridade que serão apresentadas a seguir. A medida mais comum é a Distância Euclidiana, dada pela seguinte forma:

$$D_{Euclidiana}(x_i, x_j) = \left[\sum_{l=1}^p (x_{il} - x_{jl})^2 \right]^{1/2} \quad (3)$$

onde x_{il} é o valor do atributo l para o objeto i e x_{jl} é o valor do atributo l para o objeto j .

Na Distância Euclidiana cada um dos l atributos ($l=1, \dots, p$) pode ser ponderado por um peso específico w_l relativo a sua importância. Dessa forma, a fórmula fica descrita como a Equação 4 a seguir:

$$D_{EuclidianaPonderada}(x_i, x_j) = \left[\sum_{l=1}^p w_l (x_{il} - x_{jl})^2 \right]^{1/2} \quad (4)$$

Outra medida utilizada é Distância de *Manhattan* (*city block*), dada por:

$$D_{Manhattan}(x_i, x_j) = \sum_{l=1}^p |x_{il} - x_{jl}| \quad (5)$$

As três medidas apresentadas anteriormente, são aplicáveis às variáveis do tipo quantitativo. As diferenças entre essas duas distâncias são representadas pela Figura 2.1 (considera-se que seja utilizado um espaço bidimensional). Cada objeto é representado por um ponto no plano, sendo considerada a existência de dois atributos do tipo quantitativo. A

Distância Euclidiana fornece uma medida mais precisa da distância entre os pontos, enquanto que a Distância de *Manhattan* apresenta uma expressão mais simples que pode representar, em alguns casos, alguma vantagem computacional [NEVES 2003].

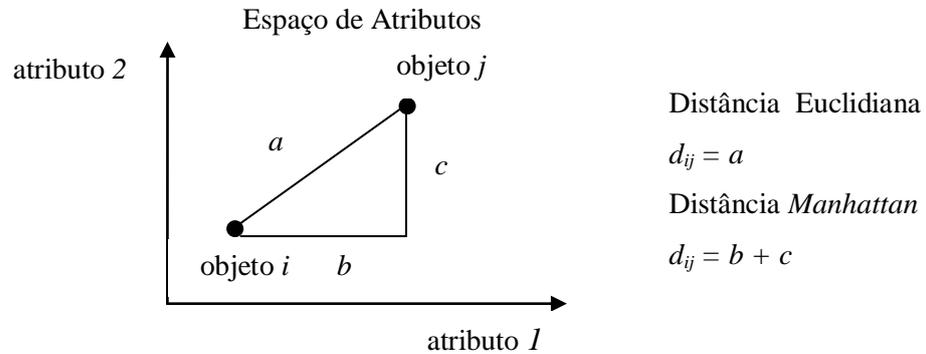


Figura 2.1 Representação da Distância Euclidiana e *Manhattan*

Essas duas medidas de similaridade, Distância Euclidiana e *Manhattan*, podem ser entendidas como sendo casos especiais de uma medida geral, chamada de Distância de *Minkowski*, que é expressa pela equação a seguir:

$$D_{Minkowski}(x_i, x_j) = \left[\sum_{l=1}^p |x_{il} - x_{jl}|^q \right]^{1/q} \quad (6)$$

Neste trabalho optou-se pela distância euclidiana, uma vez que todas as instâncias consideradas têm objetos com todos os atributos quantitativos. Com o objetivo de representar os cálculos das Distâncias Euclidiana (concordância) da Tabela 2.1, apresenta-se um exemplo de instâncias e sua ilustração através na Figura 2.2:

Tabela 2.1: Exemplo de Instância

Objeto	Atributo 1	Atributo 2
A	1	1
B	1	3
C	3	3
D	5	3
E	6	4
F	7	1

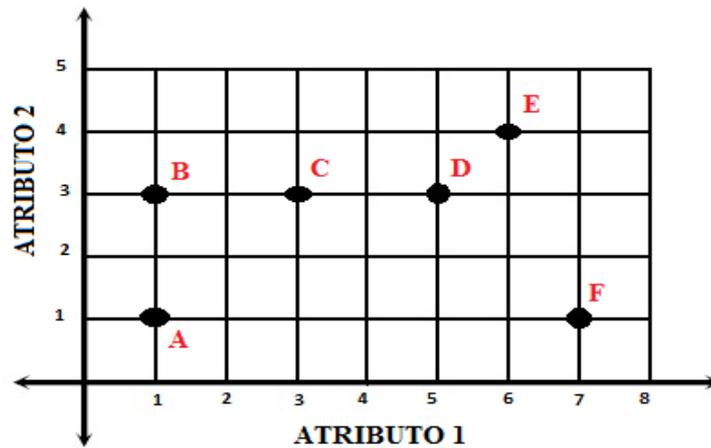


Figura 2.2 Representação Gráfica da Tabela 2.1

A partir da Figura 2.2, a distância Euclidiana ($DEuclidiana(x_i, x_j)$) pode ser definida da seguinte maneira: Sejam $A = (x_1, y_1) \Rightarrow A = (1, 1)$ e $B = (x_2, y_2) \Rightarrow B = (1, 3)$. Então, a $DEuclidiana(A, B) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \Rightarrow \sqrt{(1 - 1)^2 + (3 - 1)^2} = \sqrt{(0)^2 + (2)^2} = DEuclidiana(A, B) = \sqrt{4} = 2$. As matrizes a seguir trazem a Distância Euclidiana entre todos os pontos da Figura 2.2 e seus respectivos valores.

$$DEuclidiana(x_i, x_j) = \begin{pmatrix} d_{AA} & d_{AB} & d_{AC} & d_{AD} & d_{AE} & d_{AF} \\ d_{BA} & d_{BB} & d_{BC} & d_{BD} & d_{BE} & d_{BF} \\ d_{CA} & d_{CB} & d_{CC} & d_{CD} & d_{CE} & d_{CF} \\ d_{DA} & d_{DB} & d_{DC} & d_{DD} & d_{DE} & d_{DF} \\ d_{EA} & d_{EB} & d_{EC} & d_{ED} & d_{EE} & d_{EF} \\ d_{FA} & d_{FB} & d_{FC} & d_{FD} & d_{FE} & d_{FF} \end{pmatrix}$$

$$DEuclidiana(x_i, x_j) = \begin{pmatrix} 0,0 & 2,0 & 2,8 & 4,4 & 5,8 & 6,0 \\ 2,0 & 0,0 & 2,0 & 4,0 & 5,0 & 6,3 \\ 2,8 & 2,0 & 0,0 & 2,0 & 3,1 & 4,4 \\ 4,4 & 4,0 & 2,0 & 0,0 & 1,4 & 2,8 \\ 5,8 & 5,0 & 3,1 & 1,4 & 0,0 & 3,1 \\ 6,0 & 6,3 & 4,4 & 2,8 & 3,1 & 0,0 \end{pmatrix}$$

2.3 FUNÇÕES OBJETIVO

Existem várias funções objetivo que podem ser utilizadas nos problemas de clusterização, de forma a avaliar a homogeneidade dos grupos formados. No presente trabalho foi adotada a seguinte função objetivo:

$$f(P) = \sum_{c=1}^k Som_c \quad (7)$$

Sendo P uma partição dos n objetos em k clusters e Som_c correspondente à soma quadrados dos desvios dos clusters. Assim, uma partição é uma possível solução para o problema de agrupamento, é na verdade uma divisão de objetos em conjuntos não sobrepostos (clusters).

A Equação 7 representa a medida da dispersão dos valores dos atributos dos objetos de um cluster em relação aos valores médios de todos os atributos para um cluster. Se os clusters forem similares, os valores de Som_c serão pequenos. Dessa forma, quanto menor o valor da equação (7), mais homogêneos serão os clusters.

$$Som_c = \sum_{l=1}^p \sum_{i=1}^{n_c} (x_{il} - \bar{x}_l)^2 \quad (8)$$

e

$$\bar{x}_l = \frac{1}{n_c} \sum_{i=1}^{n_c} x_{il}, \text{ para } l = 1, \dots, p \quad (9)$$

sendo:

- n_c o número de objetos membros do cluster c ;
- x_{il} o atributo l do objeto i ;
- p o número de atributos considerados na análise;
- \bar{x}_l o valor médio do atributo l , para um cluster.

2.4 CLASSIFICAÇÃO DOS ALGORITMOS DE CLUSTERIZAÇÃO

A classificação dos algoritmos de agrupamento tanto para o Problema de Clusterização quanto para o Problema de Clusterização Automática é feita de um modo geral sem distinção entre o primeiro ou o segundo tipo de problemas. Segundo [GARAI E CHAUDHURI 2004] os algoritmos de agrupamento podem ser classificados como:

- Hierárquicos: Aglomerativos e Divisivos;
- Não-hierárquico: Particionamento.

Pode-se, ainda, citar outros algoritmos como os baseados em: densidade, em grades, em co-ocorrência de dados de tipo categóricos, em modelos, em restrições, além de métodos híbridos de clusterização [BERKHIN 2002] [HAN E KAMBER 2001][FISHER 1987].

Em particular, no presente trabalho, adotar-se-á a classificação apresentada no trabalho de [SOARES 2004]. Os algoritmos de clusterização são classificados conforme a Figura 2.2:

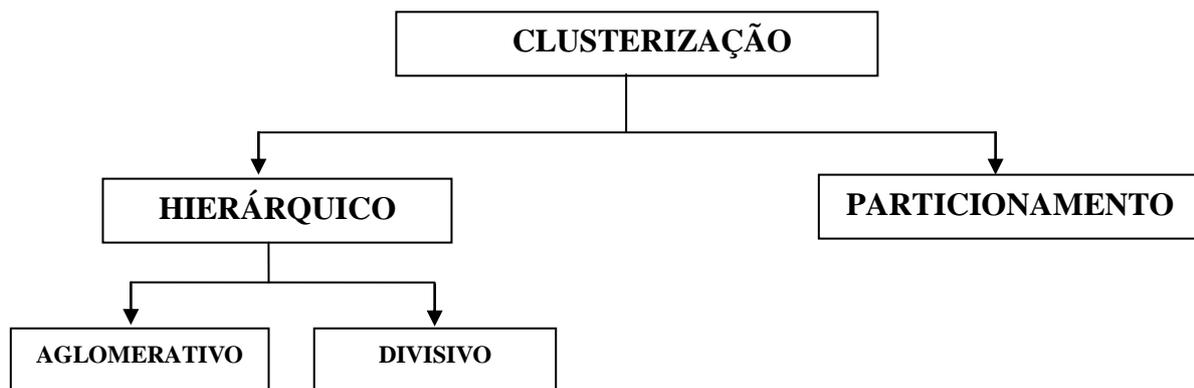


Figura 2.3 Classificação dos algoritmos de clusterização [SOARES 2004]

Os algoritmos Hierárquicos operam sobre um conjunto X formado por n objetos e procuram construir uma árvore de *clusters* denominada dendrograma. Nessa árvore, cada nó corresponde a um *cluster* que pode ter outros *clusters* filhos, pais ou irmãos de forma que, cada objeto de n é associado a um único nó da árvore em um dos seus níveis. Isso permite que os dados sejam manuseados com um nível de granularidade razoavelmente melhor, se a quantidade de objetos tratados for pequena, que os oferecidos por algoritmos de particionamento cuja descrição será apresentada mais à frente.

A literatura apresenta, ainda, uma divisão dos métodos hierárquicos de clusterização em Hierárquico Aglomerativo e Hierárquico Divisivo de acordo com a forma como o dendrograma é construído.

Se a árvore é construída das folhas para a raiz (estratégia *bottom-up*) o algoritmo inicia o processo de clusterização criando n *clusters*, cada um contendo um dos n pontos do conjunto X . Nesse caso, tem-se o método Hierárquico Aglomerativo. Iterativamente, dois ou mais *clusters* sofrem uma junção para formar um novo *cluster*. Essa junção depende do critério de similaridade que é adotado.

Em um algoritmo dito Hierárquico Divisivo, a árvore é construída da raiz para as folhas (estratégia *top-down*). Ou seja, inicialmente existe um único *cluster* contendo todos os n pontos do conjunto S , que será dividido a cada nível em dois (ou mais) *clusters* para criar

um novo nível na árvore. A cada nível que vai sendo criado na árvore, os *clusters* são novamente divididos para gerar outros *clusters* de nível inferior.

Comparando os algoritmos de clusterização hierárquico por aglomeração com os de clusterização hierárquico por divisão constata-se que o método divisivo exige um maior número de iterações para ser executado e que dependendo do número de elementos do problema tratado, torna-se inviável sua implementação computacional. Por isso, os algoritmos de clusterização hierárquico por divisão são pouco mencionados na literatura, pois exigem uma maior capacidade computacional que os métodos aglomerativos [KAUFMAN, 1990].

Percebe-se que a Clusterização hierárquica pode ser vista como um problema de particionamento em grafos. Neste sentido, são apresentados trabalhos de excelente nível técnico sobre a utilização de particionamento em grafos para este problema, destacando-se, dentre eles, os trabalhos de [DIAS E OCHI, 2003][SCHRADER 1983].

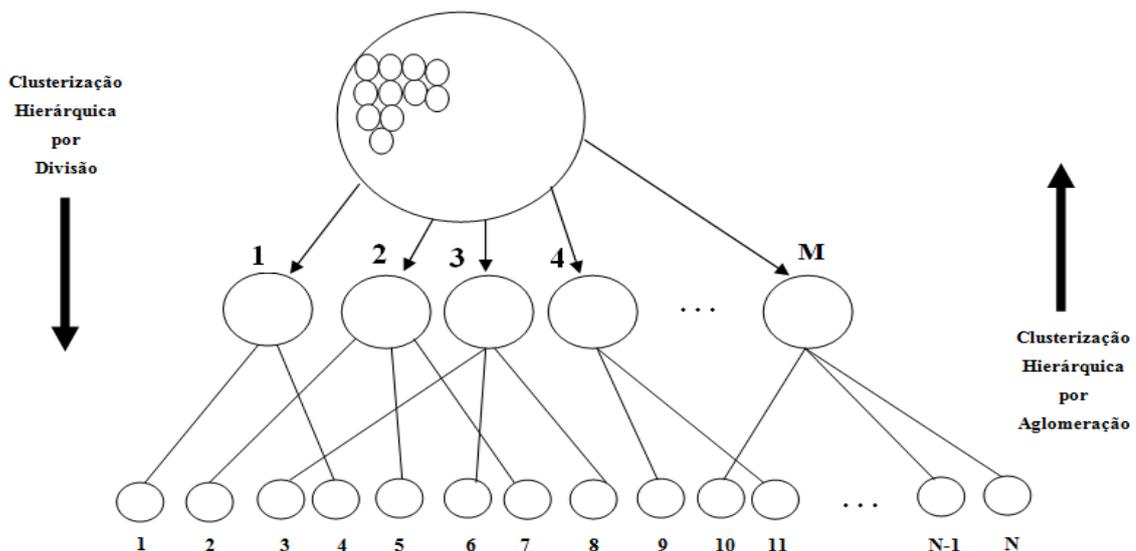


Figura 2.4 Classificação dos algoritmos de clusterização adaptado de SOARES 2004

Diferentemente dos algoritmos hierárquicos, nos algoritmos de particionamento o número de grupos é especificado antes do processo de agrupamento, que se inicia com a divisão dos objetos em k grupos. Estes algoritmos melhoram gradualmente os *clusters*. Ou seja, procuram iterativamente agrupar e fazer realocações dos pontos de X em k *clusters* de forma a otimizar uma função objetivo f . A otimização da função f procura assegurar que os pontos pertencentes a um mesmo *cluster* apresentem alta similaridade e os pontos pertencentes a *clusters* distintos tenham baixa similaridade [HAN E KAMBER 2001]. Um algoritmo de particionamento classifica os n pontos do conjunto de entrada em k grupos de tal

forma que cada grupo contenha, no mínimo, um ponto e que cada ponto pertença a exatamente um grupo. Portanto, o algoritmo de particionamento consiste em agrupar k grupos de objetos entre os objetos, ou seja, encontrar grupos “naturais” de objetos para um conjunto de dados não rotulados (tipo de aprendizado não supervisionado). Entretanto, nem todo valor de k produz a solução ideal, ou seja, aquela clusterização que reflete fielmente os grupos presentes no conjunto de entrada. [SOARES 2004].

Dentre os algoritmos de particionamento, o mais popular é o algoritmo *K-means*, [JAIN 2010][MACQUEEN 1967][STEINLEY AND BRUSCO 2007]. Proposto em 1967, o algoritmo *K-means* representa cada *cluster* pelo centroide do mesmo. O centroide C_m de um *cluster* C é o ponto $C_m = (C_{m1}, C_{m2}, \dots, C_{mp})$ onde cada coordenada C_{mj} ($j=1, \dots, p$) é dada pela média da j -ésima característica dos t objetos que pertencem ao *cluster* C_m , como dado pela Equação 10:

$$C_{mj} = \frac{\sum_i^t x_{ij}}{t} \quad (10)$$

No algoritmo *K-means*, a função objetivo a ser minimizada f leva em consideração a média das distâncias entre cada ponto e o centroide do *cluster* ao qual este pertence. Uma possibilidade para a inicializar o algoritmo consiste em escolher aleatoriamente dentre os n pontos para representar o centroide de cada um dos k *clusters*. Cada ponto do conjunto X é associado ao *cluster* cujo centroide seja mais similar, sendo que, cada vez que um ponto é realocado a um *cluster*, o centroide daquele *cluster* é atualizado [SPATH 1980]. Esse processo pode repetir as etapas de associar cada ponto do conjunto X ao centro do *cluster* mais próximo/similar e recalcular/atualizar o centro de cada *cluster* até que nenhum ponto possa ser mudado. Este processo é reiniciado considerando os novos centroides escolhidos até que um critério de parada seja atendido, como um número i de iterações sem melhoria na função objetivo.

Uma vez que o algoritmo *k-means* considera os centroides, este método não pode ser aplicado em bases de dados cujos objetos tenham atributos qualitativos. Em geral, o algoritmo *k-means* tradicional tende a produzir ótimos locais de qualidade apenas razoável. Em função disso, são encontradas na literatura algumas propostas de algoritmos (variantes de *k-means*) que trabalham a mesma função objetivo de *k-means*, mas que consideram métodos de busca mais eficientes, sejam eles: o global, *k-means* [MACQUEEN, 1967] [PENA ET AL, 1999], o *j-means* [HANSEN AND MLADENOVIC 2001] e o algoritmo de suavização

hiperbólica [XAVIER 2009]. Estes algoritmos tendem a produzir soluções de qualidade superior àquelas produzidas pelo *k-means*.

2.5 O PROBLEMA DE CLUSTERIZAÇÃO COM RESTRIÇÕES DE CAPACIDADE E CONEXIDADE (PC-RCC)

O Problema de Clusterização também pode ser mapeado em um problema de particionamento de grafos em subgrafos disjuntos, estando cada subgrafo associado a um *cluster* [DOVAL ET. AL, 1999] [DIAS 2004][DIAS AND OCHI 2003][BOLEY ET AL 1999]. Alguns problemas de clusterização têm restrições de capacidade mínima por *cluster* [SHIEH AND MAY 2001][SCHEUERER 2006] e outros agregam a restrição de conexidade [ASSUNÇÃO ET AL, 2006] [NEVES 2003], dentre outras restrições.

Em particular, o presente trabalho traz uma proposta de resolução para o problema de clusterização que agrega tanto a restrição de capacidade, quanto a restrição de conexidade [SEMAAN 2010][SEMAAN 2009][SEMAAN 2008][SHIEH AND MAY 2001]. Soma-se a estes trabalhos o trabalho de BRITO, ET AL 2004 que traz uma proposta de resolução para este problema considerando a aplicação de uma formulação de programação inteira.

A seguir é realizada a descrição do problema de clusterização com as restrições de capacidade e de conexidade onde tem-se a definição das áreas de ponderação (APONDS).

2.5.1 DESCRIÇÃO DO PROBLEMA (PC-RCC)

O problema de clusterização de uma forma geral, ocorre por exemplo, em situações nas quais a regionalização geográfica torna-se necessária, isto é, nos casos dos censos demográficos e de pesquisa socioeconômicas [OPENSHAW 1977].

O problema de Clusterização com Restrição de Capacidade e Conexidade (PC-RCC) pode ser descrito por um grafo $G=(V,A)$. Um grafo não direcionado G consiste de um conjunto $V=\{v_1,\dots,v_i,\dots,v_j,\dots,v_n\}$ de elementos, chamados de vértices, e de uma relação binária A entre eles, denominada aresta. Cada elemento de A corresponde, portanto, a um par de vértices $[v_i,v_j]$ pertencentes ao conjunto V . Por definição, $|V|$ e $|A|$ correspondem, respectivamente, ao número de vértices e ao número de arestas de G . Por exemplo (Figura 2.6): uma rede social pode ser representada através de grafo, onde os vértices representam o nome dos perfis e as arestas representam as ações dos perfis sejam elas, compartilhamentos ou comentários de mensagens. A

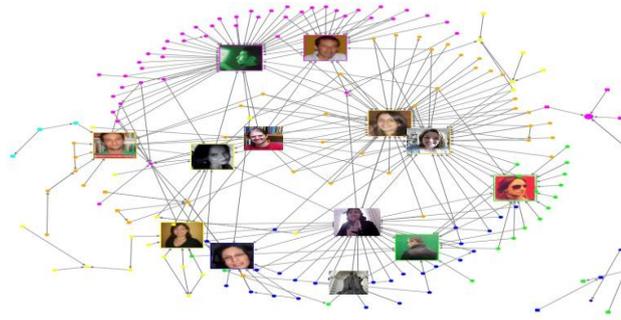


Figura 2.5 Grafo de uma Rede Social [GOOGLE IMAGENS 2014]

Considerando o PC-RCC determinado nesta tese, cada vértice estabelece a relação de vizinhança entre duas arestas é expressa através de uma aresta $[v_i, v_j] \in A$ e associa-se cada vértice v_i o valor correspondente a uma capacidade mínima estabelecida no problema tratado.

O objetivo do PC-RCC é minimizar a função objetivo correspondente à Equação 7 ($f(P) = \sum_{c=1}^k Som_c$) que consiste em definir o menor número possível de homogeneidade entre agrupamentos similares. Desta forma, o problema tratado nesta tese, define duas restrições a saber: - Restrição 1 – Conexidade: a restrição de conexidade implica, que cada agrupamento formado, devem existir vizinhos, com pelo menos, um caminho simples, onde dois vértices tomados dois a dois, devem possuir contiguidade; - Restrição 2 – Capacidade Mínima: a restrição de capacidade mínima determina que cada vértices de um grafo possui um valor referente alguma informação de cunho quantitativo.

Dessa forma, o trabalho busca tratar as restrições 1 e 2, simultaneamente. Vejamos uma exemplificação a seguir: inicialmente tem-se um único aglomerado de setores censitários Figura 2.6(a) e a Figura 2.6(b) onde define-se a formação de aglomerados conexos e com capacidade mínima de 200 domicílios por setor, por exemplo, assim tem-se a formação de 07 aglomerados cada um por uma cor diferente.

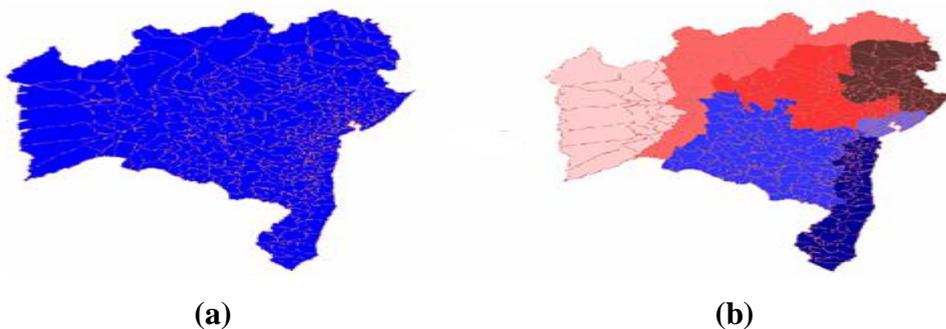


Figura 2.6 Clusterização com Restrição de Conexidade e Capacidade Mínima
 – (a) Um único aglomerado de Setores Censitários (b) Aglomerados Conexos e Com Capacidade Mínima [NEVES 2003]

O problema de Clusterização com Restrição de Capacidade e Conexidade (PC-RCC) possui uma formulação matemática definida em Brito et. al, 2004. Nessa formulação são consideradas as seguintes notações e restrições:

V = Quantidade de vértices

K = Quantidade de *clusters*

P_j = População associada a cada vértice j

E^* = Arestas da Árvore Gerador Mínima

X_i = Variável Inteira que determina a quantidade de vértices que estão no i -ésimo *cluster*

Y_{ij} = Variável Binária que assume valor 1 se o j -ésimo vértice está associado ao i -ésimo *cluster*

e_{mn}^i = Variável Binária: assume valor 1 se a aresta $(m,n) \in E^*$ está ativa no i -ésimo *cluster*

t_{mn}^i = Variável Binária: assume valor 1 se a aresta $(m,n) \in E^*$ está ativa no i -ésimo *cluster*

D_m = Medida que representa o grau de homogeneidade entre dois *clusters* vizinhos.

Função Objetivo está associada ao critério de soma mínima. Ou seja, o valor desta função representa a soma do melhor subconjunto de arestas ativas associadas aos valores D_m .

Restrições 1 e 2: A quantidade de vértices associados a cada um dos *clusters* deve ser igual ao total de vértices da instância.

Restrições 3: Garante que um vértice estará associado a exatamente um *cluster*.

Restrição 4: A soma do atributo referente à capacidade mínima associada a cada um dos vértices, em cada um dos *clusters*, deve ser maior ou igual a capacidade mínima pré-estabelecida.

Restrição 5: Garante que cada uma das arestas associadas à árvore geradora que contém todos os vértices só poderá estar em no máximo um *cluster*. Ou seja, se dois vértices são vizinhos e estão em um mesmo *cluster*, então $e_{mn}^i = 1$.

Restrição 6: A quantidade de arestas associadas a cada um dos *clusters* deve ser igual a quantidade de vértices em cada um dos *clusters* menos um.

Restrições 7 a 10: Estas restrições garantem que se uma aresta do conjunto E^* estiver vazia, ou seja, pertencer a uma subárvore associada a um *cluster*, então os vértices m e n desta aresta também farão parte do *cluster*.

$$\text{Minimizar } \sum_{i=1}^k \sum_{\forall (m,n) \in E^*} e_{mn}^i \cdot D_m$$

- (1) $\sum_{i=1}^k X_i = V$
 - (2) $\sum_{j=1}^V Y_{ij} = X_i, \quad i=1, \dots, k$
 - (3) $\sum_{j=1}^k Y_{ij} = 1, \quad j=1, \dots, V$
 - (4) $\sum_{j=1}^V Y_{ij} \cdot P_j, \quad i=1, \dots, k$
 - (5) $\sum_{i=1}^k e_{mn}^i \leq 1, \forall (m, n) \in E^*$
 - (6) $\sum_{\forall (m, n) \in E^*} e_{mn}^i = X_i - 1, i=1, \dots, k$
 - (7) $t_{mn}^i \leq Y_{im} \quad i=1, \dots, k \quad \forall (m, n) \in E^*$
 - (8) $t_{mn}^i \leq Y_{in} \quad i=1, \dots, k \quad \forall (m, n) \in E^*$
 - (9) $Y_{im} + Y_{in} - 1 \leq t_{mn}^i \quad \forall (m, n) \in E^*$
 - (10) $e_{mn}^i \leq t_{mn}^i \quad i=1, \dots, k \quad \forall (m, n) \in E^*$
- $$X_i \in Z_+, \quad Y_{ij} \in (0,1), \quad t_{mn}^i \in (0,1)$$

Na próxima Seção será tratada a modelagem do problema.

2.5.2 MODELAGEM DO PROBLEMA (PC-RCC)

A partir da descrição do problema feita na seção anterior, observa-se que o problema Clusterização com Restrição de Capacidade e Conexidade (PC-RCC), no contexto do censo geográfico, como no caso desta tese, os objetos podem estar associados a domicílios, a setores censitários, às áreas de ponderação (APONDS) e a municípios.

Uma APOND é definida como uma unidade geográfica formada por agrupamentos mutuamente exclusivos de setores censitários, sendo esses, por sua vez, formados por conjuntos de domicílios. Esta unidade é utilizada para se estimar informações para a população e, também, os níveis geográficos mais detalhados da base operacional, sendo tais áreas definidas como forma de atender às demandas por informações em níveis geográficos menores que os municípios.

Em geral, uma APOND é formada por um grupo de setores censitários que têm, em média, 300 domicílios [CENSO DEMOGRÁFICO 2010]. O tamanho dessas áreas, em termos do número de domicílios e de população, não pode ser muito reduzido, sob a pena de perda de precisão de suas estimativas. As áreas de ponderação foram definidas considerando essa condição e, também, os níveis geográficos mais detalhados da base operacional, como forma de atender a demandas por informações em níveis geográficos menores que os municípios [SILVA 2004] [CENSO DEMOGRÁFICO 2010].

Cada APOND [BRITO e MONTENEGRO 2010] é definida de forma a satisfazer os

seguintes critérios:

Um número mínimo de domicílios por APOND (para permitir a obtenção de estimativas com qualidade estatística em áreas pequenas);

- A contiguidade: os setores que constituem cada uma destas áreas devem possuir fronteira em comum ou deve ser possível sair de um setor A e chegar a um setor B, ambos em uma mesma área, passando apenas por setores que também estejam nesta mesma área;

- Os setores que compõem estas áreas devem ser homogêneos em relação a um conjunto de características (variáveis) populacionais e de infraestrutura. Ou seja, considerando que duas APONDS i e j são vizinhas são calculadas as distâncias d_{ij} obtido através da aplicação da Equação abaixo:

$$DEuclidiana(x_i, x_j) = [\sum_{l=1}^p (x_{il} - x_{jl})]^2]^{1/2}$$

Estas distâncias fornecem o grau de homogeneidade entre os setores censitários a serem agregados. (x_i, x_j)

Assim, observa-se que o problema de definição de áreas de ponderação corresponde a um problema de agrupamento com uma restrição de capacidade (número mínimo de domicílios) e de conexidade (contiguidade entre os setores). Desta forma, é necessário associar tanto as informações relativas à contiguidade (conexidade) das APONDS, quanto as informações da capacidade dos vértices a uma modelagem matemática que fosse útil para caracterizar esse problema de agrupamento e suas restrições.

Para fins de exemplificação, considere o mapa abaixo (Figura 2.7(a)) com cinco setores censitários e o seus grafos associados na Figura 2.7(b), Grafo Completo, e Figura 2.7(c), o Grafo Original.

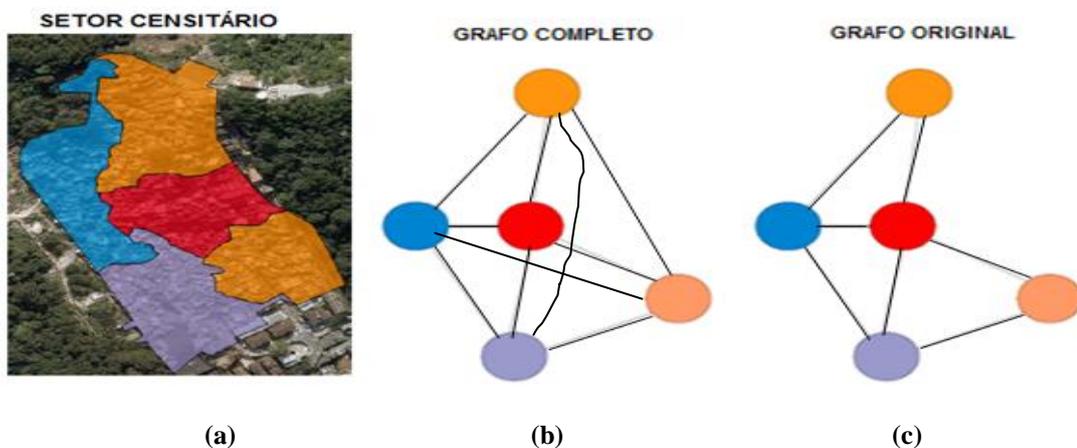


Figura 2.7 - Representação Setores Censitários (a), Grafo Completo (b) e Grafo Original (c) [BRITO ET AL, 2010]

O Grafo Completo, Figura 2.7 (b) representa a existência de contiguidade entre dois setores i e j é, portanto, representada em G através de cada aresta A ligando os vértices v_i e v_j . Além disso, o Grafo Completo apresenta cinco vértices acima, onde serão calculadas todas as distâncias (homogeneidade) d_{ij} (distância euclidiana) entre cada dois vértices. A partir do Grafo Completo é obtido um subgrafo que contém subconjunto de arestas de A , ou seja, contém as arestas A' que indicam a relação de vizinhança entre os vértices, portanto representam a relação de contiguidade entre os setores, denominado neste trabalho como Grafo Original e correspondente ao grafo $G=(V, A')$. Assim, através do Grafo Original G , pode-se definir k áreas de ponderação mediante a remoção de um subconjunto de A' de G , de modo que se tenha n grafos conexos (contiguidade).

A restrição de conexidade implica que, em cada APOND, todos os setores tomados dois a dois, devem ser vizinhos ou deve existir, pelo menos, um caminho passando apenas pelos vértices pertencentes a mesma APOND. Este trabalho, em seu estudo de caso, utiliza instâncias obtidas a partir dos dados do Censo Demográfico de 2010 (disponíveis para uso público). Essa tese também trata do estudo do problema de clusterização com restrição de capacidade, assim além de garantir a conexidade procura-se conjuntamente garantir a capacidade. Mais especificamente, cada vértice $i \in V$ do grafo corresponderá a uma região e a seus atributos, (inclusive o atributo capacidade). Nesse caso, a restrição de capacidade é uma função de um limite inferior pré-estabelecido, com base em um dos atributos dos vértices do grafo V . Assim, o somatório desse atributo nos vértices pertencentes a um mesmo cluster deve satisfazer um limite inferior.

Além disso, se duas regiões i e j são vizinhas, existe uma aresta $A' = (i, j)$ cujo valor da distância é d_{ij} , considerando a distância euclidiana, e que existe um atributo associado a cada vértice que é o atributo utilizado como base para se verificar a restrição de capacidade mínima por APOND, nesta tese utiliza-se o atributo total de domicílios particulares permanentes em cada setor censitário. Por domicílio particular permanente denomina-se o domicílio que foi construído a fim de servir exclusivamente para habitação e, na data de referência, tinha a finalidade de servir de moradia a uma ou mais pessoas [CENSO DEMOGRÁFICO 2010].

Dentre as várias abordagens encontradas na literatura para a resolução do problema de clusterização com restrição de conexidade, destaca-se o algoritmo baseado na utilização da Árvore Geradora Mínima (AGM) [NEVES 2003], que também será considerado neste trabalho.

No que concerne à restrição de conectividade do problema abordado neste trabalho, os *clusters* conexos serão produzidos mediante a realização da construção e do particionamento da AGM.

As informações básicas para a construção da AGM são o grafo de conectividade G e as medidas de similaridade entre os objetos. A AGM é construída de forma iterativa. Mais especificamente, o processo tem início a partir de uma árvore T_i , contendo apenas um vértice e, a cada iteração, uma nova aresta e um novo vértice são adicionados à árvore anterior. Na iteração n , a árvore T_n contém todos os n vértices de V e possui um subconjunto de L , contendo $n - 1$ arestas, para o qual a soma dos custos associados às arestas é mínima. As etapas utilizadas para a geração da AGM, baseados no algoritmo de *Kruskal*, são:

Etapa 1: Consiste em ordenar, de forma crescente, as arestas (distâncias) do grafo submetido conforme seus custos. Em seguida, a árvore T é iniciada vazia.

Etapa 2: Na árvore T , conforme é realizada a ordenação das arestas, a cada iteração a inserção de uma aresta em T é avaliada uma vez que não pode ocorrer ciclos em T .

Etapa 3: As inserções ocorrem até que a árvore T tenha $|V| - 1$ arestas, considerando $|V|$ a quantidade de vértices do grafo submetido ao algoritmo.

Etapa 4: Ao final da execução, o algoritmo retornará uma árvore conexa T com menor custo possível, de acordo com Equação 11 a seguir:

$$\min \sum_{A \in T} C_e \quad (11)$$

Ao final da execução das etapas do algoritmo de *Kruskal*, produz-se a árvore geradora mínima, que contém todos os vértices representando todos os objetos. A solução final possui uma AGM com custo mínimo C_e (soma mínima das distâncias associadas às arestas de G).

Para encontrar o valor de C_e utiliza-se o exemplo hipotético a seguir, segundo Neves 2003. Tem-se a ilustração (Figura 2.8) da construção de uma árvore geradora mínima para um caso hipotético.

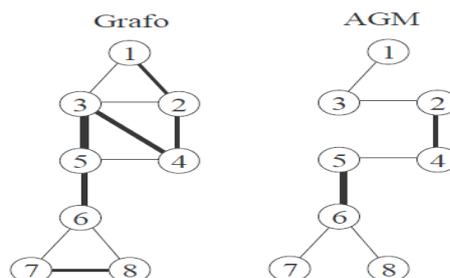


Figura 2.8 - Construção de AGM Adaptado de NEVES 2003

Segundo Neves 2003, as larguras das arestas que ligam os vértices vizinhos são inversamente proporcionais aos coeficientes de similaridades entre os objetos, ou seja, objetos vizinhos semelhantes são ligados por arestas finas (baixo custo). Assim, conclui-se que ao final que a AGM corresponde a um subgrafo desconexo de custo mínimo C_e , contendo somente as arestas mais finas (“menor custo”) é obtida através da Equação 3.

A partir deste ponto, procede-se à fase de particionamento da AGM, considerando que cada aresta que for eliminada dividirá a árvore em dois subgrafos conexos, correspondentes a dois *clusters*.

Na Figura 2.9 ilustra uma AGM e os dois grafos conexos que correspondem a duas áreas de ponderação (APONDs):

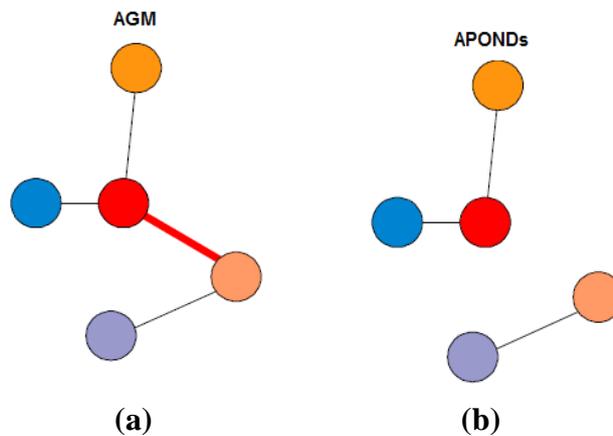


Figura 2.9 - AGM (a) e APONDs (b) [BRITO ET AL 2010]

Essa fase consiste em retirar as arestas mais “caras” (custo alto), ou seja, particionar a AGM mediante a remoção de $n - 1$ arestas considerando que T tenha $|V| - 1$ arestas disponíveis para a obtenção de k grafos conexos (*clusters*). Então, considerando $|V|$ a quantidade de vértices do grafo submetido a este algoritmo. A AGM terá, então, $n - 1$ arestas. Ou seja, para produzir k *clusters* deve-se remover da AGM as $(k - 1)$ arestas que produzem os subgrafos mais homogêneos no que concerne às distâncias.

Existem várias alternativas possíveis para definir o custo de uma aresta. Por exemplo, na etapa da construção da AGM, o custo das arestas do grafo submetido ao algoritmo é calculado através da Equação 3 ($D_{Euclidiana}(x_i, x_j) = [\sum_{l=1}^p (x_{il} - x_{jl})]^2$). E durante a fase do particionamento do grafo, utiliza-se a Equação 12 para a obtenção de seu valor.

$$Custo_a = Som(T) - (Som(T_a) + Som(T_b)) \quad (12)$$

A etapa de particionamento consiste em selecionar um *cluster* T para divisão, buscar a aresta existente entre vértices desse *cluster* que possuir o maior $Custo_a$ e removê-la da árvore. Para isso, deve-se remover cada uma das arestas de T e aplicar à Equação 7 ($f(P) = \sum_{c=1}^k Som_c$) em cada um dos novos *clusters* T_a e T_b . Em seguida, com base nos valores da função obtidos em cada um dos novos *clusters*, deve-se utilizar a Equação 12 para o cálculo do custo da aresta. O valor do custo de remoção da aresta corresponde à diferença entre a função objetivo do *cluster* atual e a soma da função objetivo de cada um dos novos *clusters*, sendo a soma da função objetivo dos novos *clusters* correspondente à soma dos quadrados dos desvios das duas subárvores T_a e T_b calculados os valores médios dos p atributos. Os dois novos *clusters* formados serão homogêneos à medida que o custo da aresta ($Custo_a$) a ser removida seja o maior possível. Assim, um custo alto associado à aresta indica que a sua remoção irá gerar *clusters* mais homogêneos.

Para ilustrar o cálculo do custo de remoção de uma aresta ($Custo_a$) da AGM, na Figura 2.10 é ilustrado o particionamento de um *cluster* formando dois novos *clusters*, considerando a remoção das arestas a e b .

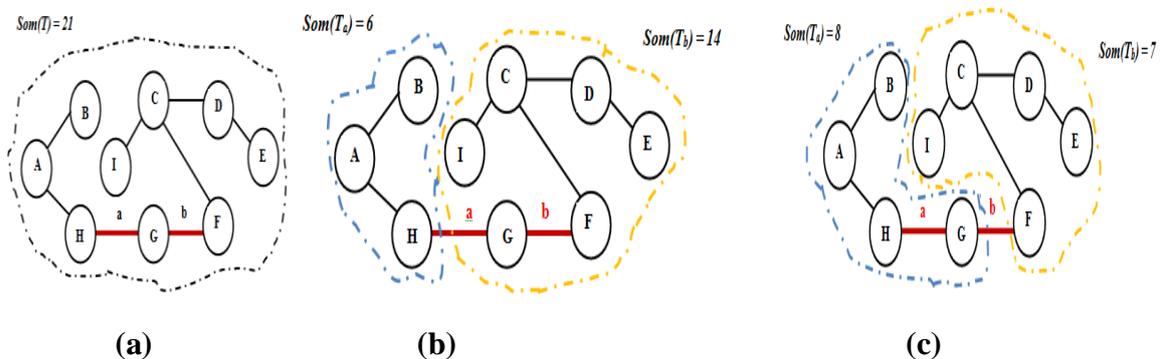


Figura 2.10 - Exemplo do Cálculo do Custo de remoção de uma aresta

A Figura 2.10 (a) ilustra a solução formada com um *cluster* associado à subárvore T que, hipoteticamente, possui um valor de função objetivo obtido pela Equação 7 (Som_c) igual a 21.

Já a Figura 2.10 (b) apresenta uma solução, caso a aresta a seja removida formando os dois novos *clusters* associados às subárvores T_a com valor de função objetivo igual a 6 e T_b com valor de função objetivo igual a 14. Assim, o custo da remoção da aresta a é igual a 1, utilizando a Equação 11 ($Custo_a$).

Na Figura 2.10 (c) as subárvores T_a e T_b possuem valores da função objetivo iguais a 8 e 7. Portanto, o custo da remoção da aresta b é igual a 6, utilizando novamente a Equação 12 ($Custo_b$).

Como se está maximizando o custo da aresta a ser removida, percebe-se que a remoção da aresta b produz a melhor solução em relação à aresta a .

Este critério de particionamento da AGM foi proposto em um algoritmo denominado SKATER (*Spatial 'K'uster Analysis by Tree Edge Removal*) que foi desenvolvido por um pesquisador da Universidade Federal de Minas Gerais utilizando o método de agrupamento com restrição de contiguidade por árvore geradora mínima.

A descrição do algoritmo e do funcionamento do software desenvolvido (elaborado em linguagem C++ para o ambiente *Windows*) pode ser encontrada em [NEVES ET AL 2002].

O SKATER utiliza um dos seguintes três critérios para obtenção de soluções:

- Construir k clusters sem estipular a restrição de capacidade;
- A capacidade de cada cluster é independente da quantidade de clusters construídos;
- O número máximo de clusters é denominado por uma capacidade mínima Cap informada previamente.

Considerando as opções existentes no SKATER, é possível afirmar que o algoritmo não atende plenamente a demanda do problema de clusterização com restrições de capacidade e conexidade, uma vez que não é possível fixar simultaneamente tanto a quantidade de clusters, quanto a capacidade mínima de cada cluster.

A Figura 2.11 ilustra o funcionamento do SKATER em quatro estágios diferentes no que se refere à área de Belo Horizonte, mais especificamente, à clusterização de seus setores censitários. Em 2.11(a) considerando aspectos socioeconômicos e condições dos domicílios; a Figura 2.11 (b) o grafo contendo a vizinhança entre os setores censitários; a Figura 2.11 (c) a árvore geradora mínima a partir do grafo original e a Figura 2.11 (d) as subárvores obtidas após o particionamento da AGM com a formação de 50 clusters, representados por cores diferentes.

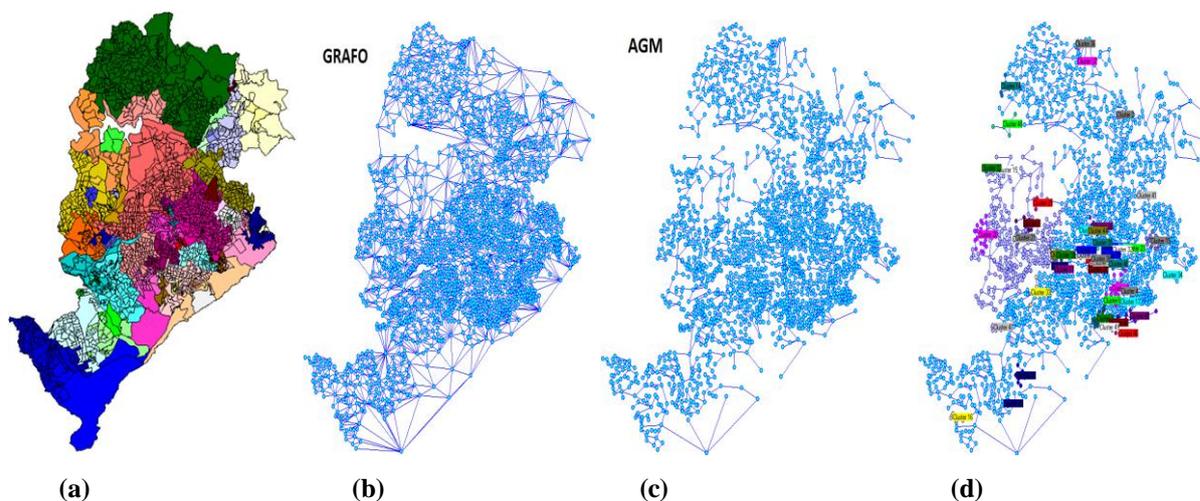


Figura 2.11 - Representação da região, do grafo, da AGM e do *cluster* de BH [NEVES 2003]

O SKATER pode ser obtido gratuitamente no site do Laboratório de Estatística Espacial (LESTE) do Departamento de Estatística, da Universidade Federal de Minas Gerais [NEVES 2003].

2.6 REVISÃO BIBLIOGRÁFICA

Esta seção traz uma revisão bibliográfica dos principais trabalhos disponíveis na literatura concernente ao problema de clusterização clássica e às suas variantes.

Em CERVEIRA (2014) é apresentado um projeto de otimização para encontrar o *layout* ideal para parques eólicos. Propõe-se um modelo matemático para encontrar a melhor configuração de interconexão elétrica das turbinas de parques eólicos e a subestação. O objetivo é minimizar os custos de instalação, que incluem os custos de custos de cabo e instalação de cabos, tendo em conta limitações técnicas. Este problema corresponde a uma árvore geradora mínima capacitada. A metodologia é aplicada em um estudo de caso real e os resultados são comparados com a solução de solo. Em MURTY ET AL (2014) é criada uma nova medida de similaridade/dissimilaridade para formação dos agrupamentos de *clusters*, chamada de separação por homogeneidade. Essa nova medida é adequada para conjuntos de quaisquer formas, tamanhos e/ou de diferentes densidades. Os principais conceitos da medida proposta são explicadas e resultados experimentais com conjunto de dados reais e artificiais que apoiam a medida proposta são analisados. No trabalho de SANTOS ET AL (2013) é apresentado um algoritmo híbrido baseado na metaheurística GRASP com o procedimento VND. O GRASP utilizou o VND como forma de intensificação das buscas locais procurando-se, desta forma, melhorar a qualidade das soluções do problema de clusterização com

restrições de capacidade e de conectividade. Ao final do trabalho foram realizados experimentos com instâncias reais obtidas em Censo Demográfico 2010.

No trabalho de CESELLI (2013) considera-se o problema de particionamento de uma região em áreas ligadas e atribuídas a administradores. Foi definido um problema de áreas homogêneas, em que é feita a busca de uma partição adequada de grafo através da atribuição de pesos aos vértices e um subconjunto de pesos pertencentes a um grafo não direcionado com seus componentes conectados. Os autores propõem uma formulação baseada em fluxo multi-produto através da utilização dos procedimentos de Busca Tabu e da Busca em Vizinhança de Grande Porte (VLSN). Em DAMODAR e PRASANTA (2013) é proposta é uma abordagem divisiva para acelerar a clusterização baseada em Árvore Geradora Mínima, e também para identificar os clusters que são formados arbitrariamente durante a forma de uma AGM. Inicialmente, o quadrado do erro do algoritmo de clusterização é usado no pré-processamento de clusterização da AGM. Então, a abordagem usando AGM é aplicada sobre os pontos representativos (centroides) de sub-*clusters* produzidos pelo método de agrupamento usando o quadrado do erro.

VANETIK (2013) trabalha com grafos com restrição de conectividade adaptados para a mineração de dados. Neste artigo, apresenta-se um novo algoritmo para encontrar padrões de grafos com conectividade prescrita em grandes conjuntos de dados a partir de um grafo simples. A autora também demonstra como seu algoritmo pode ser adaptado a um ambiente dinâmico, onde são feitas mudanças nos dados ao longo do tempo. Em BONAMI ET AL (2012) é proposta pela primeira vez a solução do problema de particionamento de grafos com restrições de capacidade para o planejamento de redes ópticas. Trata de uma variação do problema de particionamento de grafos em que o peso de um *cluster* na partição depende das arestas incidentes nos vértices.

No trabalho de SANTOS ET AL (2012) é apresentado um algoritmo híbrido baseado na metaheurística GRASP com o procedimento *Path-Relinking* para a solução do problema de clusterização com restrições de capacidade e de conectividade.

O trabalho de ZAGOURAS (2012) traz a proposta de um método avançado para classificar os tipos de circulação atmosférica com base em protótipos de grafos conectados entre si. Assim é apresentado um novo método de classificação de circulação atmosférica de mapas isobáricos. O método baseia-se na teoria dos grafos, especificamente na formação de *clusters* com restrição de conectividade.

Em COLGANO (2012) é proposta uma definição formal do problema de clusterização em grafos. Neste trabalho, o problema de clusterização em grafos é descrito como o problema

de encontrar uma solução que satisfaça um conjunto de restrições e que minimize uma função objetivo. O trabalho de CORTEZ ET AL (2012) propõe a resolução do problema de definição das áreas de ponderação do Censo 2012 considerando o seu mapeamento em um problema de clusterização em grafos. Em DENG e BRAD (2011) é proposto um algoritmo baseado na metaheurística (GRASP) e no procedimento *Path-Relinking* (PR) para resolver o problema do agrupamento em um grafo com n nós que será particionado em p subgrafos associados aos *clusters*. O objetivo é o de maximizar a soma dos pesos das arestas dentro de cada *cluster*, de tal modo que a soma dos pesos dos vértices correspondentes não exceda uma capacidade fixa.

Em SEMAAN (2010) são propostos algoritmos heurísticos (Evolutivos e GRASP) para o problema de clusterização, sendo o número de *clusters* é definido previamente. Neste trabalho o problema de clusterização foi mapeado em um problema de particionamento de grafos com restrições de capacidade e conexidade, em que experimentos foram realizados em instância reais (de uso público) do Censo Demográfico de 2000 e da Contagem Populacional 2007, obtidas no site do IBGE. Ao final do trabalho, observa-se a superioridade do Algoritmo Evolutivo em relação ao GRASP no que concerne à qualidade das soluções. Em BRITO e MONTENEGRO (2010) define-se um novo método de resolução para o problema de definição de áreas de ponderação. O mesmo pode ser mapeado em um problema clássico de agrupamento com restrições de capacidade e conexidade através da aplicação de um algoritmo que combina a construção da árvore geradora com um procedimento baseado na metaheurística VNS.

CAPÍTULO 3 – HEURÍSTICAS PARA O PROBLEMA DE CLUSTERIZAÇÃO

O presente capítulo traz uma descrição dos algoritmos heurísticos propostos para a resolução do problema de clusterização que foi o objeto de estudo desta tese. Conforme já comentado, a resolução do problema abordado não se restringe a uma simples minimização de uma função objetivo, mas também leva em conta o atendimento de restrições de capacidade e conexidade.

Neste contexto, não existem muitos trabalhos relacionados ao problema de clusterização com restrições de capacidade e de conexidade. Mais especificamente, há os trabalhos de [SEMAAN 2010][SEMAAN 2009] [SEMAAN 2008][SHIEH AND MAY 2001] e de [BRITO 2004]. Os dois primeiros autores propuseram abordagens que utilizam metaheurísticas e o último autor propôs uma formulação de programação inteira.

O objeto deste capítulo é propor alguns algoritmos heurísticos para a solução do problema de clusterização com restrições de capacidade e conexidade. Basicamente, são propostos algoritmos que utilizam os conceitos das metaheurísticas GRASP e VNS.

De forma a garantir a produção de soluções válidas para esse problema, o desenvolvimento destes algoritmos levou em consideração as seguintes questões: como representar uma solução, quais procedimentos de construção das soluções iniciais e buscas locais deveriam ser aplicados, qual refinamento deveria ser realizado em relação às soluções produzidas pelas buscas locais e como adaptar o procedimento de Reconexão por Caminhos (RC) e também o método de Descida em Vizinhança Variável (VND) ao problema.

3.1 GRASP

O GRASP (*Greedy Randomized Adaptive Search Procedure*) é uma metaheurística iterativa, gulosa, randômica e adaptativa que foi inicialmente proposta para resolver o problema do conjunto máximo independente [FEO E RESENDE, 1995]. Posteriormente, esta metaheurística foi aplicada ao problema de escalonamento de tarefas [BINATO ET AL, 2001], ao problema de planarização de grafos [RESENDE E RIBEIRO, 1997], ao problema de satisfabilidade (SAT) [RESENDE AND FEO, 1996], ao problema quadrático de alocação [LI ET. AL, 1994], e atualmente o GRASP é um dos métodos heurísticos mais populares da literatura.

O GRASP é composto por duas fases, a saber: a de construção de uma solução inicial e a de aplicação de uma busca local sobre esta solução, com o objetivo de tentar melhorá-la.

Na etapa de construção uma solução é construída iterativamente. Mais especificamente, em cada iteração desta fase, apenas um elemento é adicionado à solução a cada passo. A seleção do próximo elemento é guiada pela aplicação de uma função gulosa que avalia os benefícios ganhos com a inserção deste elemento na solução em construção, também chamada de solução parcial. A cada iteração desta fase, o próximo elemento a ser adicionado à solução parcial é escolhido dentre os elementos de uma lista restrita de candidatos (LRC), selecionado de forma aleatória, o que garante o aspecto probabilístico do método. Essa LRC é formada por um subconjunto dos melhores candidatos, isto é, aqueles cuja incorporação à solução parcial resulta nos melhores ganhos incrementais (aspecto guloso do algoritmo), no que concerne à função objetivo do problema. Uma vez que o elemento selecionado foi incorporado à solução parcial, a LRC é atualizada e os custos incrementais são reavaliados (aspecto adaptativo)

Os elementos contidos na LRC devem estar no intervalo definido pela Equação 13 por:

$$LRC = \{i \mid g_i \leq g_{min} + \alpha (g_{max} - g_{min})\} \quad (13)$$

Onde g_{max} e g_{min} são, respectivamente, o elemento de maior e o elemento de menor incremento na solução (pior e melhor candidato num problema de minimização) e α um parâmetro de entrada que pode variar de 0 a 1. Quanto mais próximo de 1 for o valor de α , mais aleatórias são as soluções geradas devido à diversidade de valores que podem ser encontradas na LRC. A partir de uma LRC, seleciona-se um elemento deste conjunto, aleatoriamente, sendo este não necessariamente o melhor candidato. Esta escolha aleatória permite que este procedimento possa ser usado várias vezes para obter soluções distintas.

Na busca local, o objetivo é tentar melhorar a solução inicial s produzida na fase de construção. Neste sentido, a cada iteração é gerado um conjunto de soluções na vizinhança de s , denotado por $N(s)$. Esse conjunto é produzido através da substituição iterativa da solução corrente por uma solução melhor resultando na nova solução atual s . A melhor solução em $N(s)$ é escolhida para ser a solução atual, caso esta solução tenha um custo inferior ao custo de s (no caso de um problema de minimização).

Nesta fase de busca local, a vizinhança da solução corrente é explorada com o objetivo de encontrar uma solução melhor, ou seja, um ótimo local de qualidade superior (s^+) ou um ótimo global (s^*).

Em um problema de minimização, assim como neste trabalho, entende-se que uma solução s^+ representa um ótimo local na vizinhança $N(s)$ de s se $f(s^+) \leq f(s)$, $\forall s \in N(s)$.

Ao buscar-se o desenvolvimento de um bom procedimento de busca local, as seguintes questões devem ser levadas em conta: a definição da vizinhança, a estratégia de busca na vizinhança e o tempo computacional consumido em cada iteração do procedimento. A figura 3.1 traz um pseudocódigo simplificado do GRASP.

Algoritmo 1: GRASP	
Entrada: <i>MaxIter</i>	
1.	<i>melhorSolução</i> ← 0;
2.	para <i>nIter</i> – 1 , ... , <i>MaxIter</i> faca
3.	<i>solução</i> ← AlgoritmoConstrução;
4.	<i>melhorSolução</i> ← AlgoritmoBuscaLocal (<i>solução</i>);
5.	fim para
Saída: <i>melhorSolução</i>	

Figura 3.1 – Pseudo-código do GRASP

3.2 ASPECTOS COMUNS AOS ALGORITMOS

A presente seção traz uma descrição das características comuns aos algoritmos implementados neste trabalho.

Inicialmente, será apresentada a estrutura de dados que foi adotada para a representação de uma solução do problema de agrupamento. Em seguida, faz-se uma descrição dos procedimentos de construção. Esses procedimentos utilizam heurísticas que efetuam o particionamento da árvore geradora mínima (AGM) construída a partir do grafo associado ao problema de clusterização, considerando as restrições de capacidade e de conexidade.

Após a descrição desses procedimentos, são apresentados os procedimentos de busca local que realizam migrações de vértices entre os *clusters* objetivando, simultaneamente, a minimização da função objetivo e o atendimento das restrições de capacidade e de conexidade.

A descrição é finalizada com a apresentação de procedimentos que correspondem a um refinamento nas buscas locais. Mais especificamente, procedimentos que incorporam o método de reconexão por caminhos (RC) e um método VND. Ambos os procedimentos têm a finalidade de intensificar a busca por soluções de melhor qualidade.

3.2.1 REPRESENTAÇÃO DA SOLUÇÃO

É fato conhecido da literatura que a forma de representação da solução tende a impactar na convergência do algoritmo no que diz respeito à obtenção de soluções válidas [HARTUV AND SHAMIR, 1999].

Este trabalho utilizou a representação da solução denominada *group-number* [TRINDADE AND OCHI, 2006]. Nessa estrutura de representação de solução, utiliza-se um vetor (ou *array*) ou, de maneira mais formal, uma estrutura de dados homogênea em que cada índice representa o vértice do grafo e o seu conteúdo é um número inteiro positivo entre 1 e k , ou seja, é o *cluster* ao qual o vértice está associado.

A Figura 3.2 ilustra a representação de uma solução através da estrutura *group-number*.

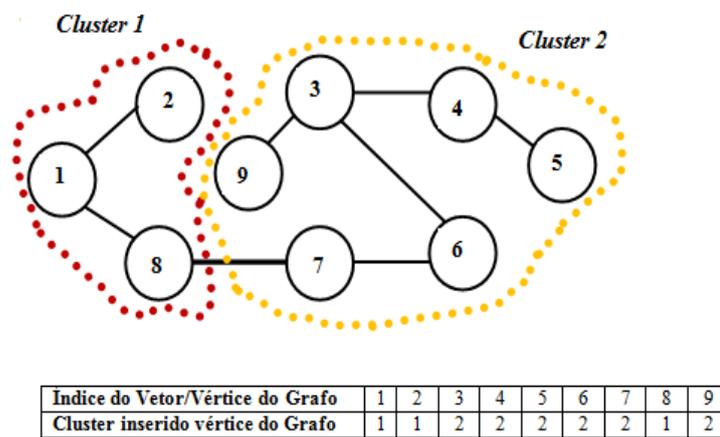


Figura 3.2 - Representação da Solução

Nesse exemplo, o grafo acima foi dividido em dois *clusters*, em que o *Cluster 1* possui os vértices do grafo (1, 2 e 8) e o *Cluster 2* possui os vértices (3, 4, 5, 6, 7 e 9).

Além deste vetor, há uma estrutura de dados auxiliar que é utilizada para armazenar um atributo referente à capacidade (neste trabalho, *mínima*) do *cluster*, obtida pelo somatório do atributo associado à capacidade dos vértices do grafo. Assim, pode-se definir a capacidade mínima por *clusters*, ou seja, quais *clusters* possuem um valor inferior ao limite pré-determinado. De forma a ilustrar esta última observação, a Tabela 3.1 a seguir traz as capacidades associadas a cada um dos vértices do grafo da Figura 3.2. O atributo de capacidade poderia ser por exemplo, o número de domicílios com pessoas com renda acima de 10 (dez) salários mínimos.

Tabela 3.1: Atributo dos vértices do grafo

Vértices do Grafo	Atributo de Capacidade
1	4
2	1
3	5
4	4
5	3
6	2
7	1
8	2
9	5

Os algoritmos implementados permitem que o valor da capacidade mínima seja informado como um parâmetro de entrada ou que o próprio algoritmo estipule uma capacidade mínima por *Cluster* através da aplicação da Equação 14 proposta por Semaan 2010 e utilizados também em [SANTOS, 2012] [SANTOS, 2013]:

$$Capacidade_{Min_Cluster} = (\beta/k) \cdot \sum_{i=1}^{|V|} x_{il} \quad (14)$$

sendo:

- β fator de ajuste;
- k quantidade de *clusters*;
- $|V|$ corresponde à quantidade de objetos a serem agrupados;
- x_{il} valor do l -ésimo atributo associado ao i -ésimo objeto;

Na próxima seção são descritos os procedimentos construtores implementados neste trabalho para construção das soluções iniciais.

3.2.2 ETAPA DE CONSTRUÇÃO

Os procedimentos de construção de soluções iniciais desenvolvidos neste trabalho geram *clusters* através do particionamento de uma AGM T . Esta árvore foi construída a partir do grafo G associado ao problema de clusterização com restrição de capacidade e conexidade, em k *clusters* (subárvore). Portanto, os k *clusters* são definidos através da remoção de $k - 1$ arestas de T , sendo que a remoção de cada aresta produz duas novas subárvores, ou seja, dois novos *clusters* definidos como T_a e T_b .

Em todos os procedimentos de construção de soluções propostos neste trabalho, a restrição de conexidade é garantida. Porém, apesar dos procedimentos terem como objetivo principal a busca de soluções válidas que atendam concomitantemente às restrições de conexidade e de capacidade mínima por *cluster*, esta última restrição pode não ser atendida. Nesse caso, em algumas situações, pode ser impossível a formação de soluções que atendam ambas as restrições.

Assim, utilizando a ideia de particionamento da AGM, foram implementados cinco estratégias de construtores de soluções iniciais que estão descritas a seguir:

3.2.2.1 CONSTRUTOR 1

A primeira estratégia do procedimento construtor de soluções iniciais realiza o particionamento da AGM respeitando somente a restrição de conexidade, sem considerar a restrição de capacidade, objetivando, portanto, somente a minimização da função objetivo.

O procedimento construtor é aplicado em duas etapas que são executadas $(k - 1)$ vezes para a obtenção de k *clusters*:

A primeira etapa consiste na **seleção do cluster a ser particionado**. Nessa etapa, seleciona-se o *cluster* com o menor grau de homogeneidade (considerando a Equação 7), excetuando-se a primeira iteração do procedimento construtor, uma vez que só existe 1 (um) *cluster* composto pela AGM. Voltamos a lembrar de que Equação 7 é representada por $f(P) = \sum_{c=1}^k Som_c$ e a Equação 11 por $Custo_a = Som(T) - (Som(T_a) + Som(T_b))$.

A seguir, define-se qual aresta será **removida** de forma a produzir dois novos *clusters* a partir desta etapa. O valor do custo da remoção da aresta é obtido através da Equação 11. Nesse caso, quanto maior o valor de $Custo_a$ mais homogêneos são os dois novos *clusters* formados. Nesse procedimento construtor foi considerada uma ideia similar à apresentada no procedimento de construção metaheurística GRASP. Ou seja, cria-se uma Lista Restrita de Candidatos (LRC) em que serão incluídas as α arestas que possuem os maiores valores de $Custo_a$. Particiona-se, então, a AGM através da remoção aleatória de uma das arestas inseridas na LRC. E, enquanto a quantidade de *clusters* pré-estabelecida não for alcançada, deve-se repetir os seguintes passos:

- Selecionar o *cluster* com maior valor da função objetivo f (Equação 7)
- Calcular o $Custo_a$ para todas as arestas do *cluster* selecionado;
- Definir a LRC com as α arestas que possuem os maiores valores de $Custo_a$;
- Particionar o *cluster* selecionado através da remoção aleatória de uma aresta de LRC.

A adoção desse procedimento possibilita uma diversificação das soluções, ou seja, encontrar soluções potencialmente válidas, evitando que o algoritmo tenha um comportamento apenas guloso.

A figura a seguir ilustra a aplicação do procedimento Construtor 1 com todas as suas fases e as respectivas explicações sobre cada uma delas, considerando a formação de 3 clusters:

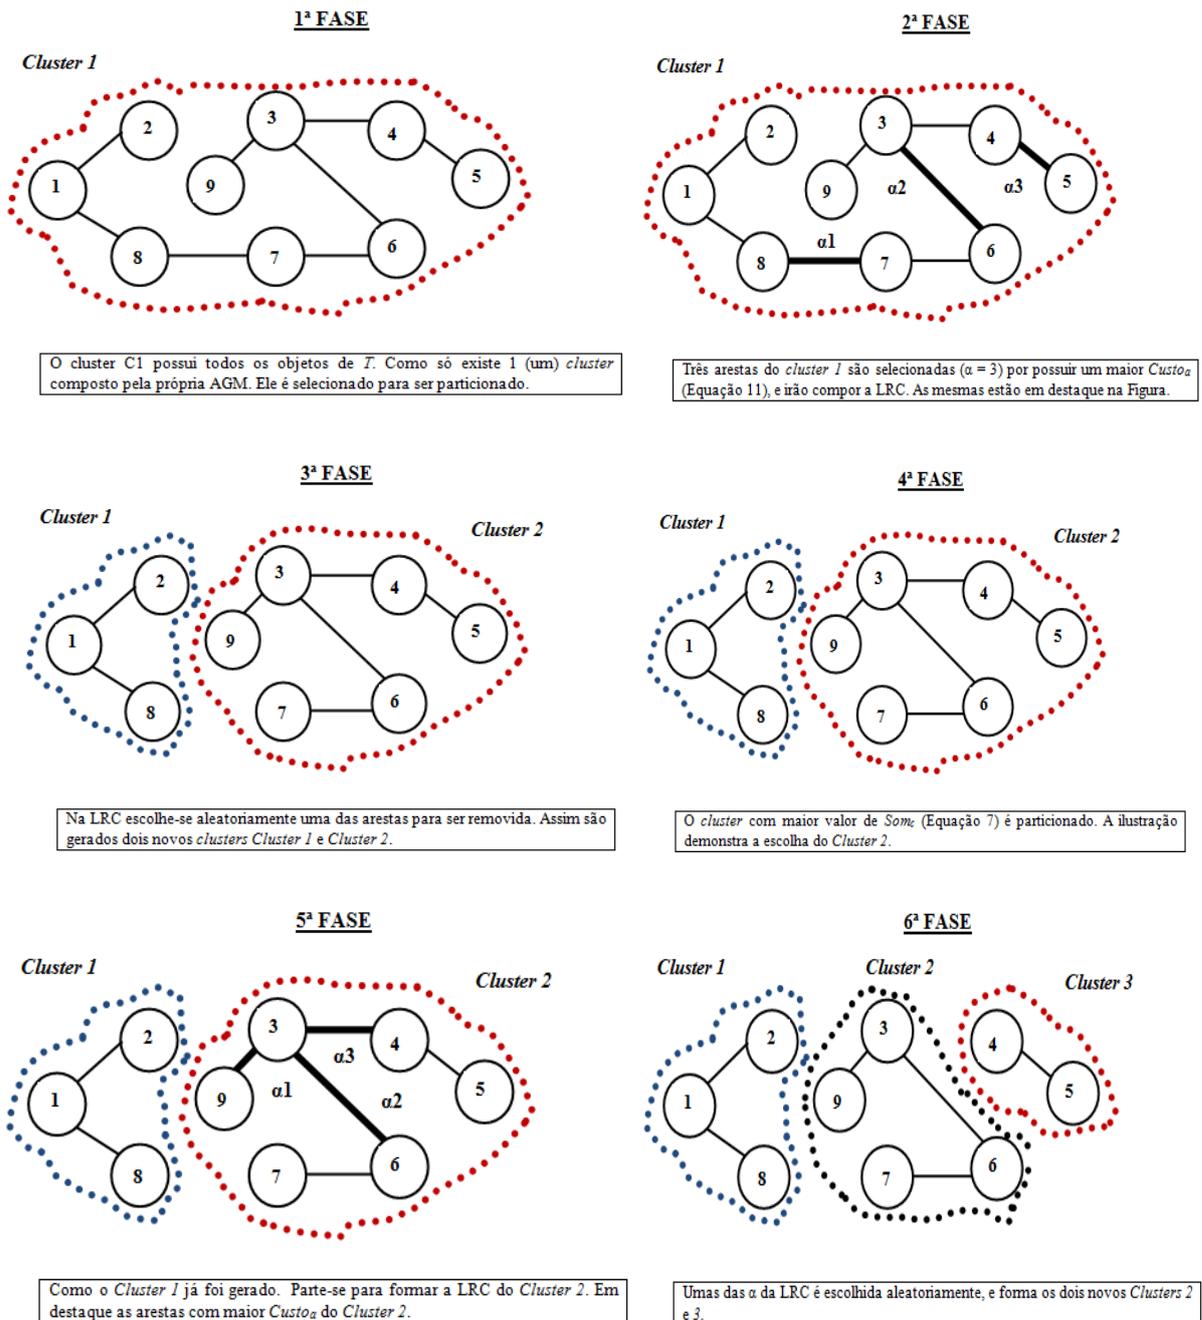


Figura 3.3 - Fases do Construtor 1

Embora exista a restrição de capacidade mínima, ou seja, um limite inferior para o somatório do atributo associado à capacidade dos vértices do *cluster*, o Construtor 1 foca apenas na restrição de conexidade. O procedimento Construtor 2, que será visto a seguir, trata da restrição de conexidade, além de garantir também a capacidade mínima.

3.2.2.2 CONSTRUTOR 2

Neste segundo procedimento, é realizado o particionamento da AGM respeitando as restrições de conexidade e de capacidade mínima. No que se refere à restrição de capacidade mínima, o construtor 2 (dois) trabalha na tentativa de obter *clusters* que atendam essa restrição, ação esta que nem sempre é bem sucedida.

O procedimento construtor 2 (dois) consiste de duas etapas descritas a seguir:

Na primeira etapa é gerada **uma subárvore principal contida na AGM**. A concepção de subárvore principal está associada à existência, na AGM, de um caminho simples sem ciclos, entre dois vértices dessa árvore, ou seja, toma-se um vértice v_i como a origem desse caminho e um vértice v_j como o término. A seleção dos vértices v_i e v_j é feita aleatoriamente entre todos os vértices pertencentes a AGM, para que se possa a partir dessa escolha calcular a distância entre os V_8 e V_9 (Figura 3.4), devido a essa arbitrariedade na escolha dos vértices fica impossível garantir que esse seja o menor caminho entre eles.

A partir da AGM, são selecionados de forma aleatória dois vértices, ilustrados em destaque na Figura 3.4 abaixo:

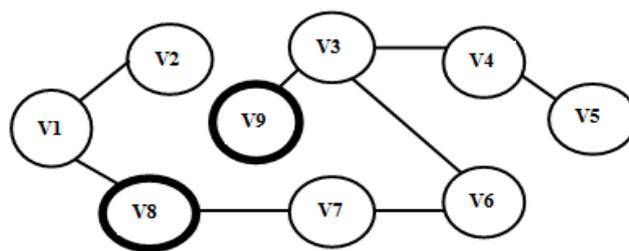


Figura 3.4 - Seleção da subárvore principal da AGM

Os vértices selecionados de forma aleatória (V_8 e V_9) irão formar a subárvore principal da AGM juntamente com os outros vértices que se encontram no caminho existente entre eles. Para a identificação dos vértices que se encontram no caminho existente entre os vértices A e B, utilizou-se a Equação 15.

$$Di(A, B) - (Di(A, verticeX) + Di(B, verticeX)) = 0 \quad (15)$$

sendo:

- A o vértice inicial a subárvore principal da AGM;
- B o vértice final da subárvore principal da AGM;
- $verticeX$ corresponde ao vértice sob consulta. Caso o lado esquerdo da Equação 15 seja igual a 0 (zero), confirma-se que o vértice X pertence ao caminho existente entre os vértices A e B . Esta distância que está sendo referenciada corresponde ao número de arestas em que cada aresta corresponde ao comprimento um.

Caso o lado esquerdo da Equação 15 tenha um resultado diferente de 0 (zero), então o vértice X não pertence à subárvore principal da AGM entre os vértices A e B .

Desta forma, a distância entre os vértices V_8 e V_9 , conforme o caminho existente na AGM, é a quantidade de arestas existentes entre esses dois vértices. A Figura 3.5 ilustra a subárvore principal formada pelos vértices V_8 e V_9 e os vértices que estão no caminho entre V_8 e V_9 .

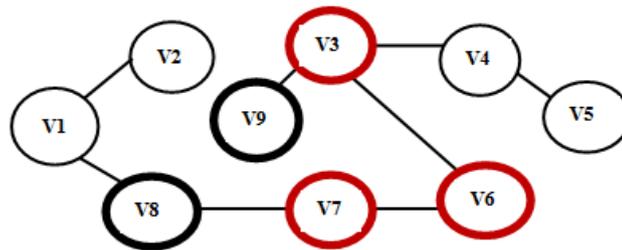


Figura 3.5 - Vértices que estão no caminho entre V_8 e V_9

Exemplificação da Equação 15 para o vértice V_1 , é ilustrada na Figura 3.6:

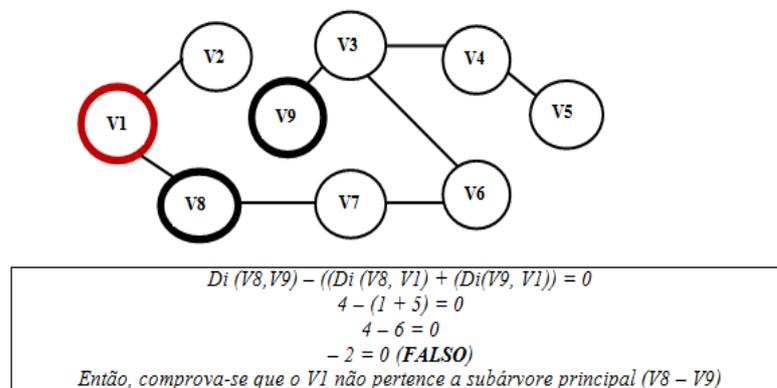


Figura 3.6 - Exemplificação do vértice (V_1) na subárvore principal da AGM

Exemplificação da aplicação da Equação 15 para o vértice V_6 , é ilustrada na Figura 3.7:

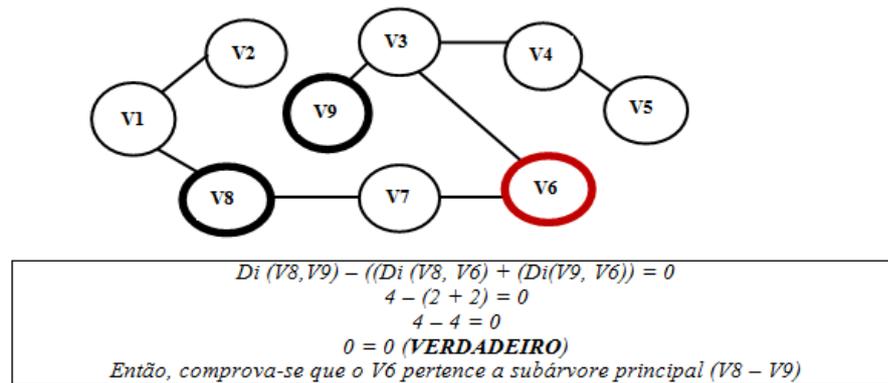


Figura 3.7 - Exemplificação do vértice (V₆) na subárvore principal da AGM

Assim, ao se definir quais vértices pertencem à subárvore principal da AGM através do cálculo da Equação 15, agrupam-se os vértices que não pertencem à subárvore principal serão agrupados ao vértice mais próximo pertencente a esta subárvore. Desta forma, o grafo deve ficar com um formato de uma “barbante” e os vértices pertencentes à subárvore principal possuirão o somatório das capacidades dos vértices a eles agrupados. Então, a subárvore principal toma a forma do grafo apresentado na Figura 3.8:

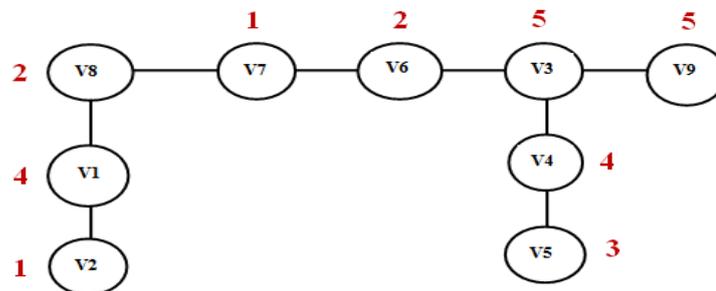


Figura 3.8 - Geração da subárvore principal da AGM

E a Figura 3.9 apresenta os vértices pertencentes à subárvore principal com o somatório dos valores das capacidades dos vértices a eles agrupados, os valores definidos na Tabela 3.1, a ilustração a seguir:

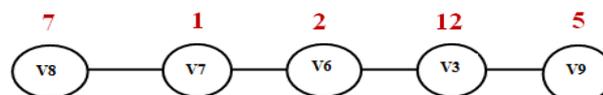


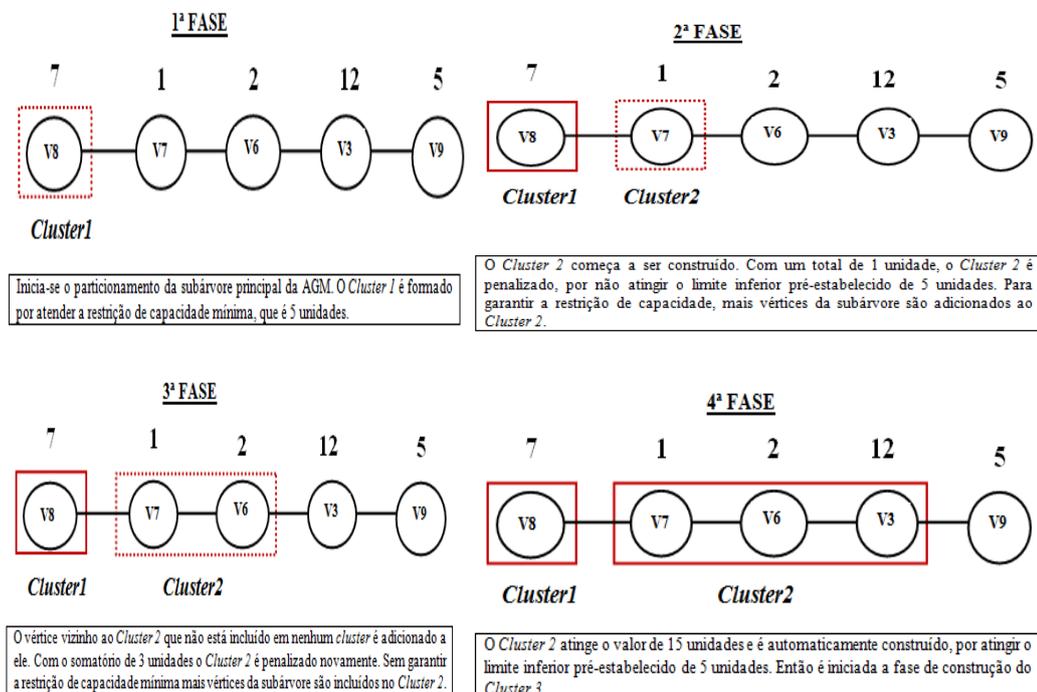
Figura 3.9 - Subárvore principal da AGM com os vértices capacitados

Na segunda etapa do procedimento construtor 2 (dois), é efetuado o particionamento da **subárvore principal considerando a restrição da capacidade mínima até a obtenção de *k* clusters**: considerando o exemplo da Figura 3.7, a partir dos vértices (V₈ e V₉) que

constituem a subárvore principal da AGM, são adicionados os grupos de vértices adjacentes, conforme a restrição de capacidade mínima.

Portanto, os *clusters* são formados por vértices ou grupo de vértices, de acordo com a verificação do somatório, ou seja, se a sua capacidade for superior ao limite inferior pré-estabelecido. Assim, a restrição de capacidade mínima é garantida, o *cluster* é formado e um novo *cluster* é obtido a partir da junção dos vértices restantes da subárvore principal da AGM, até que sejam gerados os k *clusters*. Todavia, o particionamento continua sendo executado até que o número (k) de *cluster(s)* seja obtido ou, caso ainda exista algum vértice ou grupos de vértices não adicionados a nenhum *cluster* na subárvore principal da AGM. A Figura 3.10 ilustra as fases do procedimento construtor 2 (dois). Nesse caso, definiu-se a capacidade mínima pré-estabelecida com um valor de cinco unidades (pode ser o número de alguma variável definida no problema) e a geração de 3 *clusters*. Assim como a Figura 3.8 os vértices estão capacitados.

A figura a seguir ilustra a aplicação do procedimento Construtor 2 com todas as suas fases e as respectivas explicações sobre cada uma delas, considerando a formação de 3 *clusters* e garantindo a restrição de capacidade mínima por *cluster*:



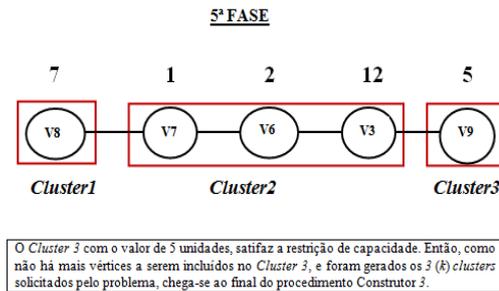


Figura 3.10 - Fases de Construtor 2

A seguir, temos a apresentação do procedimento Construtor 3 que trata também das restrições de conectividade e de capacidade mínima por *cluster*.

3.2.2.3 CONSTRUTOR 3

Assim como o procedimento Construtor 2, o procedimento Construtor 3 trabalha levando em conta as restrições de conectividade e de capacidade mínima por *cluster* para a geração de soluções válidas. Esses procedimentos são semelhantes, diferenciando-se apenas no que concerne à restrição de capacidade. Mais especificamente, esse procedimento também visa maximizar a capacidade dos *clusters* através da delimitação da capacidade máxima por *cluster*.

Assim como o Construtor 2 (dois), o Construtor 3 (três) é aplicado em duas etapas, sendo gerada na primeira etapa uma subárvore principal contida na AGM.

Na segunda etapa do procedimento construtor 3 (três) é particionada a subárvore principal considerando a restrição da capacidade mínima até a obtenção de *k clusters*, e de um fator determinante escolhido aleatoriamente para maximizar a capacidade de um *cluster*. Procura-se maximizar a capacidade dos *clusters* para aumentar a chance de formação de novos *clusters* sem penalização nas iterações seguintes.

Na ilustração das fases do procedimento Construtor 3 (três), na Figura 3.11, exemplifica-se o caso em que a capacidade mínima por *cluster* é de 5 (cinco) unidades e a máxima por *cluster* é de 12 (doze) unidades, ou seja, sendo uma variável *numCap* definida como o valor de somatório de unidades em um *cluster*, fica definido no problema exemplificado que $5 \leq numCap \leq 12$. Portanto, o *cluster* não pode ter menos de 5 (cinco) unidades e nem mais do que 12 (doze) unidades. Para a formação de 3 *clusters*.

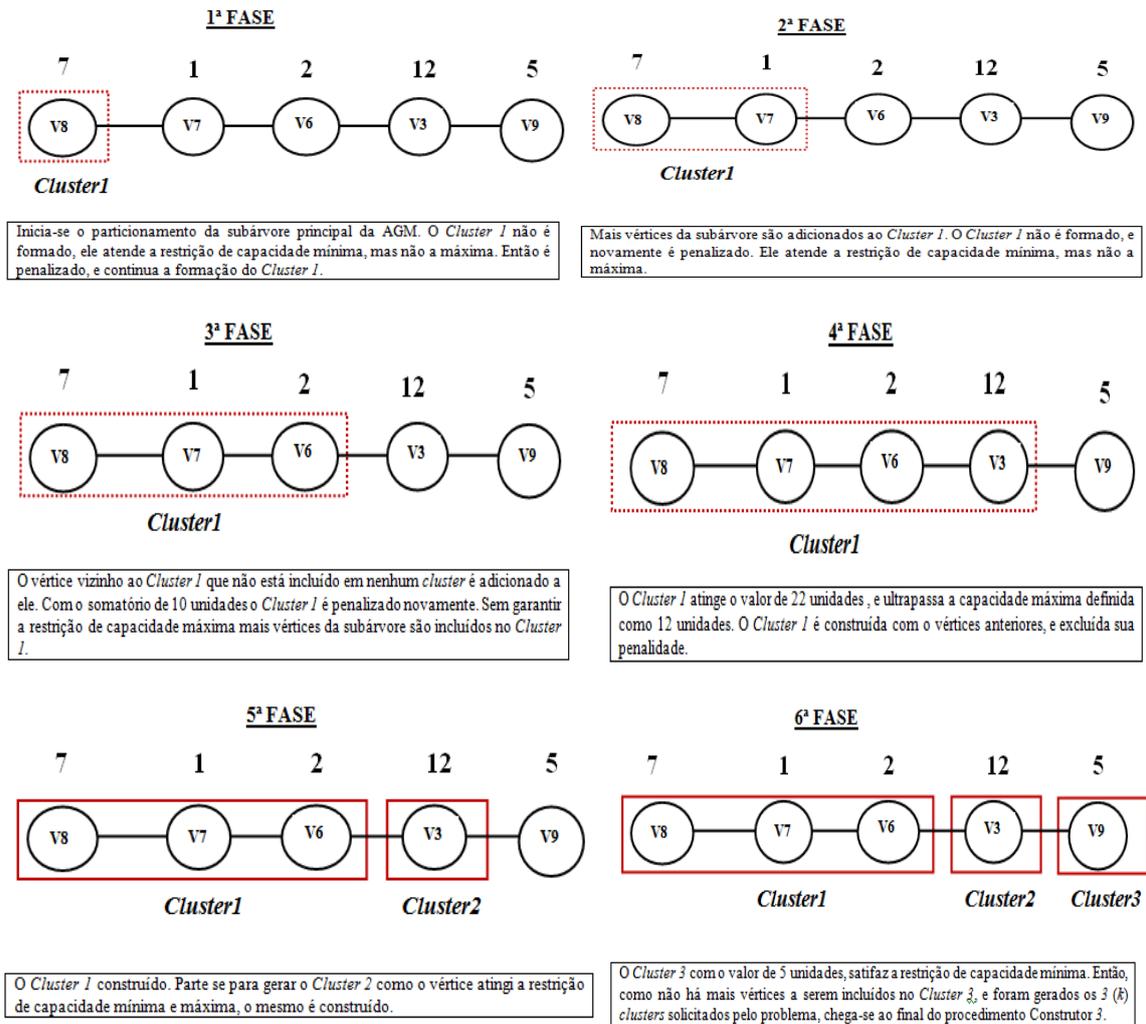


Figura 3.11 - Fases do Construtor 3

Dessa forma, verifica-se que o procedimento Construtor 3 (três) consegue maximizar a capacidade dos *clusters*.

A seguir, temos a apresentação do procedimento Construtor 4 (quatro) que trata também das restrições de conectividade e de capacidade mínima por *cluster*.

3.2.2.4 CONSTRUTOR 4

Neste procedimento, particiona-se a AGM respeitando as restrições de conectividade e de capacidade mínima. O procedimento Construtor 4 (quatro) propicia uma regeneração das soluções inviáveis que eventualmente são produzidas pelo procedimento Construtor 2 (dois), ou seja, quando neste a quantidade de *clusters* gerados é inferior a um número pré-fixado. Neste caso, torna-se necessário regenerar a solução mediante a seleção do *cluster* com o maior número excedente à capacidade mínima sugerida no problema.

O procedimento Construtor 4 (quatro) opera até que a quantidade de *clusters* definida seja atingida, ou até que não seja mais possível dividir o *cluster* em função da violação da restrição de capacidade.

A figura a seguir ilustra a aplicação do procedimento Construtor 4 com todas as suas fases e as respectivas explicações sobre cada uma delas, considerando a formação de 3 *clusters* e garantindo a restrição de capacidade mínima por *cluster* de 5 unidades, a partir de uma solução inválida produzida pelo Construtor 2 (dois):

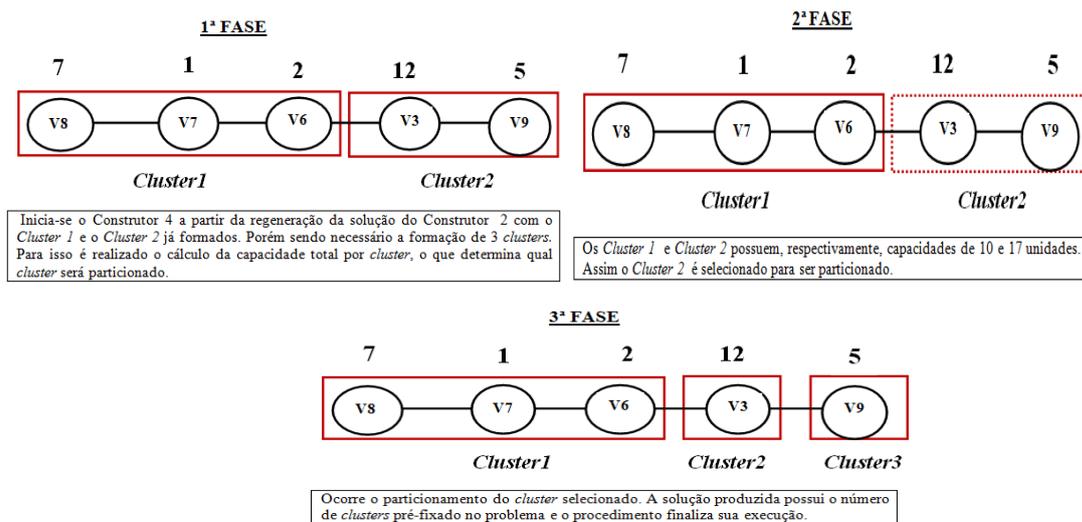


Figura 3.12 - Fases do Construtor 4

3.2.2.5 CONSTRUTOR 5

O procedimento Construtor 5 (cinco) trabalha com as restrições de conectividade e de capacidade mínima por *cluster* visando a geração de soluções válidas.

O Construtor 5 (cinco) é executado em duas etapas, assim como os construtores 2, 3 e 4, sendo gerada na primeira etapa uma subárvore principal contida na AGM.

Na segunda etapa deste procedimento construtor é particionada a subárvore principal, considerando a restrição de capacidade mínima. Tal particionamento é aplicado até a obtenção de k *clusters* e de um valor pré-estabelecido para maximizar a capacidade de um cluster considerando a restrição de conectividade existente não só na subárvore principal da AGM, mas também no Grafo Original.

Na ilustração das fases do procedimento Construtor 5 (cinco), na Figura 3.13, exemplifica-se o caso em que a capacidade mínima por *cluster* é de 5 unidades.

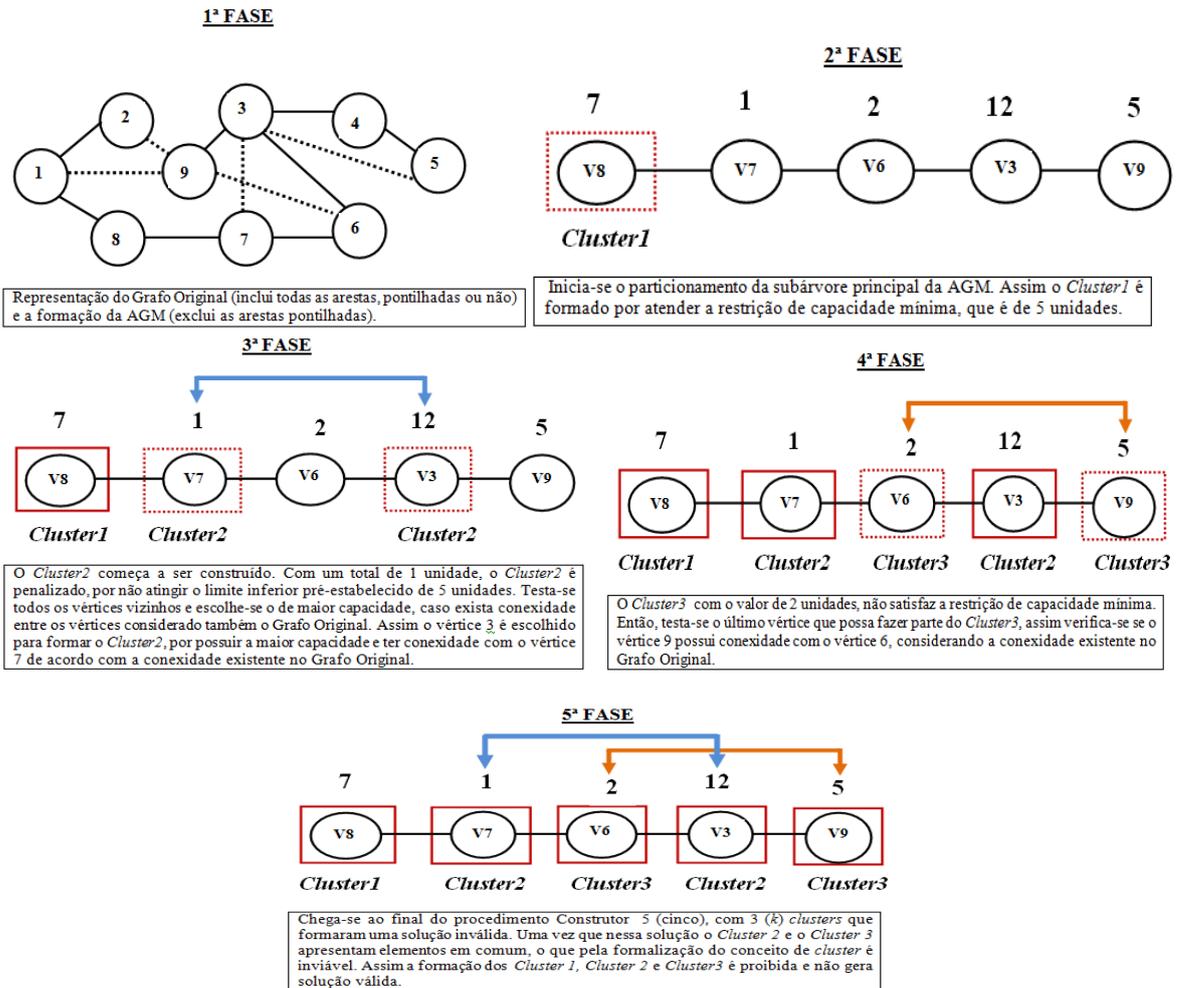


Figura 3.13 - Fases do Construtor 5 – Solução Inválida

A seguir, são apresentados os seis procedimentos de Busca Local que são propostos neste trabalho.

3.2.3 PROCEDIMENTOS DE BUSCA LOCAL

Conforme já comentado, os procedimentos de busca local tendem a melhorar as soluções advindas de procedimentos de construção (em problemas de minimização ou maximização) e propiciar a geração de um número maior de soluções consideradas válidas para o seu problema [DIAS, 2004].

Neste trabalho, foram desenvolvidos seis procedimentos de busca local. E, em todos eles, são realizadas migrações de vértices entre *clusters*, objetivando minimizar a função objetivo. Esses procedimentos de busca local atuam na tentativa de eliminação de penalidades referentes ao não atendimento da restrição de capacidade mínima por *cluster*, e na melhoria da

solução com a redução da função objetivo. Destes, três utilizam a AGM definida pelo(s) procedimento(s) construtor (es) e os outros três usam o Grafo Original.

Para que fosse possível realizar a migração de vértices entre os *clusters* em todas as seis buscas locais propostas neste trabalho, foram respeitados os seguintes requisitos:

- A migração de vértices entre *clusters* acontece, se e somente se, o *cluster* estiver penalizado. Um *cluster* está penalizado quando não gera uma solução válida, seja por não atingir a capacidade mínima pré-estabelecida, ou por não atingir o número de *clusters* definidos previamente no problema;
- Um *cluster* com apenas 1 (um) vértice não deve ser migrado, uma vez que o mesmo ficaria vazio, e não podem existir *clusters* sem vértices;
- Um vértice adjacente a, no mínimo 2 (dois) vértices no mesmo *cluster*, não pode ser migrado, pois essa migração resultaria em um *cluster* desconexo. Dessa forma, deixaria de garantir a restrição de conexidade.

A seguir, tem-se a apresentação dos seis procedimentos de busca local.

3.2.3.1 BUSCA LOCAL 1

Além de melhorar a homogeneidade dos clusters, o procedimento de Busca Local 1 também tem como objetivo principal eliminar penalidades. Mais especificamente, este procedimento utiliza uma lista constituída pelas arestas que foram removidas da AGM durante a fase de construção e uma lista de *clusters* penalizados, ou seja, que não satisfazem a restrição de capacidade. O procedimento verifica a possibilidade de realizar migrações de vértices entre os *clusters* utilizando essa lista.

Neste sentido, para cada aresta da lista, são visualizados os *clusters* aos quais os seus vértices pertencem. Em seguida, são verificados os requisitos comuns a todas as buscas locais para que seja possível realizar a migração de vértices entre os *clusters*.

A Figura 3.14 ilustra a aplicação do procedimento Busca Local 1 (um) e seus respectivos comentários:

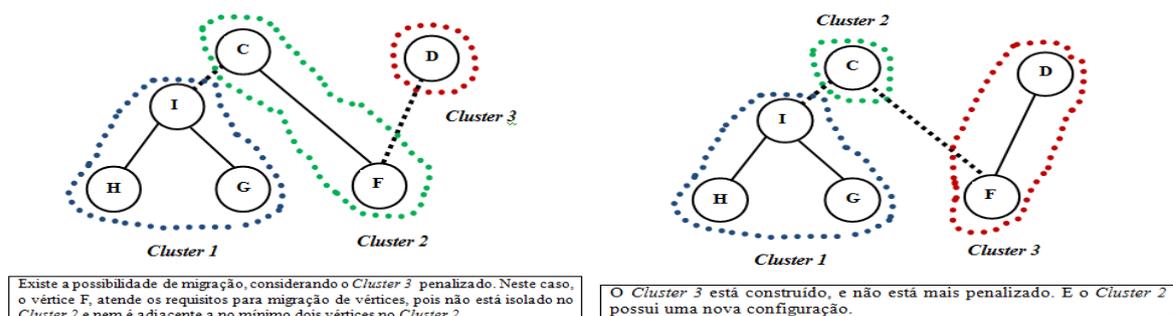


Figura 3.14 – Busca Local 1 – possibilidade de migração de vértices

No exemplo anterior, demonstrado pela Figura 3.14, há uma possibilidade de migração entre vértices.

A Figura 3.15 ilustra exemplos em que a Busca Local proíbe a migração de vértices e suas respectivas explicações:

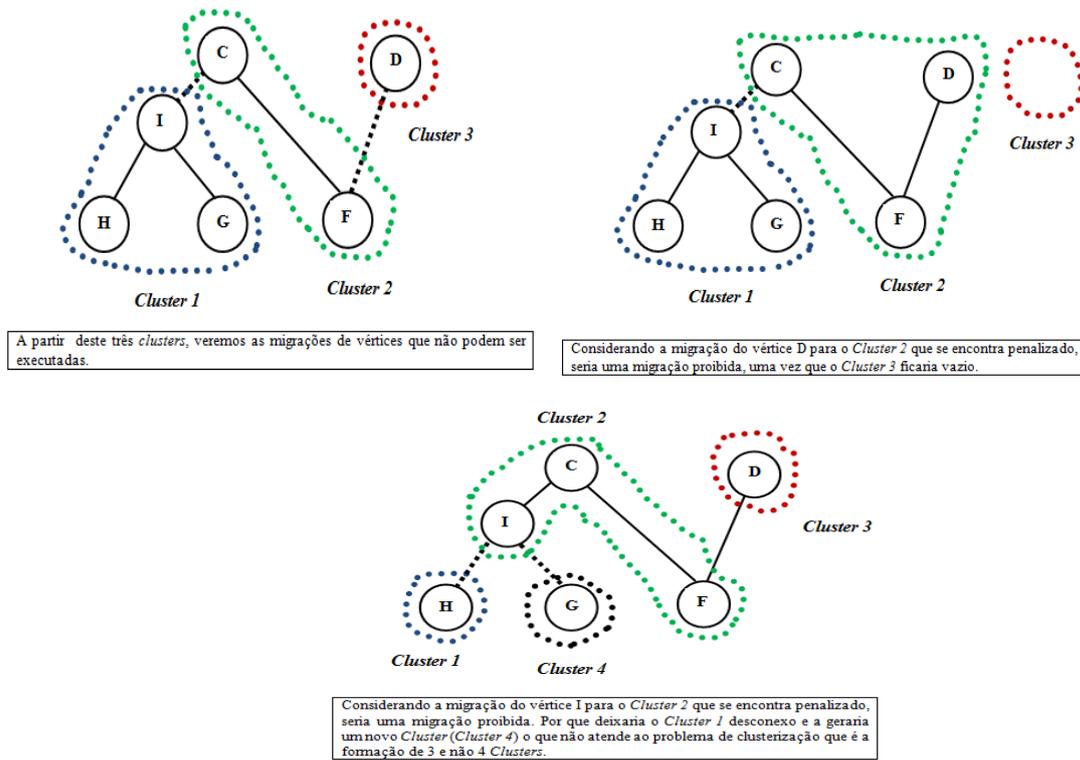


Figura 3.15 – Busca Local 1 – proibida a migração de vértices

Na Figura 3.16 tem-se um exemplo de Busca Local onde há a possibilidade de migração de vértices garantindo a restrição de capacidade mínima por cluster. Neste exemplo, demonstrado pela ilustração abaixo, a capacidade mínima pré-estabelecida foi de cinco unidades.

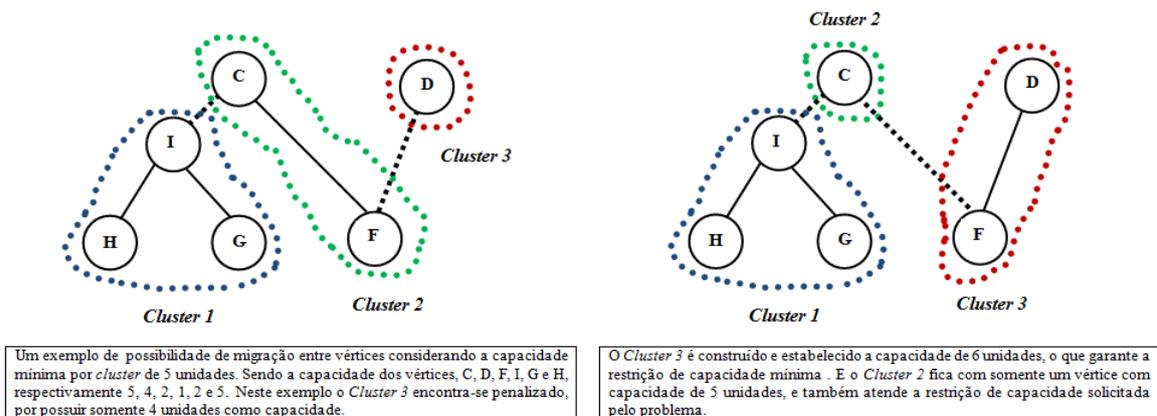


Figura 3.16 – Busca Local 1 – migração de vértices com cluster capacitados

3.2.3.2 BUSCA LOCAL 2

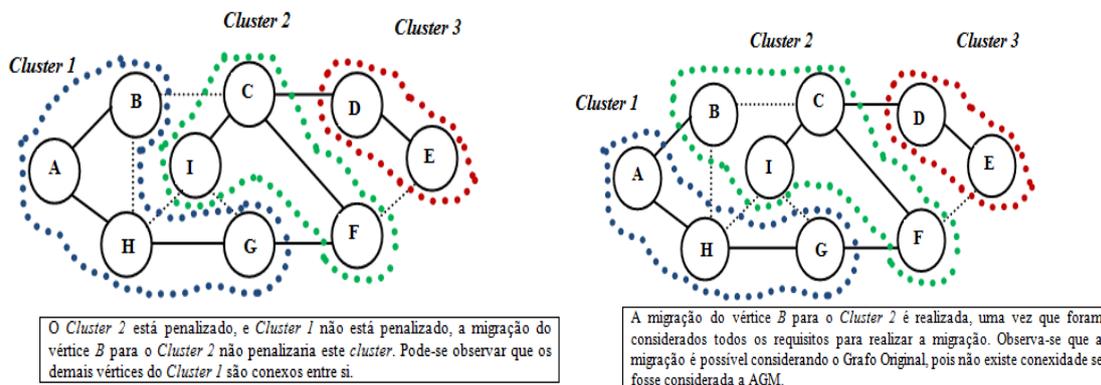
Assim como o procedimento Busca Local 1, o procedimento de Busca Local 2 também tem como objetivo eliminar as penalidades. Esse procedimento verifica a possibilidade de realizar migrações de vértices entre os *clusters*, considerando o Grafo Original, e não apenas a AGM. Tendo em vista que esse procedimento trabalha com o Grafo Original, há a necessidade de que seja verificado se as restrições de conectividade entre os vértices internos aos *clusters* estão sendo satisfeitas, ou seja, se os vértices internos aos *clusters* são conexos.

Inicialmente, esse procedimento seleciona, de forma aleatória, uma aresta $a = (i, j)$ do Grafo Original antes da construção, e em seguida, são efetuadas as seguintes verificações:

- A aresta é selecionada quando apenas um dos *clusters*, em que os vértices da aresta selecionada pertence está penalizado. Em caso negativo, o procedimento seleciona outra aresta, também aleatoriamente;
- Um *cluster* é candidato a receptor do vértice a ser migrado e outro *cluster* é candidato a doador do vértice, se apenas um destes *clusters* estiver penalizado;
- A migração de um vértice para o *cluster* receptor deve ocorrer somente se os demais vértices do *cluster* doador forem conexos entre si, ou seja, se a restrição de conectividade for atendida.

Sendo estas verificações atendidas, é possível a migração do vértice do *cluster* doador para o *cluster* receptor.

A ilustração da Figura 3.17 apresenta a aplicação do procedimento Busca Local 2 (dois) e suas explicações. As arestas em negrito pertencem à AGM construída, e as demais arestas, em conjunto com as arestas da AGM, fazem parte do Grafo Original:



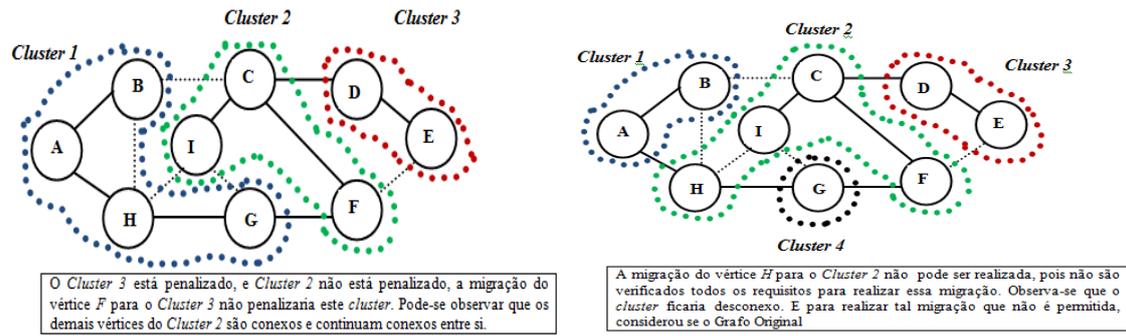


Figura 3.17 – Busca Local 2 – possibilidade de migração de vértices

Neste exemplo há uma possibilidade de migração dos vértices entre os *clusters*.

A Figura 3.18 ilustra exemplos em que a Busca Local 2 (dois) proíbe a migração de vértices:

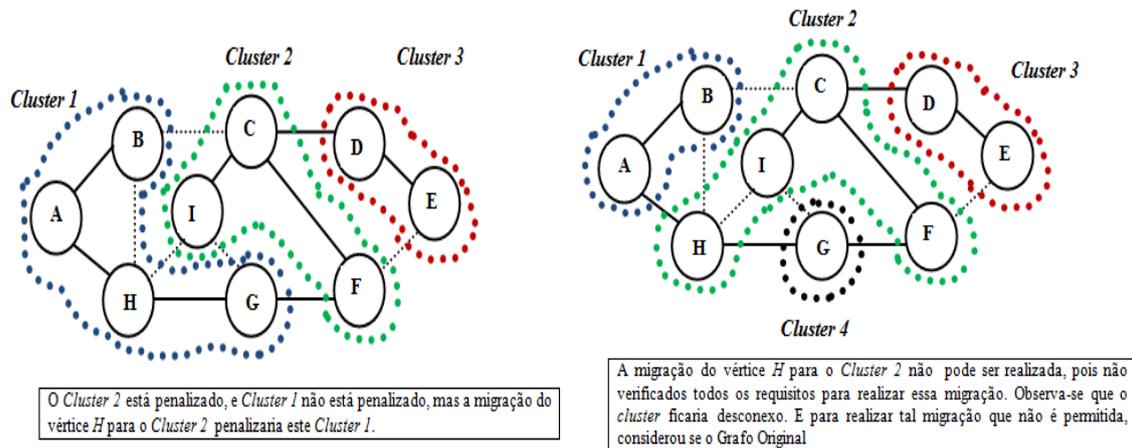


Figura 3.18 – Busca Local 2 – proibida a migração de vértices

3.2.3.3 BUSCA LOCAL 3

O procedimento de Busca Local 3 (três) também verifica a possibilidade de realizar migrações de vértices entre os *clusters* considerando o Grafo Original e a AGM construída. E assim como o Busca Local 2, verifica se as restrições de conexidade entre os vértices internos aos *clusters* estão sendo satisfeitas, ou seja, se os vértices internos aos *clusters* são conexos.

O Busca Local 3 (três) inicialmente seleciona, de forma aleatória, uma aresta $a = (i, j)$ de Grafo Original, antes da construção. A partir desta aresta, são efetuadas as verificações descritas abaixo, sendo que algumas são idênticas àquelas realizadas na Busca Local 2 (dois):

- Uma aresta é selecionada quando apenas um dos *clusters*, em que os vértices da aresta selecionada pertence, está penalizado. Em caso negativo, o algoritmo seleciona outra aresta também aleatoriamente;

- Os *clusters* podem atuar como receptores ou como doadores de vértices. Mas para isso, ambos os *clusters* não devem estar ou tornar-se penalizados. E as verificações são analisadas em ambos os sentidos.

- Mesmo com a migração de um vértice para o *cluster* receptor, os vértices do *cluster* doador devem continuar atendendo a restrição de conexidade;

- A migração de um vértice entre os *clusters* receptor e doador só é realizada quando é observada uma redução no valor da função objetivo.

3.2.3.4 BUSCA LOCAL 4

O procedimento de Busca Local 4 (quatro) utiliza uma lista de arestas removidas da AGM para geração de *clusters*. Dessa forma, esse procedimento busca melhorar a qualidade da solução, ou seja, minimizar a função objetivo através da união e da divisão de *clusters* já construídos.

São selecionados, aleatoriamente, os *clusters* aos quais os vértices das arestas removidas pertencem, podendo se unir em um *cluster* para, em seguida, este *cluster* ser dividido através da aplicação do procedimento construtor 1 (um).

A Figura 3.19 ilustra um exemplo da aplicação do Busca Local 4 (quatro) e suas respectivas explicações:

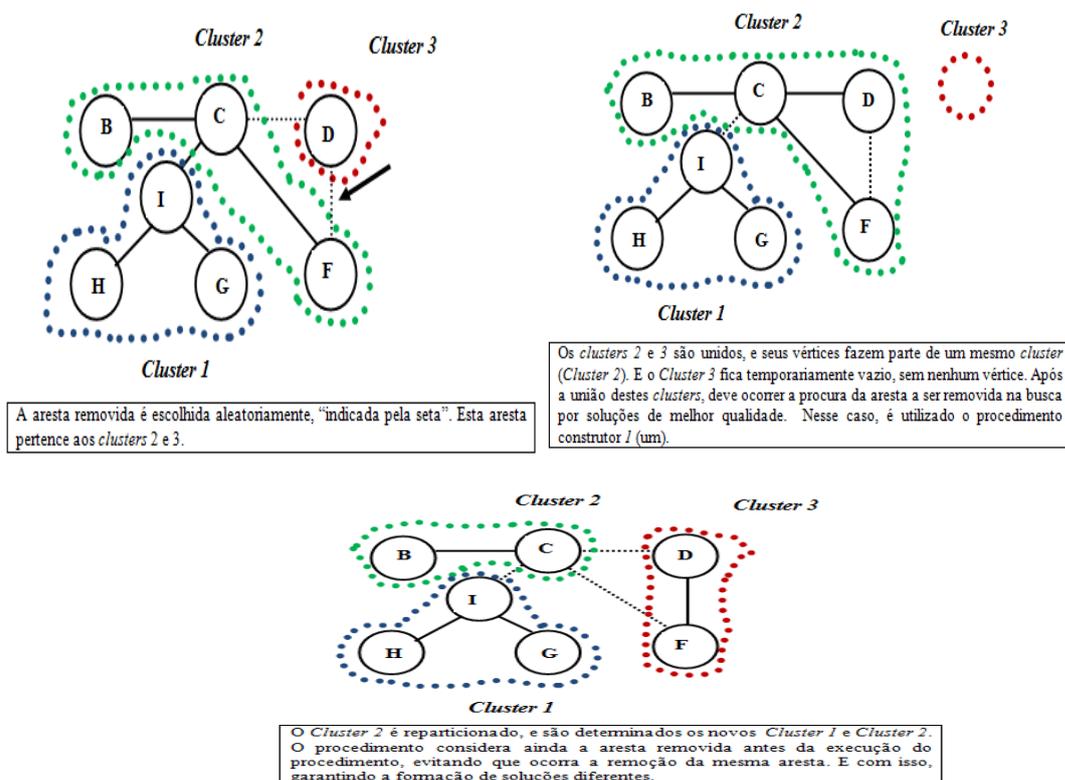


Figura 3.19 – Busca Local 4 - execução

3.2.3.5 BUSCA LOCAL 5

O procedimento de Busca Local 5 (cinco) é muito parecido com o procedimento de Busca Local 4 (quatro), e tem a finalidade de produzir novas soluções não penalizadas (que atendam a restrição de capacidade mínima), considerando a AGM.

Inicialmente, utiliza-se uma lista de arestas removidas da AGM para geração de clusters, escolhidas de forma aleatória, e depois realiza-se a união de dois *clusters*. Posteriormente, os *clusters* são divididos em dois novos *clusters* a partir de uma LRC composta pelas α arestas que, se removidas, definem novos *clusters*. Esses *clusters* devem atender a restrição de capacidade mínima e, simultaneamente, devem possuir a maior diferença, em valor absoluto, considerando o somatório das capacidades dos *clusters* obtidos, conforme Equação 16, a seguir:

$$Cap_{cl(A,B)} = |getTotal(get_{cluster}(A)) - getTotal(get_{cluster}(B))| \quad (16)$$

sendo:

- $Cap_{cl(A,B)}$ somatório da capacidade dos *cluster* e tem como objetivo maximizar o seu valor;
- A vértice do *cluster* X da AGM;
- B vértice do *cluster* Y da AGM;
- $getTotal(X)$ retorna o somatório das capacidades do *cluster* (X);
- $get_{cluster}(A)$ retorna o *cluster* em que está contido o vértice A ;
- $get_{cluster}(B)$ retorna o *cluster* em que está contido o vértice B ;

A Figura 3.20 apresenta um Grafo que é o resultado da união de dois *clusters*, o *Cluster 1* e do *Cluster 2*. Este grafo será usado para exemplificar o Procedimento de Busca Local 5 (cinco) com a restrição de capacidade mínima definida para este problema com o valor de 7 unidades.

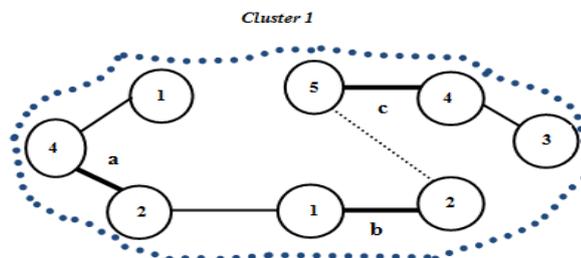


Figura 3.20 – Grafo da União do *Cluster 1* e *Cluster 2*

Na Figura anterior, cada vértice contém um número que corresponde a sua capacidade. As letras significam as arestas candidatas à remoção, e a linha pontilhada representa a aresta

removida da AGM que foi reinserida no Grafo para unir os *clusters* 1 e 2, gerando o único *Cluster* 1. Na figura 3.21 é ilustrada a remoção da aresta *a* (vide comentários).

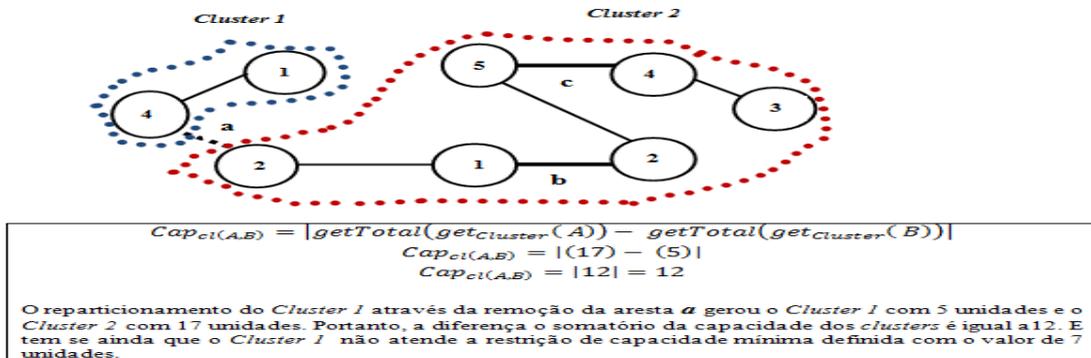


Figura 3.21 – Busca Local 5 - Remoção da aresta *a*

Na figura 3.22 é ilustrada a remoção da aresta *b* (vide comentários).

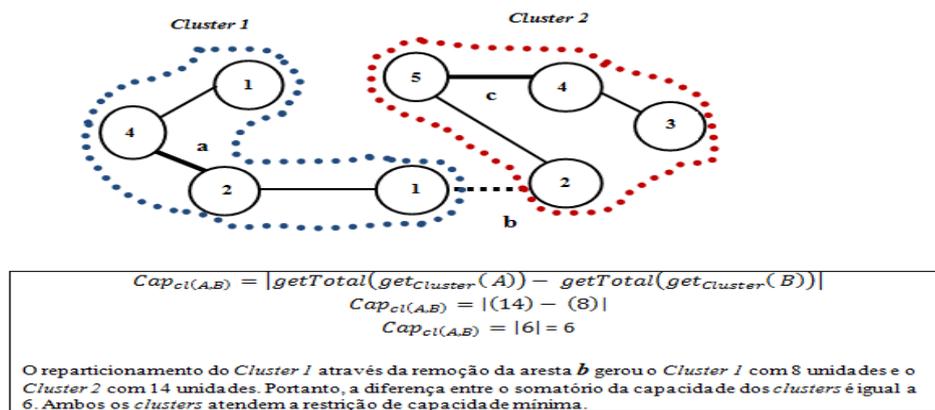


Figura 3.22 – Busca Local 5 - Remoção da aresta *b*

Na figura 3.23 é ilustrada a remoção da aresta *c* (vide comentários).

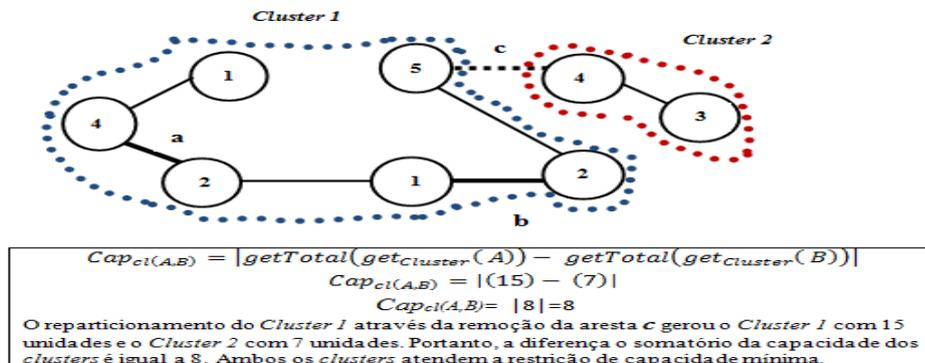


Figura 3.23 – Busca Local 5 - Remoção da aresta *c*

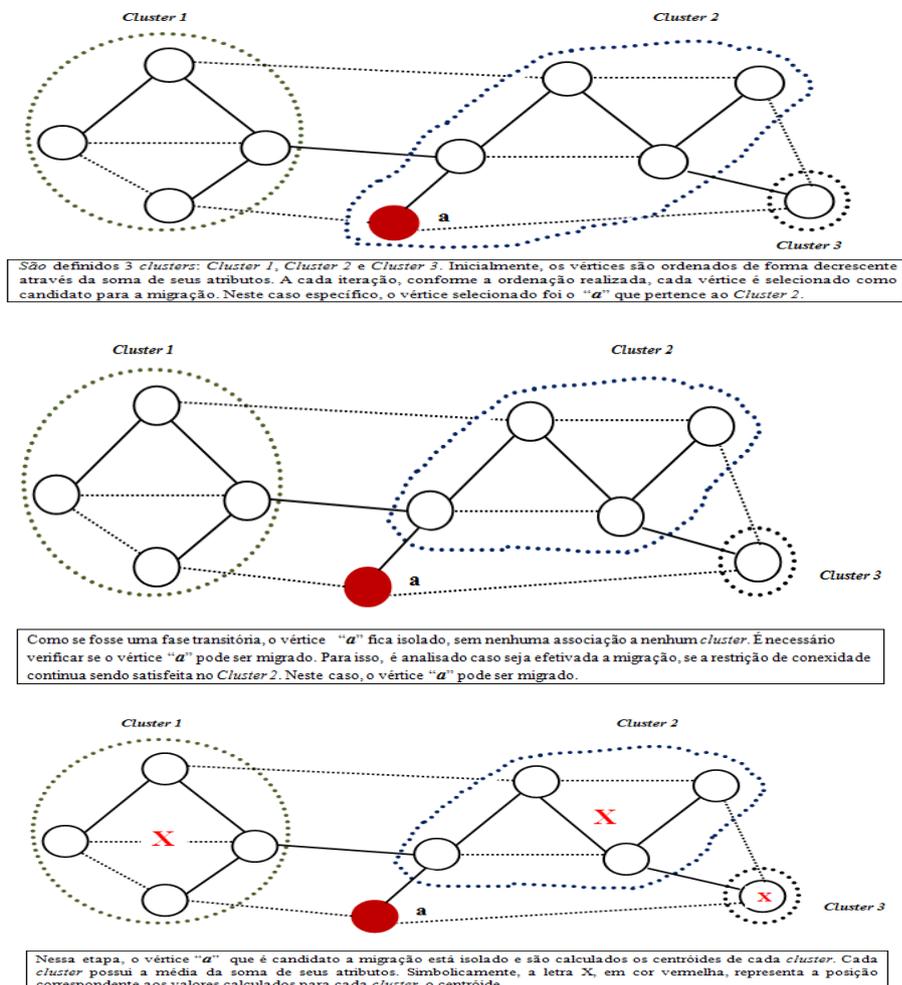
Analisando os exemplos das Figuras 3.21, 3.22 e 3.23, percebe-se que somente as arestas *b* e *c* podem fazer parte da LRC, uma vez que a remoção da aresta *a* irá gerar um *cluster* com penalidade. E, ainda objetivando maximizar o somatório das capacidades dos *clusters* obtidos, escolhe-se a aresta *c* por possuir valor igual a 8, enquanto a remoção da aresta *b* atingiu somente o valor de 6 unidades. Assim, são formados dois novos *clusters*.

3.2.3.6 BUSCA LOCAL 6

O Procedimento Busca Local 6 (seis) é aplicado essencialmente com o objetivo de minimizar a função objetivo da solução. Dessa forma, a migração dos vértices entre *clusters* é realizada tendo o Grafo Original como base somente se houver a melhoria da qualidade da solução.

Nesse Procedimento de Busca Local 6 (seis) o centroide de um cluster é utilizado e representa o ponto médio, ou seja, corresponde a média da soma de todos os atributos de um *cluster*.

A Figura 3.24 traz um exemplo da aplicação da Busca Local 6 (seis):



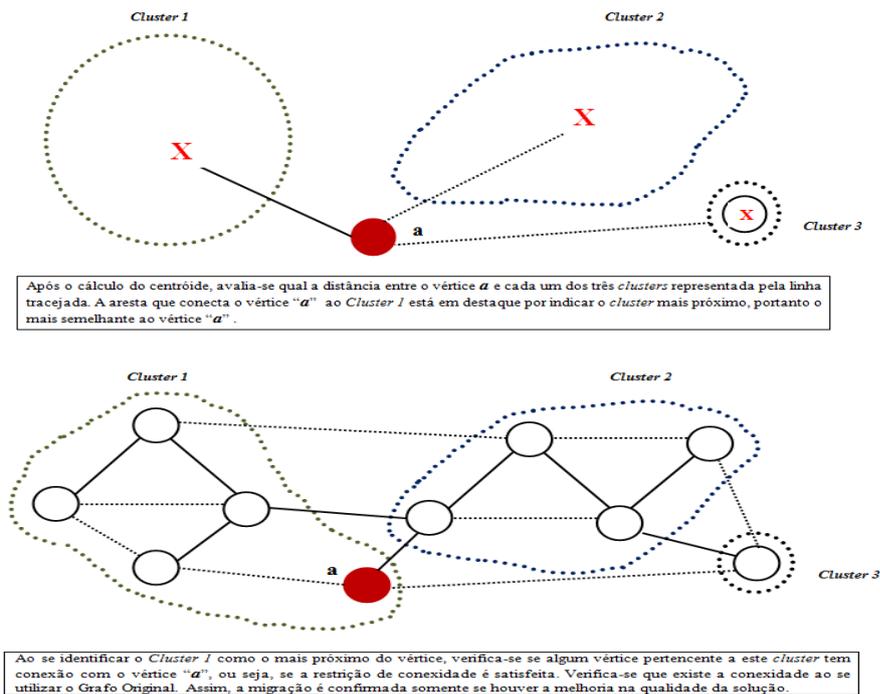


Figura 3.24 – Busca Local 6 – execução

3.3 ALGORITMOS HEURÍSTICOS PROPOSTOS

Os algoritmos heurísticos propostos neste trabalho de doutorado são o resultado de combinações da metaheurística GRASP com os procedimentos de construção das soluções iniciais (Construtor 1, Construtor 2, Construtor 3, Construtor 4 e Construtor 5), buscas locais (Busca Local 1, 2, 3, 4, 5 e 6) e com o procedimento de *Path-Relinking* (PR) (Reconexão por Caminhos (RC)) e um procedimento VND e RVND.

Também são descritas as combinações da metaheurística VNS e suas variações (GVNS, RVNS e *Skewed VNS*) com os procedimentos de construção das soluções iniciais e buscas locais as mesmas combinações já utilizadas na metaheurística GRASP.

3.3.1 PATH-RELINKING (PR)

O procedimento *Path-Relinking* (PR) (Reconexão por Caminhos (RC)) foi proposto inicialmente para compor a fase de diversificação da metaheurística *Scatter Search* [GLOVER AND LAGUNA, 1997]. Esse procedimento é baseado em uma estratégia de busca local que gera novas soluções, considerando a exploração de um “caminho que conecta” duas soluções extremas de boa qualidade. A RC tem início com a escolha de uma solução denominada Solução Base (SB) e, posteriormente, se constrói um caminho pelo espaço de soluções (vizinhanças) que a conecte até outra solução denominada Solução Guia (SG) gerando, assim, novos caminhos chamados de soluções (vizinhanças) intermediárias a cada movimento

executado. O fundamento básico da RC é a possível existência de soluções de boa qualidade no espaço que contém todas as soluções com elementos comuns das duas soluções SB e SG. Levando em consideração que o tamanho desse espaço é substancialmente grande, a RC explora as trajetórias entre as soluções SB e SG através de um procedimento guloso, onde a melhor solução encontrada no caminho é mantida. Em outras palavras, SB é modificada passo a passo até chegar a SG. Todas as soluções intermediárias obtidas em cada passo formam o caminho de SB até SG:

$$SB = S_0, S_1, \dots, S_z = SG \quad (17)$$

sendo z correspondente ao número de soluções intermediárias entre a solução SB e SG.

Portanto, a cada movimento, produz-se uma nova solução intermediária (SI) formada pelos elementos pertencentes à SB, e com a inserção de um atributo proveniente da SG, que substitui um dos elementos da SB original.

Esta solução intermediária é utilizada como a nova solução inicial no próximo passo da execução. Esse processo se repete, inserindo-se mais elementos da SG, até o momento em que será gerada uma solução idêntica à solução guia. Neste momento, considera-se a SG atingida, e a execução da RC para as soluções SB e SG é concluída [GLOVER E LAGUNA, 1997].

Na verdade, a RC aqui proposta trabalha com uma solução guia que vem do conjunto elite (*pool* das e melhores soluções distintas geradas pela metaheurística até o momento) e uma solução base que corresponde à solução resultante da busca local da iteração corrente. A partir destas duas, são produzidas as soluções intermediárias com o potencial de contribuir, de forma mais significativa, que as demais no processo de exploração de novas soluções de alta qualidade.

E que através de uma sequência de soluções geradas (soluções intermediárias), que derivam delas, possa encontrar uma solução vizinha melhor que as já conhecidas, ou seja, que possam produzir um ótimo local de qualidade superior aos ótimos locais encontrados até o presente momento [HO AND GENDREAU, 2006]. O conjunto elite é uma estrutura de dados na qual se armazena uma quantidade limitada de soluções. Estas soluções podem contribuir de forma mais significativa que as demais no processo de exploração de novas soluções de alta qualidade [HO AND GENDREAU, 2006].

São diversas as abordagens de Reconexão por Caminhos encontradas na literatura. São descritas algumas dessas abordagens [RESENDE E RIBEIRO, 2002]:

- reconexão periódica: a reconexão por caminhos não é aplicada sistematicamente, mas apenas periodicamente;
- reconexão *forward*: a solução escolhida como guia é a melhor entre duas selecionadas para a reconexão;
- reconexão *backward*: a solução escolhida como guia é a pior entre as duas selecionadas para a reconexão (*abordagem utilizada neste trabalho*);
- reconexão *back and forward*: são exploradas os dois caminhos separadamente, primeiro no sentido *forward* e depois no *backward*;
- reconexão mista: são explorados simultaneamente os dois caminhos (*forward* e *backward*), até que se encontre em uma solução intermediária equidistante das duas soluções iniciais.

Há, ainda, dois aspectos fundamentais nos quais se baseia a utilização do procedimento de reconexão por caminhos, quais sejam: a intensificação, que consiste na concentração da busca por outras soluções em regiões promissoras do espaço de possíveis soluções, e a diversificação, que caracteriza a exploração de áreas mais diversas no espaço de soluções [GREISTORFER, 2004].

Uma vez que a aplicação do procedimento de Reconexão de Caminhos pode demandar uma substancial quantidade de tempo computacional de execução, tal procedimento deve ser utilizado com parcimônia, quando inserido em uma metaheurística. No que concerne ao GRASP, este procedimento pode ser aplicado a cada m iterações consecutivas do GRASP. Para tanto, as e melhores soluções que foram obtidas após as m iterações do GRASP são armazenadas em um conjunto denominado conjunto elite. Ou seja, a cada m iterações toma-se como solução base (SB) a solução produzida após a busca local do GRASP, e toma-se como solução guia (SG) uma solução escolhida aleatoriamente do conjunto elite. Em seguida aplica-se o procedimento de RC nestas duas soluções e toma-se a Melhor Solução Intermediária (MSI). Se esta solução for melhor do que a melhor solução atual, atualiza-se esta solução. Além disso, verifica-se se a MSI é melhor do que alguma solução do conjunto elite, e novamente, se esta condição for satisfeita, atualiza-se o conjunto elite.

3.3.2 GRASP com RECONEXÃO DE CAMINHOS

Uma das formas de incorporar um mecanismo de memória adaptativa no GRASP é com o procedimento de Reconexão de Caminhos [GLOVER, 1996][GLOVER AND MARTI, 2006]. O objetivo do GRASP com RC é encontrar soluções intermediárias de melhor qualidade, que estejam entre as duas soluções, do GRASP e do conjunto elite [LAGUNA

AND MARTI, 1999]. O GRASP com RC foi aplicado com sucesso em diversos trabalhos relatados na literatura, dentre os quais os [FESTA ET. AL, 2007][MATEUS ET. AL, 2011][BASTOS ET. AL, 2005].

Neste trabalho, o GRASP com RC foi implementado utilizando as mesmas configurações da fase de construção e da fase de busca local utilizadas pelo GRASP na sua forma padrão, não sendo necessárias alterações nessas estruturas. O RC utilizou como técnica de otimização a abordagem *backward*, que é aplicada da melhor solução (Solução Base) para a pior solução (Solução Guia). A SB é obtida da iteração atual do GRASP, enquanto a SG é uma solução selecionada do conjunto elite.

No que diz respeito ao procedimento de RC implementado neste trabalho, a cardinalidade do conjunto elite foi definida como quatro e cada solução intermediária foi estabelecida a partir de uma migração dos vértices entre *clusters* da AGM ou do Grafo Original. Ao se construir uma solução intermediária, há o objetivo em minimizar o valor de uma função objetivo e, simultaneamente, produzir soluções válidas, ou seja, que satisfaçam as restrições de conectividade e de capacidade mínima do problema de clusterização em questão.

A estratégia para escolher as soluções que irão pertencer ao conjunto elite é a seguinte: inicialmente, este conjunto encontra-se vazio, mas a cada iteração do GRASP, uma solução é gerada e inserida neste conjunto. Quando o conjunto elite já está completo, a solução gerada na atual iteração do GRASP é inserida neste conjunto, caso o seu custo (função objetivo) seja menor que o custo da solução de pior qualidade do conjunto elite. Depois de verificada essa condição, necessita-se saber qual será a solução que deve ser retirada do conjunto elite. Caso seja observado que o custo da solução que deseja entrar no conjunto elite é inferior a pelo menos, a solução de maior custo já armazenada no repositório do conjunto elite, a nova solução é inserida e a solução de maior custo é retirada.

Neste trabalho, a atualização do conjunto elite, bem como a aplicação do RC, ocorrem quando a iteração do GRASP é múltipla de 10 ou quando 25% do conjunto elite for atualizado desde a última ativação (mas a primeira ativação se dá, obrigatoriamente, após a iteração 10). O processo termina quando são atingidas 100 iterações do GRASP.

3.3.3 VARIABLE NEIGHBORHOOD DESCENT (VND) OU DESCIDA EM VIZINHANÇA VARIÁVEL

Variable Neighborhood Descent ou Método de Descida em Vizinhança Variável (VND) é uma estratégia de refinamento de vizinhanças. O que difere a estratégia VND do método de busca local tradicional é que, ao invés de utilizar uma única estrutura de vizinhança,

considera-se mais de uma vizinhança. Ao atingir um ótimo local com relação à vizinhança atual, é iniciada uma nova busca local empregando outra vizinhança.

O algoritmo termina quando a solução corrente é um ótimo local de melhor qualidade em relação aos ótimos explorados em todas as vizinhanças empregadas. Portanto, as vizinhanças estendidas possibilitam a busca por soluções de melhor qualidade que estão “*mais distantes*” da solução atual. Tal procedimento permite ao método escapar de ótimos locais de baixa qualidade com respeito a uma vizinhança menor [HANSEN AND MLADENOVIC 2003].

A estrutura do VND é de fácil implementação e os seus componentes de vizinhanças podem ser alterados de forma a aumentar ou diminuir a sua complexidade para ter compromisso entre qualidade de solução e tempo computacional [CHAVES AND LORENA 2005].

O método VND [MLADENOVIC 1995] [MLADENOVIC AND HANSEN 1997] tem como característica a exploração do espaço de soluções através de trocas sistemáticas de estruturas de vizinhanças. Os autores se inspiraram em três princípios ao idealizar este método:

1° - Um ótimo local com relação a uma estrutura de vizinhança não é necessariamente um ótimo local relativo à outra estrutura de vizinhança;

2° - Um ótimo global é um ótimo local com relação a todas as possíveis estruturas de vizinhanças;

3° - Para muitos problemas, ótimos locais com relação a uma ou mais estruturas de vizinhanças são relativamente próximos.

O último princípio, segundo os autores, traz uma observação importante de natureza empírica. Mais especificamente, indica que um ótimo local frequentemente fornece algum tipo de informação sobre o ótimo global. Esse é o caso em que os ótimos local e global compartilham muitas variáveis com o mesmo valor, o que induz uma investigação sistemática da vizinhança de um ótimo local até a obtenção de uma nova solução de melhor valor.

São várias as aplicações de metaheurísticas híbridas utilizam como busca local o VND para solucionar problemas de otimização combinatória, sejam elas: Problema do Caixeiro Viajante com Coleta de Prêmios [CHAVES AND LORENA 2005], *Traveling Purchaser Problem* [SILVA ET AL 2000] e Problema do Caixeiro Viajante com Coleta e Entrega de uma Comodidade [HERNÁNDEZ-PÉREZ ET AL 2009].

A partir de uma solução inicial s , uma solução vizinha $s' \in N^v(s)$ é obtida pela aplicação de uma operação de movimento, sendo v corresponde ao número de vizinhanças

(vide figura 3.25). No caso do problema abordado neste trabalho, essa operação corresponde a mover alguns vértices de um *cluster* $C_i \in s$ para outro *cluster* $C_j \in s$. Um movimento corresponde à atribuição de todos os vértices de s para outro *cluster* C_j . Para cada atribuição, teremos uma nova solução que será uma solução vizinha de s .

Neste trabalho foram consideradas seis estruturas de vizinhanças, a saber: N^1 , N^2 , N^3 , N^4 , N^5 e N^6 .

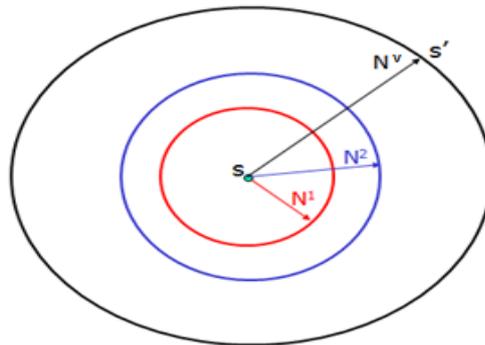


Figura 3.25 – VND com $N^v(s)$ vizinhança

- Busca na vizinhança N^1 : nessa estrutura de vizinhança, um vizinho é gerado a partir de uma lista de arestas removidas da AGM e de uma lista de *clusters* penalizados. Através do VND verifica-se a possibilidade de realizar migrações de vértices entre os *clusters* utilizando estas listas. Neste caso, são respeitadas as restrições de conexidade e de capacidade mínima por *cluster*.

- Busca na vizinhança N^2 : nessa estrutura de vizinhança, verifica-se a possibilidade de realizar migrações de vértices entre os *clusters* considerando o Grafo Original. Parte-se de um Grafo Original para verificar se as restrições de conexidade entre os vértices internos aos *clusters* são satisfeitas.

- Busca na vizinhança N^3 : essa estrutura de vizinhança é muito similar à estrutura de vizinhança N^2 , uma vez que também verifica a possibilidade de realizar migrações de vértices entre os *clusters* e considera o Grafo Original. E, assim como a estrutura da vizinhança N^2 , é verificado se os vértices internos dos *clusters* estão conexos.

- Busca na vizinhança N^4 : a estrutura de vizinhança N^4 utiliza uma lista de arestas removidas da AGM para geração de um *cluster*. O VND procura por vizinhos que melhorem a solução através da união e da divisão de *clusters* já construídos.

- Busca na vizinhança N^5 : a estrutura de vizinhança N^5 considera a AGM e é similar a vizinhança N^4 . Difere apenas por buscar novas soluções não penalizadas, que atendam a restrição de capacidade mínima.

- Busca na vizinhança N^6 : o VND na estrutura de vizinhança N^6 procura minimizar a função objetivo da solução através da migração dos vértices entre *clusters* que é realizada utilizando o Grafo Original.

Neste trabalho, As vizinhanças N^1, N^2, N^3, N^4, N^5 e N^6 são integradas na busca local do GRASP usando o algoritmo VND, ou seja, N^1 corresponde a Busca Local 1, N^2 corresponde a Busca Local 2, N^3 corresponde a Busca Local 3, N^4 corresponde a Busca Local 4, N^5 corresponde a Busca Local 5 e N^6 corresponde a Busca Local 6.

Primeiramente, são investigados todos os possíveis movimentos da vizinhança N^1 que levam a uma solução que seja um mínimo local de melhor qualidade nesta vizinhança. Quando este mínimo local for alcançado, parte-se para a investigação de soluções na vizinhança N^2 que seja o mínimo local da vizinhança em N^2 . Posteriormente, retorna-se à investigação de soluções na vizinhança N^1 para garantir o seu mínimo local entre N^1 e N^2 .

O mesmo procedimento é realizado incluindo-se as vizinhanças N^3, N^4, N^5 e N^6 até que não existam mais movimentos em nenhuma das vizinhanças que diminuam o custo da solução. Portanto, o VND assegura que o mínimo local obtido não corresponde apenas à melhor solução encontrada para uma vizinha, mas sim o a melhor solução dentre todas as 6 (seis) vizinhanças pré-estabelecidos pelo problema definido nesta tese.

3.3.4 GRASP com VND

A estratégia VND (*Variable Neighborhood Descent*) ou Método de Descida em Vizinhança Variável foi inicialmente introduzida no método GRASP para o problema de Steiner em grafos, com soluções de acordo com a estratégia gulosa randomizada do método. Nele, a hibridização foi feita substituindo-se a busca local por uma estratégia VND que explorava duas estruturas de vizinhanças [RIBEIRO E VIANA 2005]. A metaheurística GRASP também foi combinada a uma estratégia de VND para o problema da árvore geradora mínima com restrição de grau [RIBEIRO E SOUZA 2002]

Assim, propõe-se, neste trabalho, utilizar o VND com um módulo de busca local a ser incorporado à metaheurística GRASP para o problema de clusterização de grafos com restrição de capacidade e conexidade.

O objetivo do VND é identificar os clusters que garantam as restrições de conectividade e capacidade mínima através de uma intensificação da busca por melhor solução na primeira, na segunda, na terceira, na quarta, na quinta e na sexta vizinhança do *cluster*.

O algoritmo 3 mostra o pseudo-código do algoritmo GRASP com VND implementado neste trabalho:

<p>Algoritmo 3: GRASP com VND</p> <p>Entrada: Grafo $G = (A, V)$</p> <ol style="list-style-type: none"> 1. melhorSolução $\leftarrow 0$; 2. solução \leftarrow AlgoritmoConstrução; 3. melhorSolução \leftarrow VND (solução); <p>Saída: melhorSolução.</p>

Figura 3.26 – Pseudo-código do algoritmo GRASP com VND

Inicialmente, tem-se como entrada para a execução da metaheurística GRASP com VND o Grafo com seus vértices e suas arestas.

Linha 1 inicializa-se a variável melhor Solução com o valor 0 (zero), variável está que irá receber o melhor resultado do GRASP.

Linha 2: é construída uma solução inicial para o problema;

Linha 3: realizada uma busca local - VND na solução inicial;

A saída do algoritmo GRASP com VND é a melhor solução encontrada.

3.3.5 RANDOM VARIABLE NEIGHBORHOOD DESCENT (RVND) OU DESCIDA EM VIZINHANÇA VARIÁVEL COM ORDEM ALEATÓRIA

Random Variable Neighborhood Descent (RVND) ou Método de Descida em Vizinhança Variável com Ordem Aleatória [SUBRAMANIAN ET AL 2010] é uma variação do método *Variable Neighborhood Descent* (VND) ou Método de Descida em Vizinhança Variável [MLADENOVIC AND HANSEN, 1997].

O método VND Clássico [HANSEN ET AL 2010] trabalha com um conjunto de vizinhanças previamente ordenadas, já o RVND utiliza uma ordem aleatória de vizinhanças a cada execução. Essa é uma vantagem, uma vez que não é necessário fazer testes para descobrir qual a melhor ordem [PENNA ET AL, 2011].

A estrutura do RVND é simples de implementar, ao invés de usar uma sequência determinística de vizinhanças para explorar o espaço de soluções, utiliza-se uma ordem aleatória a cada execução. Assim, sempre que em uma determinada vizinhança não for

possível melhorar a solução corrente, o RVND seleciona, aleatoriamente, outra vizinhança para continuar a busca pelo espaço de soluções [SUBRAMANIAN ET AL 2010].

Então, sendo $N = \{N^1, N^2, N^3, \dots, N^v\}$ o total de vizinhanças, o RVND selecionará aleatoriamente a ordem em que estas estruturas N^v s serão executadas.

Neste trabalho foram consideradas como estruturas de vizinhanças as mesmas definidas no VND, ou seja, seis estruturas de vizinhanças, quais sejam: N^1, N^2, N^3, N^4, N^5 e N^6 .

3.3.6 GRASP com RVND

A estratégia RVND (*Random Variable Neighborhood Descent*) ou Método de Descida em Vizinhança Variável com Ordem Aleatória foi utilizado com a metaheurística GRASP, inicialmente, em Souza et. al, 2010, para resolver o problema de planejamento operacional da mineração em céu aberto, com alocação dinâmica de caminhões.

Neste trabalho, o RVND foi incorporado ao GRASP como um módulo de busca local, sendo que a escolha da mesma acontece de forma aleatória. Mais especificamente, o RVND tem sua aplicação dentro do GRASP condicionada à busca por melhores soluções nas vizinhanças dos *clusters*, ou seja, age na intensificação das soluções do GRASP.

3.3.7 VARIABLE NEIGHBORHOOD SEARCH (VNS) OU BUSCA EM VIZINHANÇA VARIÁVEL

Em 1997, Hansen e Mladenović propuseram uma metaheurística que se baseava em uma troca sistemática de vizinhanças, associada a um algoritmo aleatório na determinação de pontos iniciais da busca local, chamada de Busca em Vizinhança Variável, conhecida na literatura em inglês como *Variable Neighborhood Search* (VNS). Contrariamente a outras metaheurísticas baseadas em métodos de busca local, o VNS não segue uma trajetória, mas explora incrementalmente vizinhanças mais ou menos distantes da solução corrente, partindo da solução atual para a nova se, e somente se, uma melhora ocorrer. Portanto, é baseada num princípio simples: explorar o espaço de soluções através de trocas sistemáticas de estruturas de vizinhanças durante o processo de busca [MLADENOVIC AND HANSEN, 1999] [MLADENOVIC AND HANSEN, 2001d].

Diferentemente de outras metaheurísticas, a estrutura do VNS básico e suas extensões são simples e requerem poucos, e às vezes nenhum parâmetro. Sua disseminação foi rápida, com inúmeras publicações [HANSEN ET AL, 2001] [HANSEN AND MLADENOVIC,

2001a] [HANSEN AND MLADENOVIC, 2001b] [HANSEN AND MLADENOVIC, 2002] [HANSEN AND MLADENOVIC, 2003a] [HANSEN AND MLADENOVIC, 2003b].

Uma característica importante do VNS é que este método aceita somente movimentos de melhora da solução e sempre que isto ocorre, ele retorna à primeira vizinhança. A ideia intrínseca a este método é explorar uma vizinhança ao máximo, enquanto resultados satisfatórios forem sendo obtidos.

O VNS possui um procedimento de perturbação que possui a finalidade de diversificação da solução a fim de evitar a ciclagem (retorno sistemático ao mínimo local anteriormente alcançado) do algoritmo. A cada iteração, uma solução vizinha da solução inicial é escolhida aleatoriamente e servirá de base para a execução da busca local.

O algoritmo VNS trabalha com várias vizinhanças. Portanto, seja N_v o conjunto finito de estruturas de vizinhanças pré-selecionadas, com $(v = 1, \dots, v_{max})$ e $N_v(s)$ o conjunto de soluções na v -ésima vizinhança de s . Além do conjunto N_v de vizinhanças, usa-se a função de avaliação f , a ser minimizada. Uma solução ótima s (ótimo global) é uma solução viável de tal maneira que para cada solução viável $s' \in S$, tem-se que $f(s) < f(s')$.

Uma ilustração (Figura 3.27) do VNS pode ser vista no Algoritmo 4.

Algoritmo 4: VNS	
Entrada: Grafo $G = (A, V)$	
1.	Inicialização: selecionar o conjunto de estruturas de vizinhanças $N_v (v=1, \dots, v_{max})$ que serão usadas na busca; Encontrar uma solução inicial s e Escolher um critério de parada;
2.	Enquanto (<i>critério de parada não satisfeito</i>) faça
3.	$v \leftarrow 1$;
4.	Enquanto ($v \leq v_{max}$) faça
5.	Perturbação (<i>shaking</i>): gerar aleatoriamente uma solução s' na v -ésima vizinhança de s ($s' \in N_v(s)$);
6.	Busca Local: aplicar um método de busca local em s' , obtendo um ótimo local s'' ;
7.	Mover ou não: Se o ótimo local s'' é melhor que o atual, ou seja, $f(s'') < f(s)$ então
8.	Mover para lá ($s \leftarrow s''$),
9.	Ir para a próxima vizinhança ($v \leftarrow v+1$); Senão
10.	Passar para a próxima vizinhança ($v \leftarrow v+1$); fimSe
	fimEnquanto
	fimEnquanto
Saída: melhorSolução	

Figura 3.27 – Pseudo-código do algoritmo VNS

A seguir, tem-se uma explicação do algoritmo VNS.

3.3.7.1 ALGORITMO VNS

O algoritmo VNS proposto nesta tese é composto por duas fases, a saber: Na primeira fase é construída uma Árvore Geradora Mínima (AGM) e, em seguida, realizado o seu particionamento em n *clusters* de forma que satisfaça às restrições de conexidade e capacidade tratadas neste trabalho. A segunda fase é caracterizada pela aplicação de um procedimento VNS na solução com menor valor de função objetivo (Equação 7) resultante da etapa anterior.

A partir de uma solução inicial s , uma solução vizinha $s' \in N^v(s)$ é obtida pela aplicação de uma operação de movimento, sendo v correspondente ao número de vizinhanças.

Assim como foi utilizado na metaheurística GRASP, define-se o Grafo Original (G) considerando as informações existentes na base de dados utilizada (Censo Demográfico 2010) definindo dessa forma os seus vértices e arestas existentes. Aplica-se o algoritmo de *Kruskal* para se construir a AGM T com custo mínimo. A geração da AGM implica geração de um ótimo local para o problema, uma vez que o valor da função objetivo calculado em cada *cluster*, escolhendo-se seu valor em função da distância de cada um dos vértices aos centróides (média dos vértices em relação aos atributos).

Parte-se da premissa de que a AGM corresponde a um único *cluster*. Então, inicia-se o particionamento da AGM, onde cada aresta que for eliminada irá dividir a árvore em duas novas subárvores, ou seja, dois *clusters* (Construtor 1, Construtor 2, Construtor 3, Construtor 4 ou Construtor 5). Assim, deve-se, particionar a AGM obtendo como resultado k grafos conexos (*clusters*). E assim sucessivamente, até que não seja mais possível encontrar uma aresta que, ao ser removida, produza *clusters* com capacidade maior ou igual a um valor mínimo já pré-estabelecido.

Ao se concluir essa primeira etapa do algoritmo VNS, são produzidas $n + 1$ soluções iniciais s , dentre estas, seleciona-se a solução com menor valor associado à função objetivo. Então, calcula-se a distância de cada um dos vértices V que compõe o *cluster* ao seu respectivo centroide. Coloca-se, em ordem crescente as distâncias obtidas nas vizinhanças Busca Local 1 (Vizinhança 1), Busca Local 2 (Vizinhança 2), Busca Local 3 (Vizinhança 3), Busca Local 4 (Vizinhança 4), Busca Local 5 (Vizinhança 5) e Busca Local 6 (Vizinhança 6). Sortear um grupo doador dentro os k grupos (subárvores) *clusters*, atribuindo maior chance de seleção aos grupos cujos soma das distâncias dos setores (vértices) são maiores. Em seguida, selecionar t objetos doadores na Vizinhança N_l e tentar realocá-los a um dos $(k - 1)$ grupos

receptores, de forma a produzir a maior redução possível na função objetivo. Se houver redução na função objetivo, continua-se em N_1 , senão alterna-se para N_2 , e assim sucessivamente, enquanto não obtiver resultado melhor. O objetivo principal é possibilitar aos objetos mais distanciados do centroide uma maior chance de mudar de *cluster*.

Posteriormente, deve-se definir o número de vizinhanças do VNS, que no caso deste trabalho segue as mesmas estruturas vizinhanças definidas na Seção 3.3.3.

O procedimento de perturbação é semelhante ao Procedimento de Busca Local 1, porém com o objetivo de perturbar a solução, evitando que esta fique estagnada em ótimos locais de baixa qualidade e regenerando possíveis soluções inválidas que tenham sido eliminados pelos outros procedimentos de busca local. A Figura 3.28 ilustra um exemplo da aplicação do Procedimento de Perturbação e suas respectivas explicações:

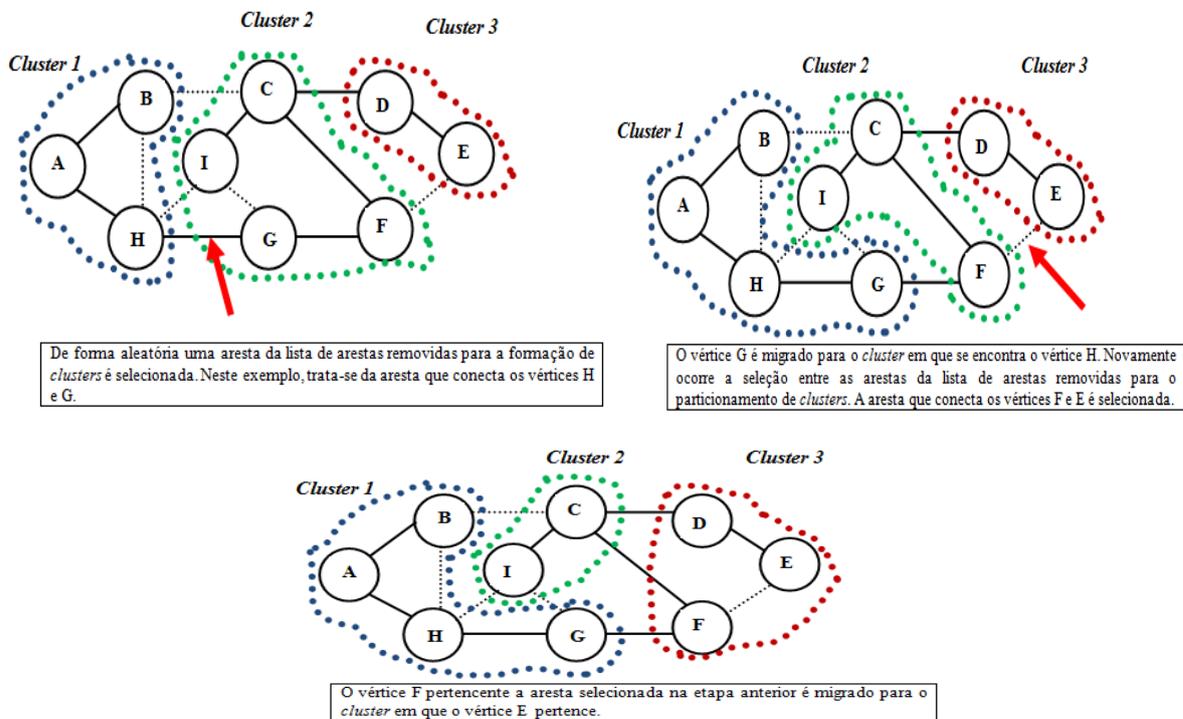


Figura 3.28 – Procedimento de Perturbação

O procedimento de Perturbação procura selecionar os x vértices do cluster doador na vizinhança N^l e tentar realocá-los a um dos $(k - 1)$ *clusters* receptores, de forma a tentar reduzir o valor da função objetivo, conforme Figura 3.28

A finalidade desta etapa é produzir soluções $s' \in N^v(s)$ de qualidade superior à solução s . Caso haja redução no valor da função objetivo, deve-se permanecer em N^l a procura de melhores resultados, senão, troca-se de vizinhança, e assim sucessivamente, até

que o critério de parada seja satisfeito, sempre utilizando o procedimento de perturbação em cada vizinhança.

Em [HANSEN AND MLADENOVIC 2001a] foram propostas várias extensões da VNS e em [HANSEN AND MLADENOVIC 2003a] é descrito um tutorial sobre VNS, incluindo também várias extensões, exemplos e questões em relação à implementação. Na literatura aparecem diversas formas de estender a VNS, às quais geralmente são acrescentadas algumas características adicionais. A evolução da VNS pode ser vista nas Seções a seguir.

3.3.8 GENERAL VARIABLE NEIGHBORHOOD SEARCH (GVNS) OU BUSCA GERAL EM VIZINHANÇA VARIÁVEL

A estratégia GVNS (*General Variable Neighborhood Search*) ou Busca Geral em Vizinhança Variável é inspirada na ideia de buscar boas soluções por meio de estruturas de vizinhanças diferentes. Um algoritmo similar ao desenvolvido neste trabalho já existe na literatura com bons resultados [SOUZA ET AL 2010]. Ele foi utilizado para resolver o Problema de Planejamento Operacional de Lavra em Minas a Céu Aberto, produzindo soluções viáveis e competitivas quando comparadas com as soluções do modelo de programação matemática executado pelo *CPLEX*. A metaheurística GVNS, pode ser dividida em duas fases, a saber: perturbação e busca local. Na fase de perturbação, o algoritmo gera uma solução aleatória em uma dada vizinhança (exploração estocástica das estruturas de vizinhança) e na fase de busca local, é aplicado o método VND.

O algoritmo GVNS baseia-se nos critérios de busca local em torno de uma solução corrente com intuito de explorar novas regiões, o que é análogo ao algoritmo VNS. No entanto, a diferença fundamental está na fase de melhoria da busca local usando o VND. O GVNS tem sido um dos métodos que mais obteve êxito recentemente, por exemplo, analisando os trabalhos de [ANDREATA E RIBEIRO 2002] [BRINBERG ET AL 2000] [CAPOROSSO ET AL 1999] [CAPOROSSO E HANSEN 2000] [RIBEIRO E SOUZA 2002].

O algoritmo GNVS aplicado ao problema tratado neste trabalho segue os mesmos passos implementados no algoritmo VNS, com mesmas estruturas de vizinhanças utilizadas neste, diferindo apenas na busca local onde foi aplicado um VND.

3.3.9 REDUCED VARIABLE NEIGHBORHOOD SEARCH (RVNS) OU BUSCA REDUZIDA EM VIZINHANÇA VARIÁVEL

Uma redução da busca em vizinhança variável original foi também proposta por Mladenovic 1997, gera uma solução inicial sem executar uma busca local nessa solução, já se

direcionada à exploração das estruturas de vizinhanças [MLADENOVIC AND HANSEN 1997]. Tal fato pode melhorar o tempo do algoritmo VNS em casos em que um método de busca local tem um custo computacional muito elevado. Essa redução é chamada *Reduced Variable Neighborhood Search* (RVNS).

Esse tipo de algoritmo VNS chamado de RVNS [MARTINS 2009] é inspirado em dois aspectos fundamentais no processo de busca relacionados com a intensificação e a diversificação.

No algoritmo RVNS um conjunto de estruturas de vizinhanças N_v ($v=1, \dots, v_{max}$) será considerado ao redor da solução atual s (o qual pode ser ou não um ótimo local). Geralmente essas vizinhanças estão aninhadas, isto é, os elementos da vizinhança N_1 também são elementos na vizinhança N_2 e assim sucessivamente.

Deve-se observar que o algoritmo RVNS (Figura 3.29) produz uma escolha de vizinhos mais dinâmica a partir da seleção de vizinhos de todas as estruturas de vizinhança (diversificação) e priorizando a primeira estrutura de vizinhança (intensificação) nas fases iniciais da busca. Entretanto, uma componente importante da estrutura RVNS é a capacidade de encontrar novas regiões promissoras a partir de um ótimo local.

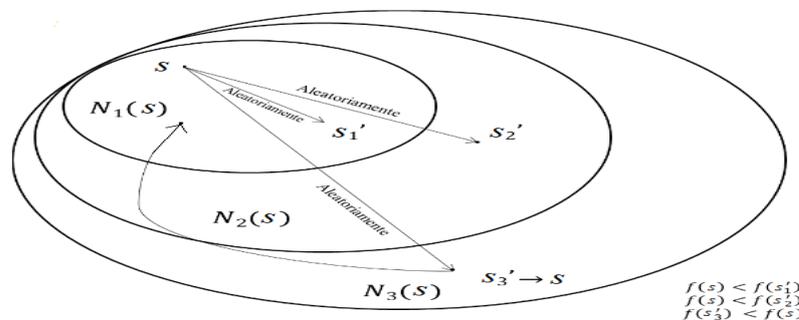


Figura 3.29 – Comportamento do RVNS com três vizinhanças

Adaptado de Souza, 2011.

Observa-se que o algoritmo RVNS aplicado ao problema tratado neste trabalho segue os mesmos passos do algoritmo VNS, utilizando até as mesmas estruturas de vizinhanças.

3.4.0 SKEWED VARIABLE NEIGHBORHOOD SEARCH (SVNS) OU BUSCA INCLINADA EM VIZINHANÇA VARIÁVEL

Ao assumir vizinhanças cada vez maiores, as soluções geradas aleatoriamente podem diferenciar-se substancialmente da solução atual, e por isso, o VNS se degenera em uma

heurística de partidas múltiplas (no sentido de que se realizam, interativamente, descidas com soluções geradas aleatoriamente). Além disso, se a solução corrente não está no vale mais profundo, esta informação é em parte irrelevante. [LIN AND KERNIGHAN 1973] [HANSEN AND MLADENOVIC 2000]. Seria, então, interessante modificar o esquema do VNS para explorar melhor aqueles vales que estão mais longe da solução incumbente. Isto pode ser feito aceitando realizar um movimento para uma solução de valor próximo da incumbente atual, mas não necessariamente melhor, desde que esta solução esteja longe da incumbente [VANSTEENWEGEN AND SOUFFRIAU 2009] [VANSTEENWEGEN AND SOUFFRIAU 2009] [VANSTEENWEGEN ET AL 2010]. Para lidar com esses casos, surgiu uma nova variantes do VNS, o algoritmo *Skewed Variable Neighborhood Search* (SVNS) ou Busca Inclinada em Vizinhança Variável.

O SVNS introduz uma função que controla a distância entre as soluções produzidas (métrica dentro das estruturas de vizinhança).

3.4.0.1 ALGORITMO SVNS

O algoritmo SVNS que será apresentado a seguir é composto por duas fases, ou seja, segue o mesmo esquema do algoritmo VNS (Seção 3.3.7.1) com algumas peculiaridades a serem abordadas a seguir:

Na etapa da Agitação (*shaking*) deve-se sortear, assim como no método de seleção da roleta utilizado nos algoritmos genéticos, um *cluster* com probabilidade inversamente proporcional ao valor da função objetivo, ou seja, atribuindo maior chance de escolha aos *clusters* cujas somas das distâncias dos vértices aos respectivos centroides sejam maiores.

Uma vez definida o *cluster*, logo em seguida, definir a vizinhança, no caso deste trabalho igual a três. O $k = 3$, e como já se sabe que quais vértices pertencem a quais *clusters*, pode-se determinar a distância (em ordem crescente) de cada um dos objetos aos centroides:

- seja $k = 1$, seleciona-se os $p\%$ vértices que estejam, a no máximo 15% distante do centroide;
- seja $k = 2$, seleciona-se os $p\%$ vértices que estejam, a no máximo 10% distante do centroide;
- seja $k = 3$, seleciona-se os $p\%$ vértices que estejam, a no máximo 5% distante do centroide;

Uma vez selecionados os $p\%$ vértices, fica definido um novo *cluster* p a ser testado. A finalidade desta etapa é produzir soluções $s' \in N^v(s)$ de qualidade superior à solução s . Após as trocas, os centroides são recalculados e a busca prossegue. O objetivo dessa etapa é alocar

os demais vértices ao centroide mais próximo e efetuar as atualizações necessárias dos centroides considerando as restrições de conectividade e capacidade.

Nas etapas seguintes pode-se considerar como resultado da solução, a solução atual ou uma solução já armazenada (em caso de não haver melhoramento desta etapa parcial). A ideia é tornar-se mais tolerante na aceitação de uma solução retornada pela busca local, não necessariamente melhorando a solução candidata. Um *cluster* com custo um pouco pior pode ser aceito, porém tais limites de aceitação precisam ser definidos. Neste sentido, foram considerados neste trabalho os resultados que não apresentaram melhoria, desde que o valor não se afastasse muito do valor atual. Devido a isso, precisamos guardar a melhor solução encontrada até então. Já a função objetivo do ótimo local $f(s'')$ foi substituída por $f(s'') - \alpha\rho(s, s'')$, onde $\rho(s, s'')$, é a diferença do valor da função objetivo s e s'' e α é um parâmetro. Definiu-se $\alpha = 0.9$, após um conjunto de testes para ajuste deste parâmetro.

E finalizou-se o algoritmo SVN quando o critério de parada foi satisfeito.

CAPÍTULO 4 - EXPERIMENTOS COMPUTACIONAIS

O presente capítulo traz os resultados relativos a um conjunto de experimentos computacionais realizados com os algoritmos descritos no Capítulo 3 deste trabalho de tese.

Conforme apresentado no Capítulo 3, os algoritmos considerados nos experimentos do presente trabalho foram os algoritmos construtivos GRASP: Padrão, com Reconexão de Caminho, com Busca Local VND e com Busca Local Randômica RVND, além dos algoritmos VNS Padrão e suas variantes RVNS, GVNS e SVNS.

As instâncias utilizadas para avaliar os algoritmos supracitados foram obtidas a partir dos dados do Censo Demográfico 2010 do IBGE (dados de uso público disponíveis no site do IBGE).

4.1 TECNOLOGIAS

As implementações dos algoritmos propostos foram feitas em Linguagem C, utilizando como ambiente de desenvolvimento o *NetBeans 7.2*. Todos os experimentos computacionais foram realizados em um computador dotado de processador AMD de 1.4Ghz e com 4GB de memória RAM e sistema operacional *Windows 7*.

4.2 INSTÂNCIAS UTILIZADAS

Este trabalho, em seu estudo de caso, utiliza 64 (sessenta e quatro) instâncias referentes aos problemas de Criação de Áreas de Ponderação Agregadas e de Agregados de Municípios [CENSO DEMOGRÁFICO 2010]. No caso do censo demográfico, os objetos podem estar associados, por exemplo, a domicílios, setores censitários, áreas de ponderação (APOND) e a municípios.

Utilizou-se um conjunto de instâncias obtidas a partir dos dados da amostra do Censo Demográfico 2010. Para cada instância foram utilizados dois arquivos do tipo texto. O primeiro arquivo contendo as informações de vizinhança entre os vértices/objetos (setores censitários) e o segundo contendo os atributos associados a estes vértices/objetos (setores censitários), sejam eles: total de domicílios particulares permanentes em cada setor censitário (variável de capacidade mínima), proporção de domicílios com banheiros e total de rendimento nominal mensal dos domicílios particulares permanentes.

Observa-se, ainda, que para todas as instâncias utilizadas nesse trabalho, a variável total de domicílios particulares permanente (disponível para cada setor censitário) do IBGE foi utilizada como variável de capacidade no processo de formação dos grupos. Assim,

estipulou-se previamente, que a soma dos valores total de domicílios associados a cada uma das APONDS não deveria ser inferior a um parâmetro P pré-estabelecido.

O arquivo referente à vizinhança é utilizado para determinar a relação entre os vértices do Grafo G a partir do qual será construída a AGM T . Assim, cada objeto corresponde a um vértice do grafo ao qual também terá associado seus atributos. Tais atributos devem ser normalizados e submetidos ao cálculo das distâncias d_{ij} nas arestas (i, j) de G .

Tabela 4.1: Relação das instâncias utilizadas

Código	Vértices Número de Objetos (Setores Censitários)	Arestas (Número de Vizinhanças)
1	88	438
2	157	720
3	20	224
4	102	586
5	34	298
6	28	322
7	22	326
8	15	106
9	53	604
10	75	470
11	42	288
12	67	528
13	35	354
14	30	318
15	70	305
16	32	254
17	44	362
18	25	438
19	259	1518
20	202	1058
21	323	2140
22	83	442
23	27	316
24	24	246
25	21	318
26	411	3150
27	46	384
28	12	105
29	97	514
30	101	499
31	59	735
32	382	2643
33	26	452
34	77	481
35	38	367
36	93	497
37	122	658
38	240	1283
39	221	1197
40	19	121
41	72	364
42	94	502
43	489	3881
44	29	468
45	152	707

46	90	514
47	48	397
48	189	913
49	64	514
50	100	561
51	523	4287
52	11	102
53	146	691
54	82	435
55	359	2577
56	307	1925
57	63	501
58	18	114
59	162	743
60	592	4997
62	274	1836
62	581	4728
63	60	471
64	404	3002

4.3 ALGORITMOS

Conforme descrito no Capítulo 3, os procedimentos e as estratégias implementadas nesta tese utilizam o algoritmo GRASP e incorporam o procedimento *Path-Relinking* (PR), uma estratégia de busca local baseada no VND e outra estratégia de Busca local baseada num RVND. Além de utilizar o algoritmo VNS Padrão e suas variantes GVNS, RVNS e SVNS. Todos esses algoritmos utilizam como dado de entrada, especificamente, a AGM construída com o procedimento *Kruskal* em sua forma padrão e a AGM construída considerando o procedimento *Kruskal* modificado através da aleatoriedade de seus pesos, além de trabalhar também com o Grafo Original. Estes três tipos de dados de entrada direcionam a definição três categorias de algoritmos para cada versão algoritmo implementado, sejam eles assim denominados:

- GRASP padrão considerando: (i) a AGM com *Kruskal padrão*, (ii) apenas a AGM com *Kruskal* modificado e (iii) apenas o Grafo Original;
- GRASP com o procedimento *Path-Relinking* considerando: (i) a AGM com *Kruskal padrão*, (ii) apenas a AGM com *Kruskal* modificado e (iii) apenas o Grafo Original;
- GRASP com a estratégia VND considerando: (i) a AGM com *Kruskal padrão*, (ii) AGM com *Kruskal* modificado e (iii) apenas o Grafo Original;
- GRASP com a estratégia RVND considerando: (i) a AGM com *Kruskal padrão*, (ii) apenas a AGM com *Kruskal* modificado e (iii) apenas o Grafo Original;
- VNS padrão considerando: (i) a AGM com *Kruskal padrão*, (ii) apenas a AGM com *Kruskal* modificado e (iii) apenas o Grafo Original;

- GVNS considerando: (i) a AGM com *Kruskal padrão*, (ii) apenas a AGM com *Kruskal* modificado e (iii) apenas o Grafo Original;

- RVNS considerando: (i) a AGM com *Kruskal padrão*, (ii) apenas a AGM com *Kruskal* modificado e (iii) apenas o Grafo Original;

- SVNS considerando: (i) a AGM com *Kruskal padrão*, (ii) apenas a AGM com *Kruskal* modificado e (iii) apenas o Grafo Original;

Além disso, observamos que cada grupo de algoritmos é definido a partir de uma combinação de procedimentos de construção e de busca local implementados neste trabalho, como será visto logo à frente nas Tabelas 4.2, 4.3, 4.4, 4.5, 4.6 e 4.7 perfazendo um total de 40 (quarenta) versões de algoritmos considerando a AGM construída com *Kruskal padrão*, 40 (quarenta) versões de algoritmos considerando a AGM construída com *Kruskal* modificado e 40 (quarenta) versões de algoritmos considerando somente o Grafo Original.

Além da combinação dos procedimentos de construção e de busca local implementados neste trabalho, devem ser informados aos algoritmos o critério de parada, quais versões dos procedimentos de construção e de busca serão executados e os valores de alguns parâmetros:

- **Critério de parada**: pode ser utilizada a quantidade de iterações ou o tempo de execução;

- **Procedimentos Construtores (C)**: todos os algoritmos devem especificar qual algoritmo construtor deve ser utilizado. Nesse trabalho, foram implementadas cinco versões de procedimentos construtores, sendo que em todas as versões a restrição de conexidade foi atendida; Assim, C-1 representa o procedimento construtor versão 1 (um), e assim por diante.

- **Procedimentos de Busca Local (BL)**: versões de procedimentos de busca local que serão utilizadas pelo algoritmo. Assim, BL-1 representa a busca local versão 1 (um), e assim sucessivamente;

- **Alfa (α)**: este parâmetro é utilizado com o objetivo de atribuir aos procedimentos construtores um comportamento semi-guloso, mediante a manipulação do tamanho da LRC (Lista Restrita de Candidatos). Este parâmetro, no caso específico deste problema de clusterização com restrição de capacidade e conexidade representa o limite máximo do tamanho da LRC, considerando que pode existir uma quantidade inferior de elementos desta LRC;

- **Quantidade de clusters (k)**: representa o número de *clusters* utilizados no problema;

- **Capacidade Mínima por cluster ($Capacidade_{Min_cluster}$)**: é o valor do fator de ajuste utilizado para cálculo da capacidade mínima por *cluster*, conforme Equação 14. A

Tabela 4.2 apresenta os algoritmos GRASP Padrão, com *Path-Relinking*, com VND e RVND considerando apenas o Grafo Original com as combinações dos procedimentos de construção e os de busca local, com suas respectivas siglas.

Tabela 4.2: Siglas dos algoritmos utilizando o Grafo Original

ALGORITMOS	SIGLA	CONSTRUTORES					BUSCA LOCAL		
		C-1	C-2	C-3	C-4	C-5	BL-2	BL-3	BL-6
GRASP Padrão	G1	X					X	X	X
	G2		X				X	X	X
	G3			X			X	X	X
	G4				X		X	X	X
	G5					X	X	X	X
GRASP com Path-Relinking	GPR1	X					X	X	X
	GPR2		X				X	X	X
	GPR3			X			X	X	X
	GPR4				X		X	X	X
	GPR5					X	X	X	X
GRASP com VND	GVND1	X					X	X	X
	GVND2		X				X	X	X
	GVND3			X			X	X	X
	GVND4				X		X	X	X
	GVND5					X	X	X	X
GRASP com RVND	GRVND1	X					X	X	X
	GRVND2		X				X	X	X
	GRVND3			X			X	X	X
	GRVND4				X		X	X	X
	GRVND5					X	X	X	X

A Tabela 4.3 apresenta os algoritmos GRASP Padrão, com *Path-Relinking* e com VND considerando somente a AGM construída utilizando o *Kruskal* modificado com as combinações dos procedimentos de construção e os de busca local, com suas respectivas siglas, implementados neste trabalho.

Tabela 4.3: Siglas dos algoritmos utilizando a AGM construída *Kruskal* Modificado

ALGORITMOS	SIGLA	CONSTRUTORES					BUSCA LOCAL		
		C-1	C-2	C-3	C-4	C-5	BL-1	BL-4	BL-5
GRASP Padrão	AGMM1	X					X	X	X
	AGMM2		X				X	X	X
	AGMM3			X			X	X	X
	AGMM4				X		X	X	X
	AGMM5					X	X	X	X
GRASP com Path-Relinking	PR_AGMM1	X					X	X	X
	PR_AGMM2		X				X	X	X
	PR_AGMM3			X			X	X	X
	PR_AGMM4				X		X	X	X
	PR_AGMM5					X	X	X	X
GRASP com VND	V_AGMM1	X					X	X	X
	V_AGMM2		X				X	X	X
	V_AGMM3			X			X	X	X
	V_AGMM4				X		X	X	X
	V_AGMM5					X	X	X	X
GRASP com RVND	RV_AGMM1	X					X	X	X
	RV_AGMM2		X				X	X	X

GRASP com RVND	RV_AGMM3			X			X	X	X
	RV_AGMM4				X		X	X	X
	RV_AGMM5					X	X	X	X

A Tabela 4.4 apresenta os algoritmos GRASP Padrão, com *Path-Relinking* e com VND considerando somente a AGM construída utilizando o *Kruskal* padrão com as combinações dos procedimentos de construção e os de busca local, com suas respectivas siglas, implementados neste trabalho.

Tabela 4.4 Siglas dos algoritmos utilizando a AGM construída *Kruskal* Padrão

ALGORITMOS	SIGLA	CONSTRUTORES					BUSCA LOCAL		
		C-1	C-2	C-3	C-4	C-5	BL-1	BL-4	BL-5
GRASP Padrão	AGM1	X					X	X	X
	AGM2		X				X	X	X
	AGM3			X			X	X	X
	AGM4				X		X	X	X
	AGM5					X	X	X	X
GRASP com Path-Relinking	PR_AGM1	X					X	X	X
	PR_AGM2		X				X	X	X
	PR_AGM3			X			X	X	X
	PR_AGM4				X		X	X	X
	PR_AGM5					X	X	X	X
GRASP com VND	V_AGM1	X					X	X	X
	V_AGM2		X				X	X	X
	V_AGM3			X			X	X	X
	V_AGM4				X		X	X	X
	V_AGM5					X	X	X	X
GRASP com RVND	RV_AGM1	X					X	X	X
	RV_AGM2		X				X	X	X
	RV_AGM3			X			X	X	X
	RV_AGM4				X		X	X	X
	RV_AGM5					X	X	X	X

A Tabela 4.5 apresenta os algoritmos VNS Padrão e suas variações (GVNS, RVNS E SVNS) e considerando apenas o Grafo Original com as combinações dos procedimentos de construção e os de busca local, com suas respectivas siglas.

Tabela 4.5 Siglas dos algoritmos utilizando também o Grafo Original

ALGORITMOS	SIGLA	CONSTRUTORES					BUSCA LOCAL		
		C-1	C-2	C-3	C-4	C-5	BL-2	BL-3	BL-6
VNS Padrão	VNS1	X					X	X	X
	VNS2		X				X	X	X
	VNS3			X			X	X	X
	VNS4				X		X	X	X
	VNS5					X	X	X	X
GVNS	GVNS1	X					X	X	X
	GVNS2		X				X	X	X
	GVNS3			X			X	X	X
	GVNS4				X		X	X	X
	GVNS5					X	X	X	X
RVNS	RVNS1	X					X	X	X
	RVNS2		X				X	X	X

	RVNS3			X			X	X	X
	RVNS4				X		X	X	X
	RVNS5					X	X	X	X
SVNS	SVNS1	X					X	X	X
	SVNS2		X				X	X	X
	SVNS3			X			X	X	X
	SVNS4				X		X	X	X
	SVNS5					X	X	X	X

A Tabela 4.6 apresenta os algoritmos VNS Padrão e suas variações (GVNS, RVNS E

Tabela 4.6 - Siglas dos algoritmos utilizando a AGM construída com *Kruskal* modificado

ALGORITMO	SIGLA	CONSTRUTORES					BUSCA LOCAL		
		C-1	C-2	C-3	C-4	C-5	BL-1	BL-4	BL-5
VNS Padrão	VNS_AGMM1	X					X	X	X
	VNS_AGMM2		X				X	X	X
	VNS_AGMM3			X			X	X	X
	VNS_AGMM4				X		X	X	X
	VNS_AGMM5					X	X	X	X
GVNS	GVNS_AGMM1	X					X	X	X
	GVNS_AGMM2		X				X	X	X
	GVNS_AGMM3			X			X	X	X
	GVNS_AGMM4				X		X	X	X
	GVNS_AGMM5					X	X	X	X
RVNS	RVNS_AGMM1	X					X	X	X
	RVNS_AGMM2		X				X	X	X
	RVNS_AGMM3			X			X	X	X
	RVNS_AGMM4				X		X	X	X
	RVNS_AGMM5					X	X	X	X
SVNS	SVNS_AGMM1	X					X	X	X
	SVNS_AGMM2		X				X	X	X
	SVNS_AGMM3			X			X	X	X
	SVNS_AGMM4				X		X	X	X
	SVNS_AGMM5					X	X	X	X

A Tabela 4.7 apresenta os algoritmos VNS Padrão e suas variações (GVNS, RVNS E SVNS considerando somente a AGM construída utilizando o *Kruskal* padrão com as combinações dos procedimentos de construção e os de busca local, com suas respectivas siglas, implementados neste trabalho.

Tabela 4.7 - Siglas dos algoritmos utilizando a AGM construída com *Kruskal* padrão

ALGORITMO	SIGLA	CONSTRUTORES					BUSCA LOCAL		
		C-1	C-2	C-3	C-4	C-5	BL-1	BL-4	BL-5
VNS Padrão	VNS_AGM1	X					X	X	X
	VNS_AGM2		X				X	X	X
	VNS_AGM3			X			X	X	X
	VNS_AGM4				X		X	X	X
	VNS_AGM5					X	X	X	X
GVNS	GVNS_AGM1	X					X	X	X
	GVNS_AGM2		X				X	X	X
	GVNS_AGM3			X			X	X	X
	GVNS_AGM4				X		X	X	X
	GVNS_AGM5					X	X	X	X
RVNS	RVNS_AGM1	X					X	X	X
	RVNS_AGM2		X				X	X	X
	RVNS_AGM3			X			X	X	X

	RVNS_AGM4				X		X	X	X
	RVNS_AGM5					X	X	X	X
SVNS	SVNS_AGM1	X					X	X	X
	SVNS_AGM2		X				X	X	X
	SVNS_AGM3			X			X	X	X
	SVNS_AGM4				X		X	X	X
	SVNS_AGM5					X	X	X	X

Após a realização de um conjunto de testes preliminares com 24 instâncias do Censo Demográfico 2010 com base nos parâmetros descritos para cada grupo de algoritmos, foram estabelecidas as seguintes configurações para o Algoritmo GRASP: determinou-se critério de parada igual a 100 iterações, o alfa (α) igual a 10 (dez) pois contém o número máximo de arestas com os maiores valores de custos gerados nas soluções iniciais (procedimentos construtores), mas durante todos os experimentos realizados neste trabalho o valor de alfa não passou de 3 (três), o k igual a 3 e a variável fator de ajuste igual a 25% (para o cálculo da capacidade mínima por *cluster*).

4.4 EXPERIMENTOS REALIZADOS

Os experimentos realizados neste trabalho têm como objetivo, através de execuções sistemáticas e análises probabilísticas, demonstrar mesmo que de forma empírica, a eficiência e a robustez dos algoritmos propostos no que se refere à qualidade das soluções obtidas e à obtenção de soluções válidas (aquelas cujas restrições do problema abordado são atendidas).

Um primeiro experimento considerou 100 execuções de cada algoritmo apresentado na Seção 4.4.1 em cada uma das instâncias apresentadas na Tabela 4.1, para obtenção de três *clusters*. A partir dos resultados obtidos, são apresentadas análises avaliando os algoritmos em relação à obtenção de soluções classificadas como soluções de excelente qualidade, soluções razoáveis e soluções de qualidade péssima. Além disso, foram avaliados os tempos de execução dos algoritmos que utilizam apenas o Grafo Original; a AGM construída com *Kruskal* modificado e AGM construída com *Kruskal* padrão, as versões de procedimentos construtores, bem como os algoritmos GRASP e VNS.

4.4.1 EXPERIMENTOS COM ALGORITMOS PROPOSTOS

Com base na Apêndice A, que apresenta os resultados computacionais obtidos na execução dos algoritmos propostos neste trabalho para cada uma das 64 instâncias utilizadas, a presente seção trata de mostrar os gráficos construídos com base naquelas tabelas a partir de cem execuções das melhores soluções obtidas, o tempo de execução (em segundos) e o *Gap*. O *Gap* (Equação 18) que representa os valores de desvio percentual em relação à melhor

solução (menor valor de função objetivo) encontrada para uma dada instância no experimento:

$$Gap = 100 * \frac{solução - solução_{best}}{solução_{best}} \quad (18)$$

sendo:

- *solução*: valor da função objetivo do algoritmo corrente de uma instância em determinado instante;
- *solução_{best}*: menor (melhor) valor conhecido da função objetivo para um dado experimento;

São consideradas soluções válidas, ou seja, aquelas cujas restrições de conectividade e de capacidade mínima por *cluster* forem atendidas.

Por tratar-se de um problema de minimização, a melhor solução (*Solução_{best}*) é justamente aquela que apresenta o menor valor da função objetivo dentre as 120 (Cento e Vinte) versões associadas ao GRASP padrão, ao GRASP com *Path-Relinking*, ao GRASP com VND e GRASP com RVND, além do VNS padrão e suas variações (GVNS, RVNS e SVNS). Nas citadas tabelas, as soluções cujo valor do *Gap* for igual a 0% estão com a célula na cor cinza, pois correspondem aos melhores resultados. E as soluções cujo valor do *Gap* é superior a 10% estão assinaladas com a cor preta e com a formatação em negrito, pois se referem aos piores resultados.

As Figuras 4.1, 4.2, 4.3, 4.4, 4.5, 4.6, 4.7 e 4.8 apresentam gráficos com os quantitativos das soluções obtidas por algoritmo, classificadas conforme a sua qualidade, sejam elas: Melhores (com *Gap* igual a 0%), Razoáveis (com *Gap* maior do que 0% e menor ou igual a 10%) e Péssimas (*Gap* acima de 10%). Uma vez que as Tabelas presentes no Apêndice A apresentaram os melhores resultados produzidos pelos algoritmos para cada instância, o quantitativo máximo apresentado no eixo *x* corresponde ao total de instâncias consideradas nos experimentos, ou seja, sessenta e quatro.

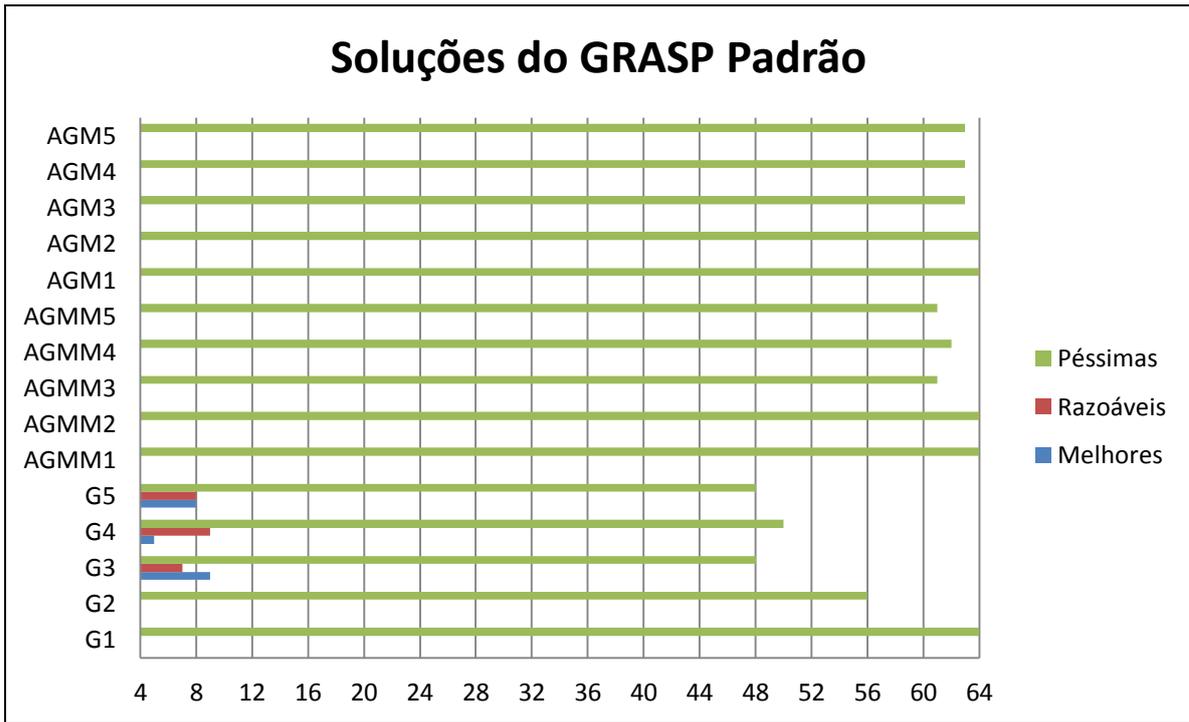


Figura 4.1 - Soluções GRASP Padrão

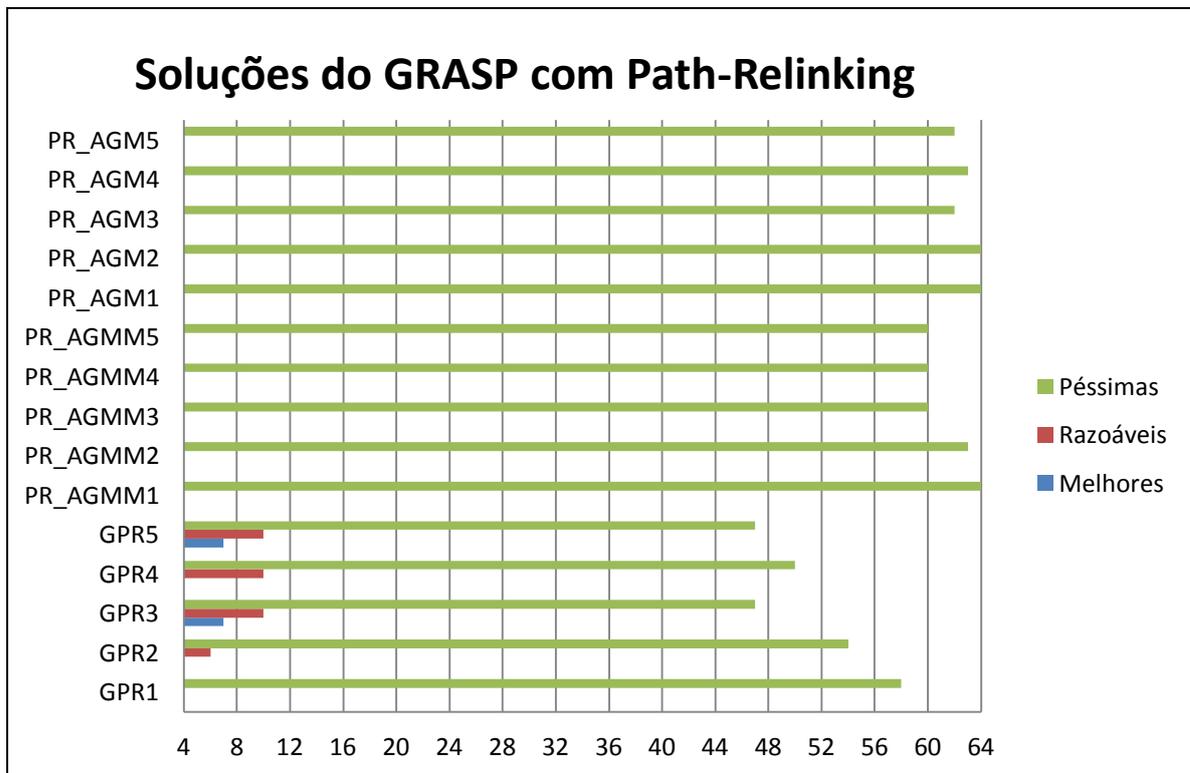


Figura 4.2 - Soluções GRASP com *Path-Relinking*

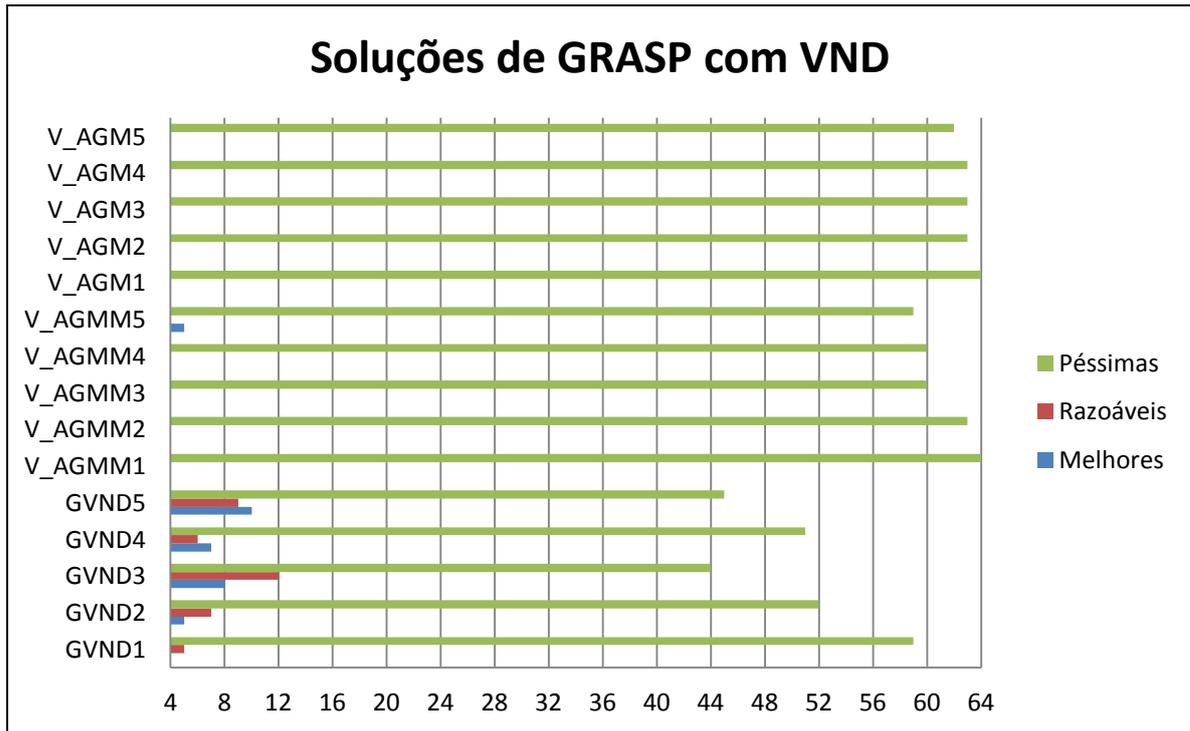


Figura 4.3 - Soluções GRASP com VND

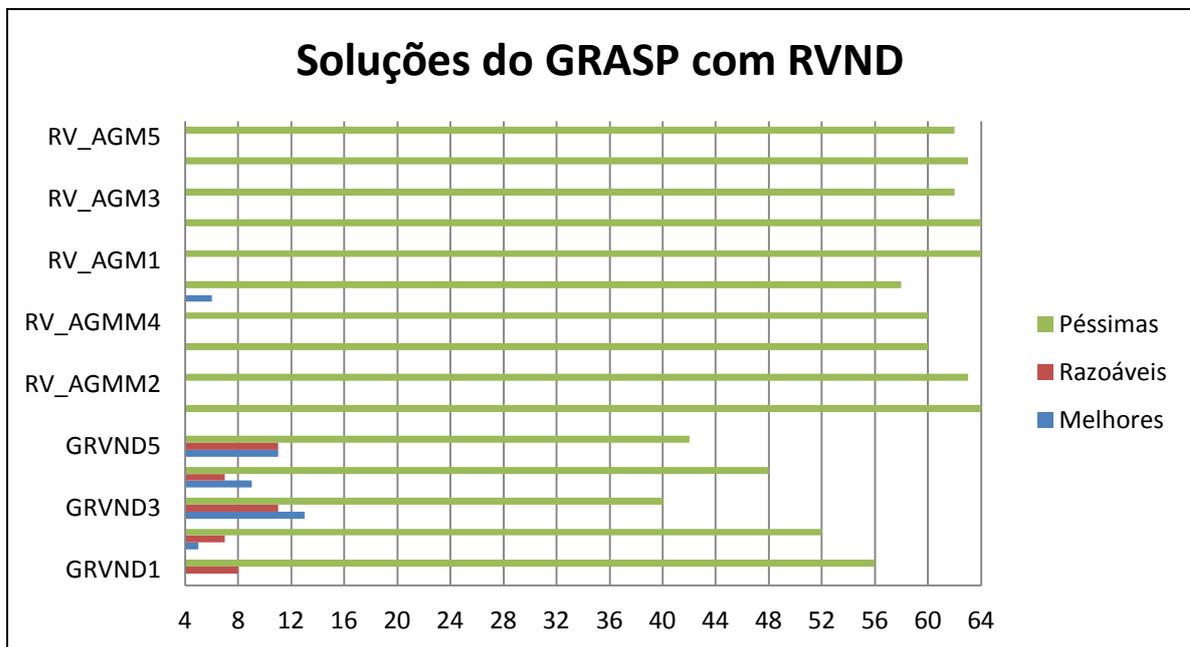


Figura 4.4 - Soluções GRASP com RVND

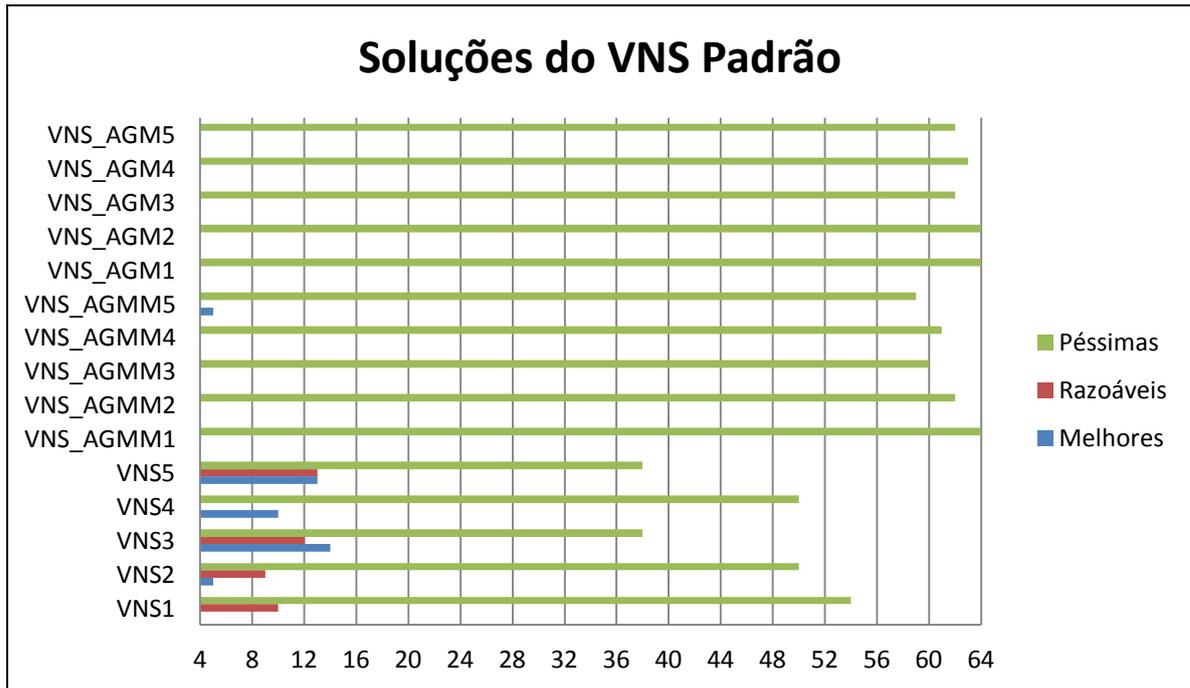


Figura 4.5 - Soluções VNS Padrão

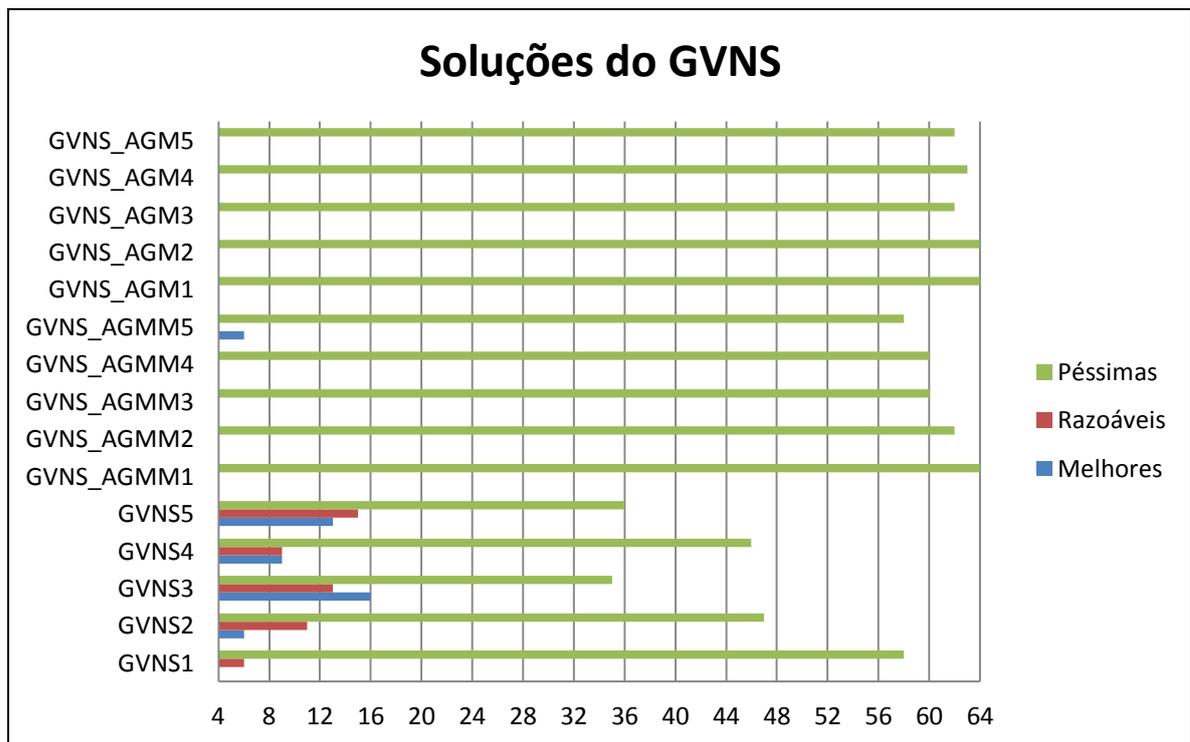


Figura 4.6 - Soluções GVNS

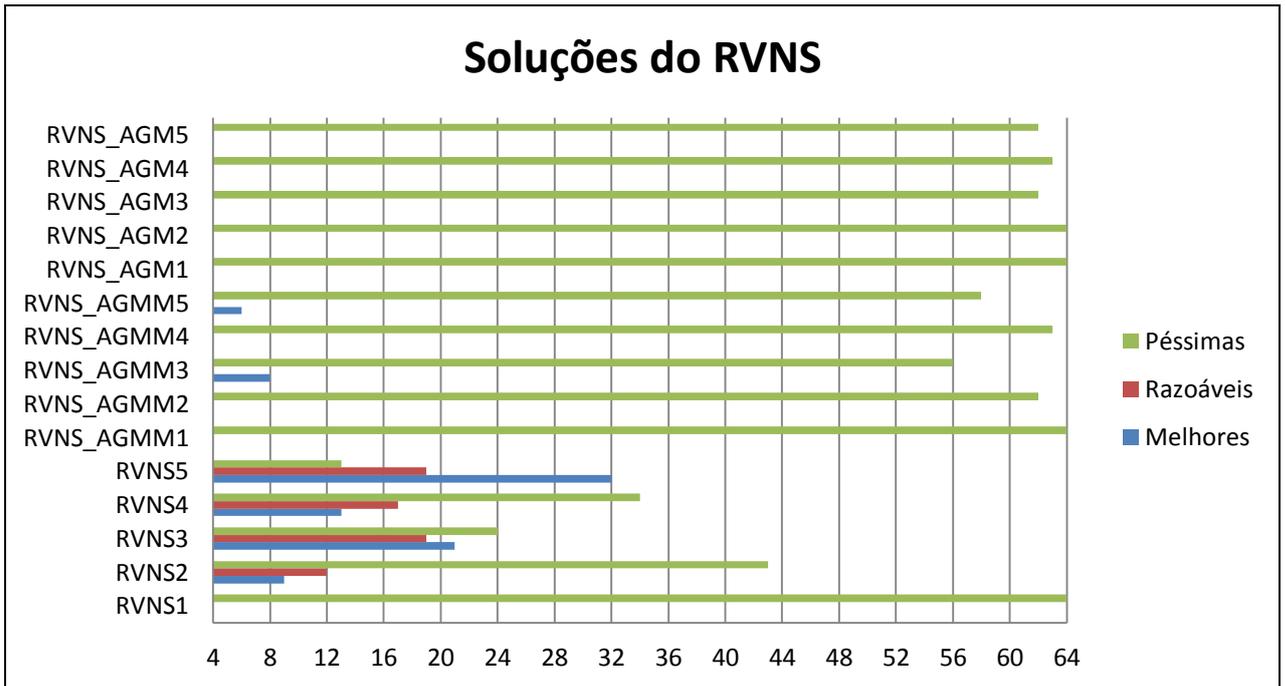


Figura 4.7 - Soluções RVNS

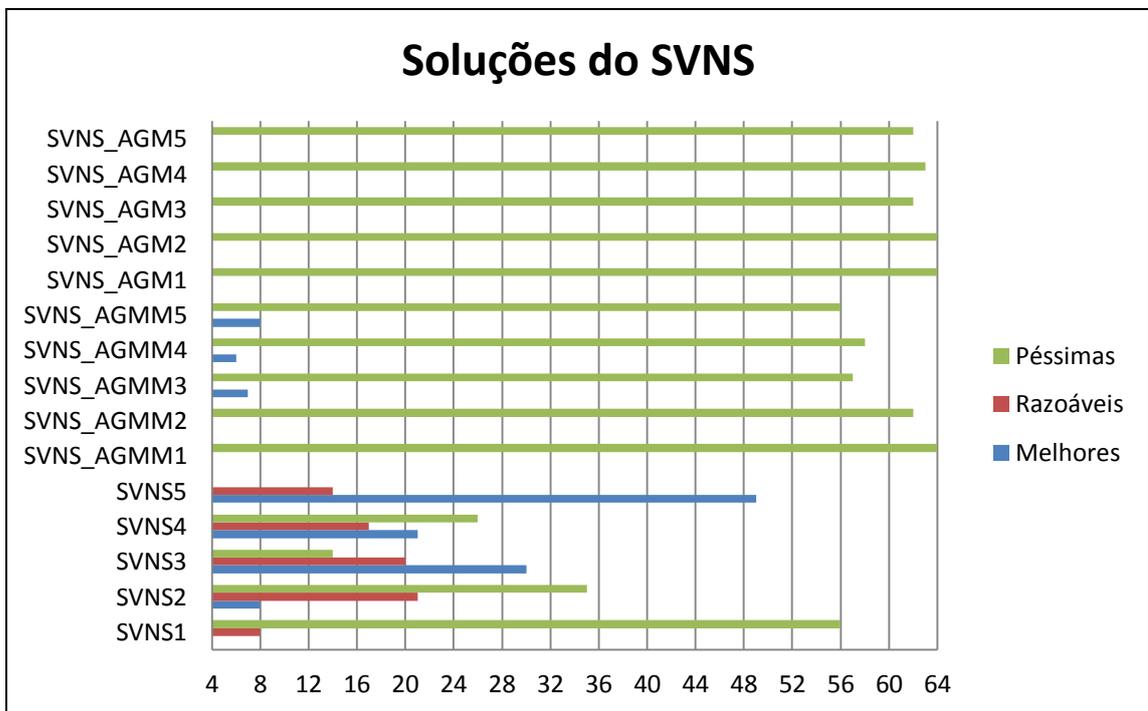


Figura 4.8 - Soluções SVNS

Agora, uma vez considerados os dados das tabelas e as informações sumarizadas nas figuras anteriores, faz-se necessária a realização de uma análise comparativa entre os melhores algoritmos GRASP Padrão, GRASP com *Path-Relinking*, GRASP com VND, GRASP com RVND, VNS Padrão, GVNS, RVNS e SVNS para cada uma das 64 (sessenta e quatro) instâncias utilizadas, o que pode ser visualizado na Figura 4.9:

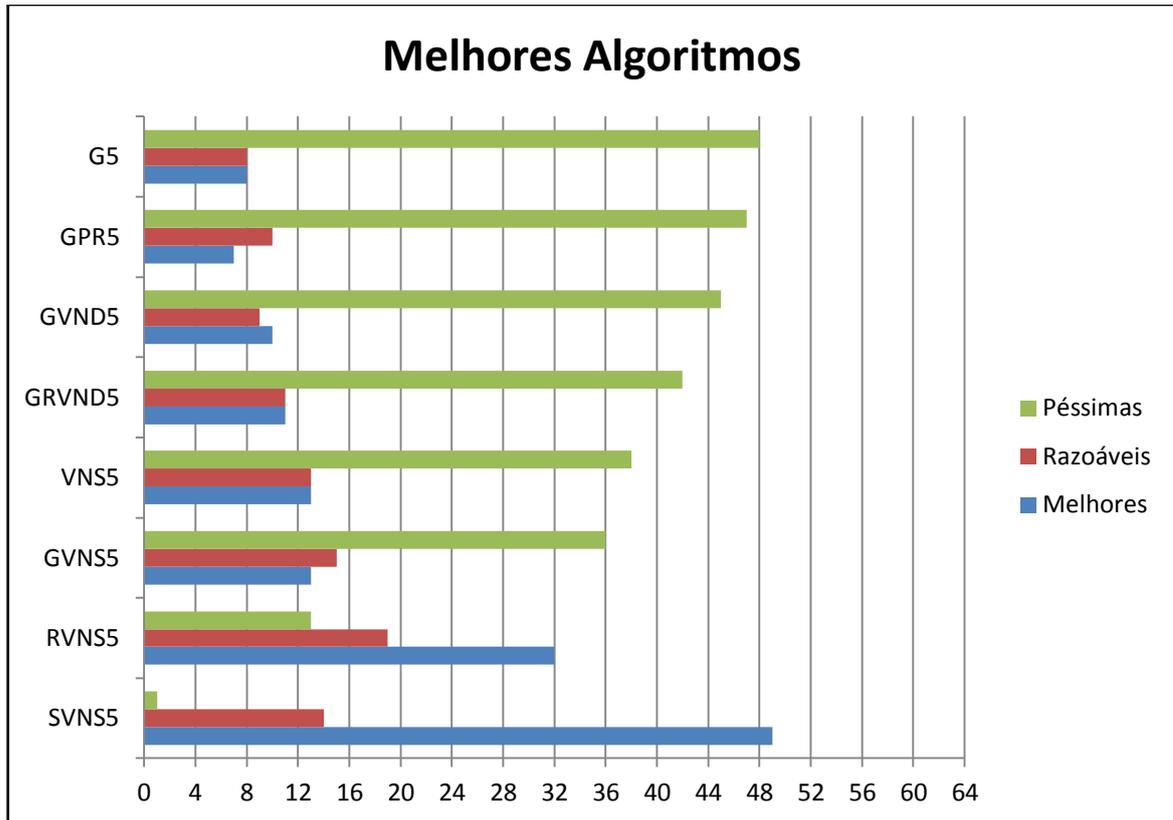


Figura 4.9 – Melhor Solução por Algoritmo

Uma primeira análise da figura 4.9 indica que, dentre todos os algoritmos, o SVNS5 apresentou um melhor desempenho no que concerne à qualidade das soluções produzidas. Mais especificamente, apresenta o maior número de soluções melhores e o menor número de soluções péssimas. E os piores resultados são apresentados pelo GRASP Padrão. Mas especificamente o GRASP Padrão apresenta a maior número de soluções péssimas igual a 48, seguido do GRASP com *Path-Relinking* com 47, o GRASP com VND com 45, o GRASP com RVND com 42, o VNS Padrão com 38, o GVNS com 36, o RVNS com 13 e por último o SVNS com o menor número igual a 1

A Figura 4.10, apresenta a média das versões melhores, razoáveis e péssimas do algoritmo SVNS por categoria enumeradas como: Grafo Original, AGM Modificada (gerada com *Kruskal* modificado por pesos aleatórios) e AGM Padrão (gerada com *Kruskal* padrão).

Foram testadas 5 (cinco) versões de cada de cada categoria para cada uma das 64 instâncias tratada nesse trabalho, perfazendo um total de 320 (trezentos e vinte) resultados diferentes.

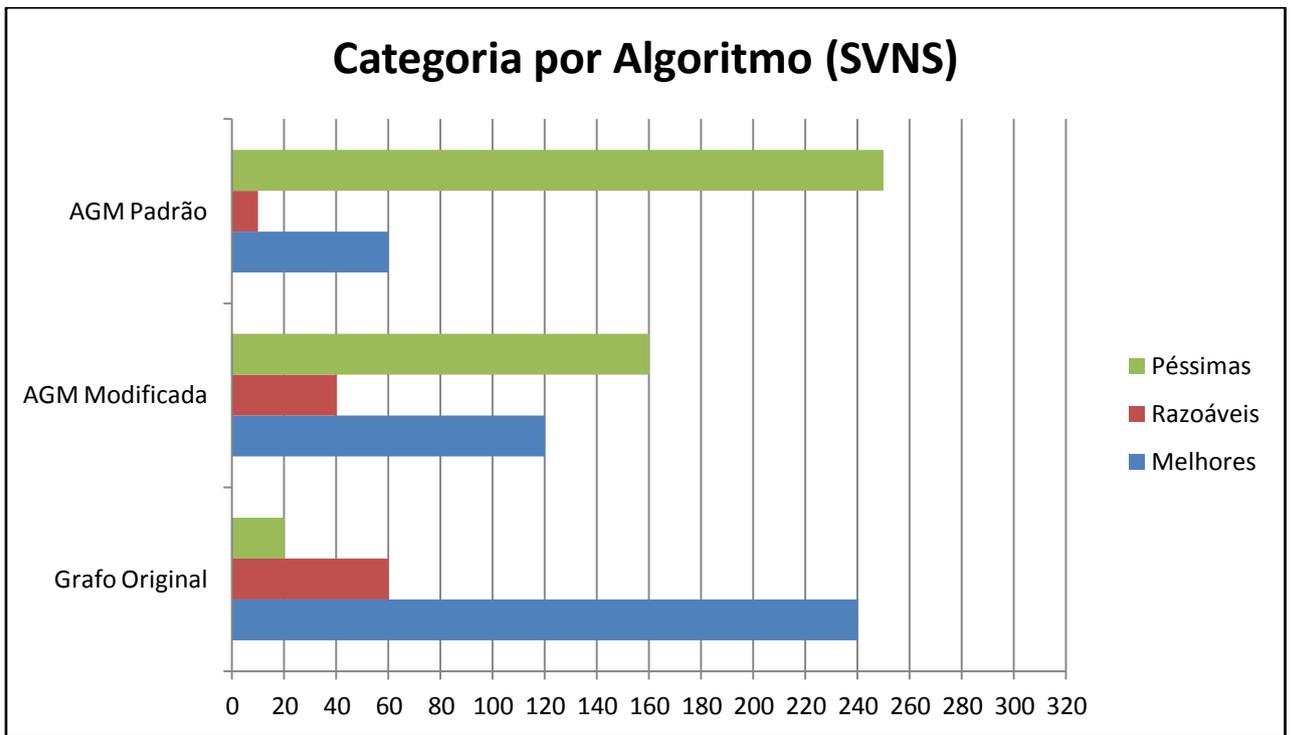


Figura 4.10 – Melhor Categoria por Algoritmo (SVNS)

Na análise da figura 4.10 percebe-se que, o Grafo Original apresenta um resultado superior em relação ao número de soluções melhores são 240 (duzentos e quarenta) em comparação a AGM Modificada que alcança somente metade deste resultado, foram 120 (cento e vinte) melhores e a AGM Padrão que só consegue alcançar 60 (sessenta) destas. O número de soluções péssimas do Grafo Original também mostra que sua performance computacional é melhor em relação as outras categorias, pois só atingi 20 soluções péssimas, enquanto a AGM Modificada chega ao número de 160 (cento e sessenta) e a AGM Padrão se encontra com 250 (duzentos e cinquenta) soluções péssimas.

A Figura 4.11 ilustra um comparativo entre o algoritmo SVNS5 (Grafo Original), SVNS_AGMM5 (AGM com *Kruskal* Modificado) e SVNS__AGM5 (AGM com *Kruskal* Padrão) e o *software* SKATER:

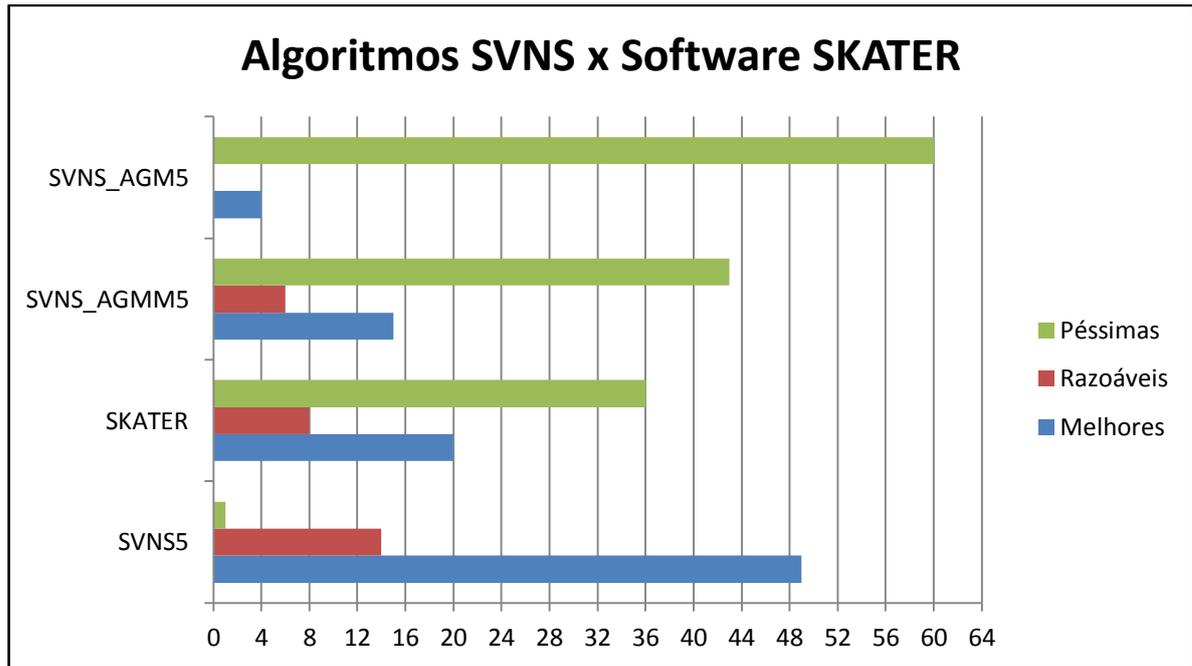


Figura 4.11 – Comparativo algoritmos SVNS e o software SKATER

Na Figura 4.11, foram considerando-se 100 execuções, para cada uma das 64 (sessenta e quatro) instâncias, para obtenção de 3 *clusters* para a obtenção de soluções válidas, desde que sejam garantidas as restrições de capacidade e conectividade. O algoritmo SVNS5 (Grafo Original) apresentou o melhor resultado, seguido do software *Skater*. O *Skater* conseguiu 20 (vinte) soluções melhores, 8 (oito) soluções razoáveis e 36 (trinta e seis) soluções péssimas. E com a pior performance aparece o algoritmo SVNS com AGM (construída com *Kruskal* padrão).

4.5 AVALIAÇÃO PROBABILÍSTICA DOS RESULTADOS

Para se verificar o desempenho dos algoritmos também foi realizada uma análise de probabilidade empírica [AIEX ET AL 2007]. Esse tipo de abordagem consiste em tomar os tempos de processamento que cada algoritmo requer para atingir um valor alvo no que se refere à função objetivo. Neste sentido, foram estabelecidos neste trabalho dois alvos de avaliação obtidos em testes anteriores, a saber: um alvo considerado fácil, dado pelo pior valor da função objetivo de uma solução válida (em relação ao algoritmo) e um alvo considerado difícil, dado pelo menor (melhor) valor da função objetivo. Dessa forma, no instante em que cada algoritmo encontra uma solução menor ou igual ao alvo fixado, o tempo é registrado e uma nova execução do algoritmo é iniciada. Em outras palavras, um novo critério de parada é inserido para cada algoritmo, que consiste na obtenção de uma solução

cujo valor atinja ou ultrapasse o alvo, dentro do tempo limite pré-estabelecido em 3600 segundos.

Cada versão de algoritmo foi executada 100 vezes para cada instância, usando os mesmos parâmetros dos experimentos anteriores. Os tempos tomados e dispostos em ordem crescente numa lista L . A cada tempo de CPU t obtido, foi associada a probabilidade empírica do tempo sendo $p_i = \left(i - \frac{1}{2}\right) / 100$, sendo i a ordem que t aparece na lista ordenada L . A plotagem é feita então tomando cada ponto (t_i, p_i) para $i = 1, 2, 3, \dots, 100$, num gráfico, que estabelece uma distribuição de probabilidade empírica do tempo que cada algoritmo consome para alcançar o alvo pré-estabelecido [AIEX ET AL 2007].

Para esta análise foram utilizadas as instâncias vinte e oito, trinta e nove e instância sessenta, onde são apresentados os gráficos com a probabilidade empírica ao longo do tempo em segundos. Nota-se que cada curva do gráfico representa a convergência empírica de cada algoritmo, e que quanto mais à esquerda estiver a curva, melhor (mais rápido) será a convergência do algoritmo (mais eficiente), ou seja, o tempo que o algoritmo consome para atingir o alvo.

Nas Figuras 4.12, 4.13, 4.14, 4.15, 4.16 e 4.17 são apresentadas as distribuições de probabilidades empíricas ao longo do tempo de execução através dos gráficos *TTTTPlots*. Com o objetivo de avaliar os algoritmos utilizou-se no experimentos instâncias de tamanhos diferentes tanto na quantidade de vértices (nº de objetos) quanto no número de arestas. Padronizou-se que as instâncias com número de até 100 (cem) vértices independente do número de arestas seria denominada, neste trabalho, como instância de pequeno porte, por exemplo instância 28. E que as instâncias com número acima de 100 (cem) e menor que 400 vértices independente do número de arestas seria denominado de instância de médio porte, como a instância 39. E que a instância 60, seria descrita como de grande porte, uma vez que tem o número de vértices acima de 400 sem padronizar o número de arestas.

No entanto, percebe-se que algumas versões de algoritmos não conseguiram atingir o alvo fácil (valor da maior função objetivo) e o alvo difícil (valor da menor função objetivo) em nenhuma das 100 execuções e nem em tempo requerido durante o experimento de (3600 segundos), por isso não aparecem nas respectivas Figuras.

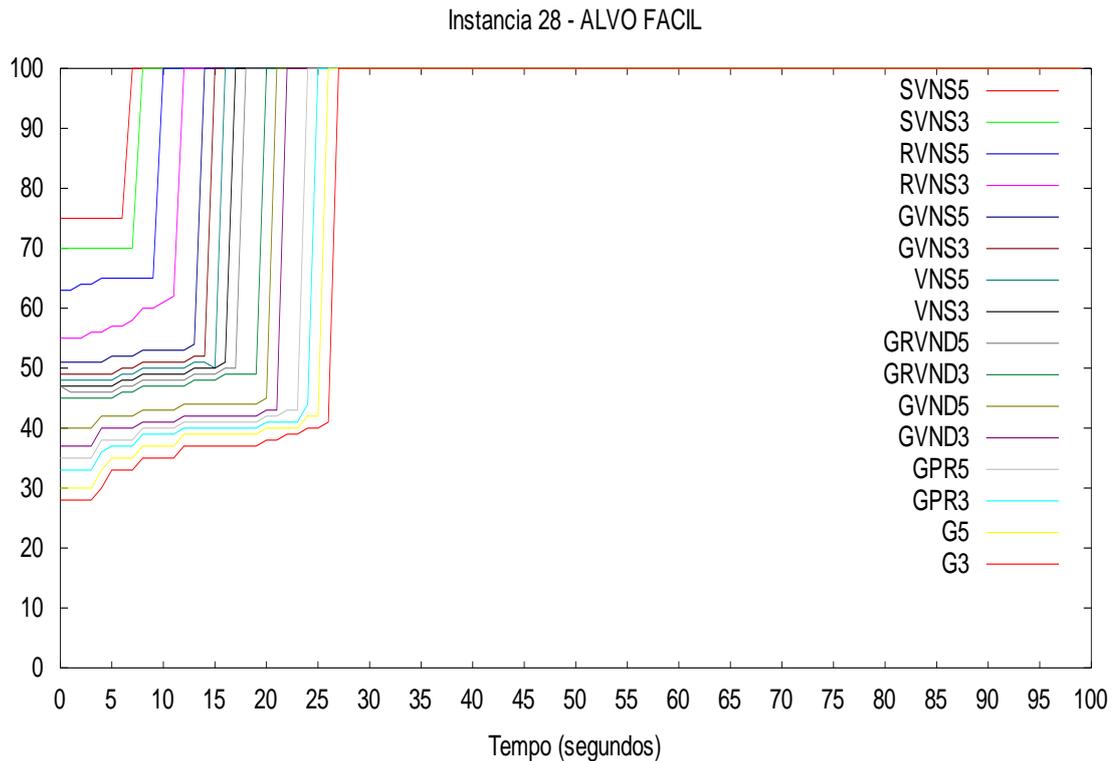


Figura 4.12 – Análise probabilística da instância 28 – alvo fácil

Pelos resultados ilustrados na Figura 4.12 verifica-se em termos de qualidade da solução gerada, que a versão o algoritmo SVNS5 (utiliza o procedimento construtor C-5 e as buscas locais BL-01, BL-04 e BL-05) apresentou o melhores resultado seguidos dos algoritmos SVNS3, RVNS5 e RVNS3 que obtiveram resultados muito próximos entre si. Para os experimentos que utilizam o Construtor 1 não foi possível alcançar o alvo para nenhuma das versões de algoritmos geradas. E as análises probabilísticas com as versões de Construtor 2 e 4 apresentaram resultados insatisfatórios, ou seja, a maioria das versões desses algoritmos não atingiu o alvo em nenhuma das 100 execuções ou dentro do limite de tempo estabelecido.

E o pior resultado foi constatado o algoritmo G3 (GRASP incluindo o Construtor 3 e buscas locais BL-01, BL-04 e BL-05) que só consegue atingir o alvo em 27 segundos.

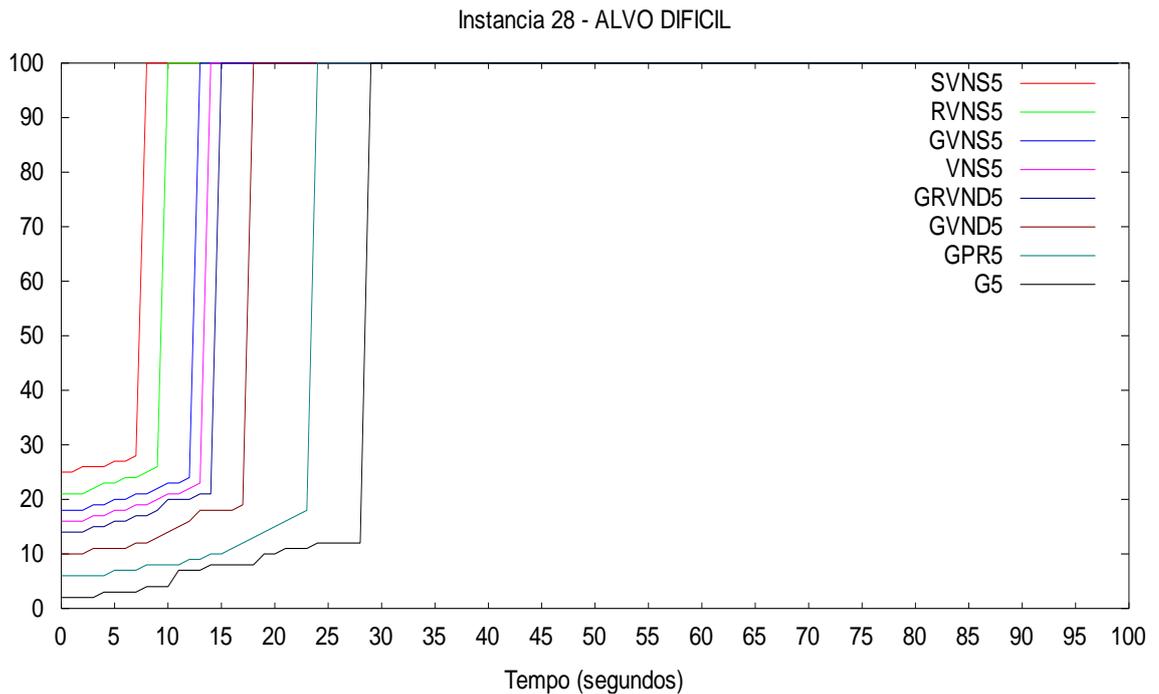


Figura 4.13 – Análise probabilística da instância 28 – alvo difícil

Com base na Figura 4.13, verificou-se que mais uma vez, em termos de qualidade da solução gerada, a versão do SVNS, o SVNS5 apresentou os melhores resultados. O desempenho das demais versões dos algoritmos propostos, por sua vez, mantiveram a mesma ordem dos testes com a instância 28 alvo fácil.

O SVNS5 alcança o alvo fácil em 7 segundos, já o pior resultado representado pelo algoritmo G3 atingi o alvo em 27 segundos.

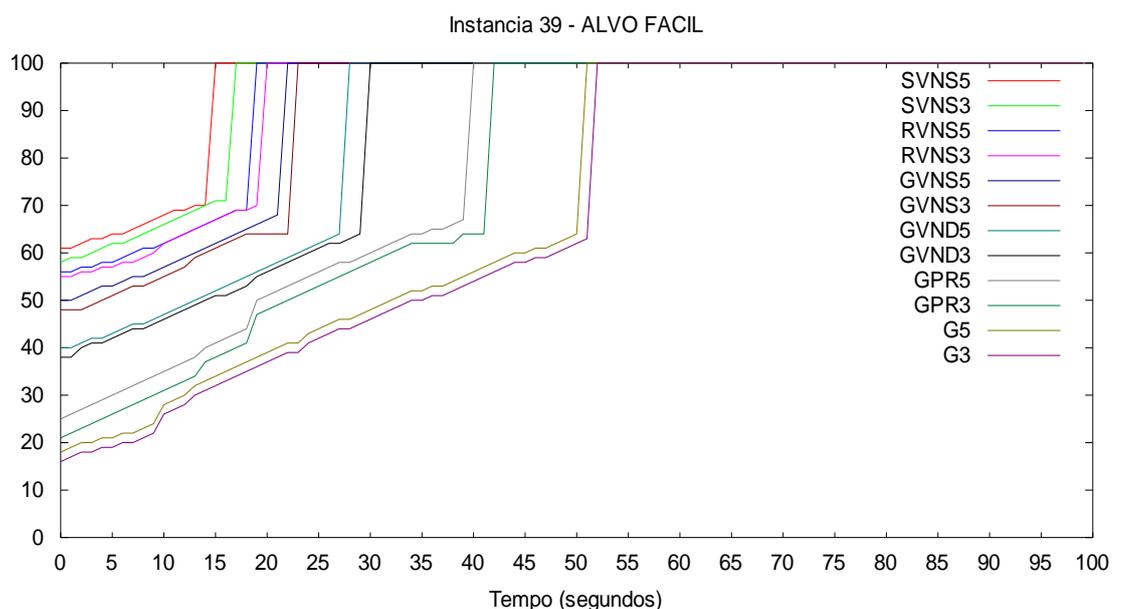


Figura 4.14 – Análise probabilística da instância 39 – alvo fácil

Neste caso, da Figura 4.14, houve uma competitividade maior entre as versões SVNS5 e SVNS3. Isso nos mostra que as metaheurísticas ainda são sensíveis aos parâmetros de entrada do problema. Mas de forma geral, percebe-se que não ocorre nenhuma diferença nesta bateria de testes quando comparada com a bateria de testes anteriores. Ou seja, o SVNS5 foi novamente o melhor algoritmo e os piores desempenhos ficaram com as versões do GRASP G5 e G3.

É constatado ainda que entre cada par de versões que utilizaram os mesmos procedimentos de busca local (BL-01, BL-04, BL-05) o construtivo que mais se destacou para o conjunto de testes foi o Construtor 05 (C-05) seguido do Construtor 03 (C-03). Pois entre as versões SVNS5, que utiliza o C-05 se mostrou mais eficiente que o SVNS3, que utilizar o C-03. O mesmo acontece com as versões RVNS5 e RVNS3, GVNS5 e GVNS3, GVND5 e GVND3, GPR5 e GPR3, e por último G5 e G3. Destaca-se que os algoritmo GVNS5, VNS5 e GRVND5 apresentaram resultados similares, por isso optou-se por visualizar no gráfico somente o resultado do GVND5. Os algoritmos GVNS3, VNS3 e GRVND3 também apresentaram resultados semelhantes, e também optou-se por mostrar no gráfico somente o resultado do algoritmo GVND3.

Mais uma vez, os algoritmos o Construtor 1 não atingi o alvo em nenhuma das versões dos algoritmos gerados. E as versões do construtor 2 e do 4 apresentaram baixo desempenho em que a maioria dos algoritmos não conseguiu atingir o alvo, em nenhuma das 100 execuções e nem dentro do limite estabelecido.

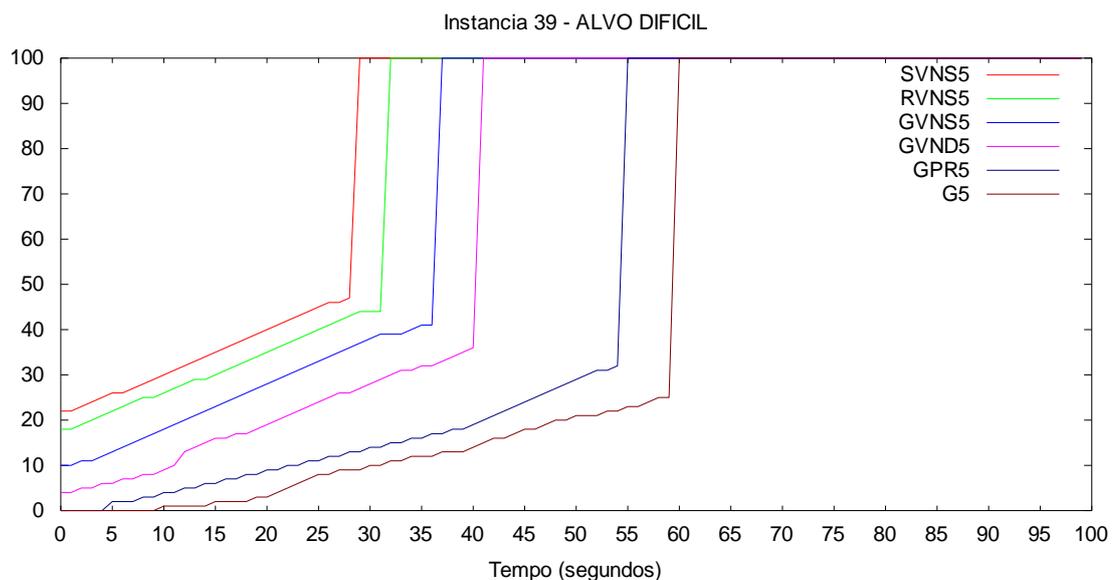


Figura 4.15 – Análise probabilística da instância 39 – alvo difícil

Pela Figura 4.15 é constatado que a versão do SVNS o SVNS5 apresenta o melhor resultado, assim como, nos testes anteriores. O SVNS5 atingi o alvo em 28 segundos, tem-se na sequencia como os melhores resultados RVNS5, GVNS5, GVND5, GPR5 e G5. Informa-se que o GVND5 representa também os resultados das versões VNS5 e GRVND5 que apresentam resultados similares.

E o pior resultado continua com o GRASP utilizando o Construtor 05 e Buscas Locais BL-01, BL-04, BL-05, ou seja, o G5 que converge ao alvo com 59 segundos, sendo 30 segundos a mais que o melhor resultado.

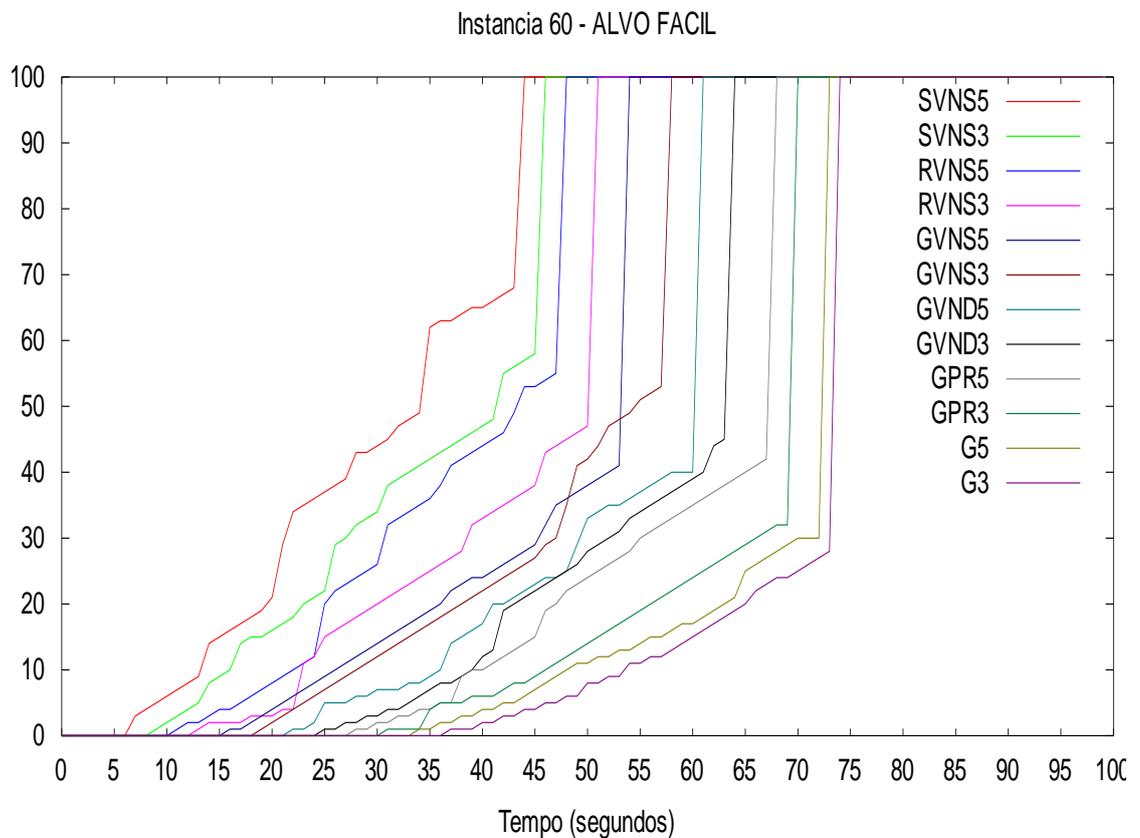


Figura 4.16 – Análise probabilística da instância 60 – alvo fácil

Com base na Figura 4.16 temos a análise probabilística da instância 60 (considerada de grande porte) para o alvo fácil, observa-se que os algoritmos apresentados apresentam mudanças significativas em relação aos tempos computacionais exigidos quando se compara com os resultados das instâncias de pequeno e médio porte. O algoritmo SVNS5 atingir o alvo em 42 segundos na instância 60, ou seja leva muito mais tempo do que o utilizado na instância 39 que levou 14 segundos e na instância 28 chega ao alvo em 7 segundos.

O Construtor 1 continua sem atingir o alvo em nenhuma das versões dos algoritmos gerados. E as versões do construtor 2 e do 4 continuaram apresentando baixo desempenho

pois a maioria de seus algoritmos não consegue atingir o alvo, em nenhuma das 100 execuções e nem dentro do limite estabelecido.

Já os piores resultados foi representado pelo GRASP através do algoritmo G5 e G3 e são também os que consomem mais tempo de execução para atingir o alvo, o primeiro leva 72 segundos e o segundo 74s.

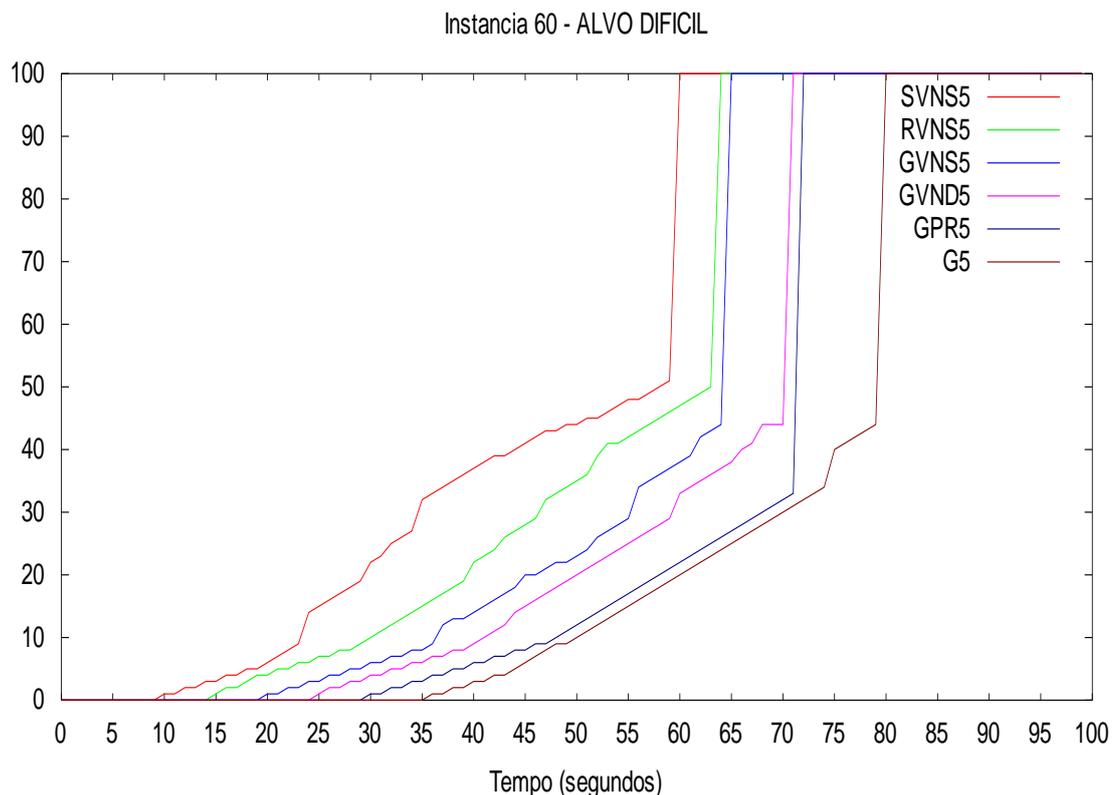


Figura 4.17 – Análise probabilística da instância 60 – alvo difícil

Com base na Figura 4.17 temos a análise probabilística da instância 60 (considerada de grande porte) para o alvo difícil. Optou-se por mostrar somente os melhores resultados obtidos. O pior algoritmo foi o G5 que levou aproximadamente 80 segundos, enquanto o melhor resultado o algoritmo SVNS5 atingi 100% de probabilidade em 59 segundos. O segundo melhor resultado fica com o algoritmo RVNS5 que conseguiu convergir em 63 segundos. As versões VNS5 e GRVND5 apresentam resultados iguais ao GVND5 por isso optou-se por demonstrar somente o resultado do GVND5 que leva 64 segundos para atingir o alvo.

Pode-se concluir que em todas as instâncias seja ele de pequeno porte (instância 28), de médio porte (instância 53) ou de grande porte (instância 60), os resultados para atingir o alvo difícil se repetem onde o SVNS5 apresenta o melhor resultado. O algoritmo G3 que representa GRASP Padrão com Construtor-03 e Busca Locais BL-01, BL-04 e BL-05 se

mostrou como o pior resultado em todos os experimentos no que se refere ao alcance do alvo fácil e o algoritmo G5 que representa o GRASP Padrão com Construtor-05 e Busca Locais BL-01, BL-04 e BL-05 se mostrou como o pior resultado em todos os experimentos no que se refere ao alcance do alvo difícil.

4.6 ANÁLISE DE ROBUSTEZ DOS RESULTADOS

De forma a avaliar os algoritmos no que concerne à robustez, foi aplicada uma análise estatística básica. Mais especificamente, os k melhores algoritmos foram executados 200 vezes, considerando cada uma das instâncias. A partir dos resultados obtidos com as 200 execuções calculou-se a solução média dos melhores algoritmos, o desvio padrão e os coeficientes de variação das instâncias 28 (pequeno porte), 39 (médio porte) e 60 (grande porte). A Tabela 4.8 a seguir trazem estas medidas e a melhor solução (solução *best*) obtida a partir das Tabelas presentes no Apêndice A, para uma instância de pequeno, médio e grande porte e a Tabela 4.9 traz o melhor tempo de execução de cada algoritmo e o tempo médio de cada execução de algoritmo em segundos.

Tabela 4.8 Resultados de Análise de Robustez para a instância 28 (pequeno porte), 39 (médio porte) e 60 grande (porte)

INSTÂNCIA	28		39		60	
	SVNS5	RVNS	SVNS5	RVNS	SVNS5	RVNS
SOLUÇÃO BEST	25,89	25,89	73,06	73,06	108,73	108,73
Solução Média	25,89	25,89	70,85	72,19	110,02	114,21
Desvio-Padrão	0,00	0,00	0,94	1,28	3,63	5,09
Coeficiente-Variação	0,00	0,00	0,013	0,017	0,032	0,044

Para a instância 28 (pequeno porte) e a instância 39 (médio porte) os algoritmos SVNS5 e RVNS5 se mostraram robustos, visto que para a primeira instância não apresentou nenhuma variação nos valores de desvio-padrão e, conseqüentemente, nos valores de coeficiente de variação. Já a instância 39 apresenta valores de desvio-padrão e coeficiente de variação relativamente baixos. A instância 60 apresenta alterações nos valores de desvio-

padrão, mas mantém a robustez dos algoritmos SVNS5 e RVNS5 com baixa variação no seu coeficiente de variação.

Tabela 4.9 Medidas dos tempo de processamento dos algoritmos (segundos)

INSTÂNCIA	28		39		60	
ALGORITMO	SVNS5	RVNS5	SVNS5	RVNS5	SVNS5	RVNS5
TEMPO BEST	30	32	2308	2317	2760	2741
Tempo Médio	48	43	2365	2340	2828	2786

No que diz respeito aos tempos de processamento das instâncias 28 e 39 observa-se um equilíbrio entre os tempos dos dois algoritmos (SVNS5 e o RVNS5) tendo como base seus tempos médios que demonstram valores muito próximos. Já a instância 60 percebe-se visivelmente um tempo de processamento maior algoritmo SVNS5 em comparação com o RVNS5.

CAPÍTULO 5 – CONCLUSÕES E TRABALHOS FUTUROS

O presente capítulo apresenta as conclusões dos estudos e experimentos realizados a respeito do problema de agrupamento com restrições de capacidade e conectividade para um caso real do Censo Demográfico 2010 do IBGE. Também são descritos os futuros desdobramentos deste trabalho de tese.

5.1 CONCLUSÕES

Neste trabalho foi proposto um estudo das metaheurísticas GRASP e VNS aplicadas ao problema de clusterização com restrições de capacidade e de conectividade. A partir desse estudo foram elaborados métodos construtivos, de buscas locais, de memória adaptativa utilizando a reconexão de caminhos e de busca local exaustiva usando um VND e RVND, aplicado ao Grafo Original e a AGM construída com *Kruskal* padrão e com *Kruskal* modificado.

Neste sentido, foram propostas diferentes versões de heurísticas, a saber: uma versão que difere da tradicional (GRASP da literatura) por utilizar o mecanismo de reconexão de caminhos, uma versão que utiliza uma busca local exaustiva (módulo VND), uma versão que utiliza uma busca local exaustiva randômica (módulo RVND), uma versão que utiliza o VNS padrão, uma versão que utiliza um GVNS (*General Variable Neighborhood Search* ou Busca Geral Com Vizinhança Variável), uma versão que utiliza um RVNS (*Reduced Variable Neighborhood Search* ou Busca Reduzida Em Vizinhança Variável) e uma versão que utiliza um SVNS (*Skewed Variable Neighborhood Search*) ou Busca Inclinada Com Vizinhança Variável.

Os resultados e as análises apresentados no Capítulo 4 indicam que os algoritmos que operam sobre o Grafo Original tiveram considerável ganho de desempenho frente à AGM, sendo o Grafo Original e a AGM utilizados como “ponto de partida” para aplicação dos procedimentos de particionamento, de construção e de busca local. O Capítulo 4 apresenta ainda a AGM Modificada pela utilização de pesos aleatórios para as arestas. Numa primeira análise que trata dos gráficos, ou seja, do quantitativo das soluções obtidas por algoritmo, todos os algoritmos que utilizaram o Grafo Original obtiveram maior número de soluções melhores (*Gap* igual a 0%). Na avaliação probabilística dos resultados somente os algoritmos que utilizaram o Grafo Original conseguem alcançar o Alvo Fácil e Alvo Difícil. Durante a análise de robustez percebe-se que os melhores resultados foram também representados por algoritmos gerados a partir do Grafo Original. Já os algoritmos que utilizam a AGM com

Kruskal padrão teve um rendimento razoável quando compara-se o desempenho da AGM com pesos aleatórios. E na análise probabilística e de robustez a AGM com pesos aleatórios é melhor do que a AGM padrão, porém essas variações da AGM ficaram atrás do resultado do Grafo Original que continua sendo o melhor resultado. A estrutura do Grafo Original tende a ampliar as possibilidades de operação dos procedimentos de construção e busca local no que diz respeito às migrações de vértices, e assim gerar soluções válidas, mas facilmente, o que não pode ser repetido para a AGM construída com o algoritmo de *Kruskal* modificado e nem com a AGM construída com o algoritmo de *Kruskal* padrão.

A maior contribuição deste trabalho foi no que diz respeito à utilização de heurísticas como o GRASP com reconexão de caminhos, com VND e com RVND, além da utilização de VNS padrão e variações (GVNS, RVNS e SVNS), utilizados para a solução do problema de clusterização com restrições de capacidade e de conectividade.

Os resultados apresentados demonstram que as heurísticas que são geradas pela união de procedimentos de construção e seus procedimentos de busca local tende a ser mais complexas e com a utilização de hibridismo melhoram o desempenho do algoritmo que é construído com heurísticas padrão (GRASP Clássico e VNS Puro) sem nenhum tipo de combinação de metaheurísticas. Assim, o pior resultado foi observado a partir do GRASP padrão, seguido pelo GRASP com reconexão de caminho, posterior ao GRASP com VND, seguido do GRASP com RVND, e por fim VNS padrão e suas variações GVNS, RVNS e SVNS com o melhor resultado.

Destaca-se neste trabalho, o algoritmo SVNS5, que se manteve em primeiro lugar nos experimentos realizados através de execuções sistemáticas, tendo como critério de parada o número de iterações. Assim, procurou-se demonstrar sua eficácia no que se refere à qualidade das soluções obtidas e da obtenção de soluções válidas (restrições do problema são atendidas). Esta versão do SVNS5 que utiliza o Construtor 5 que cria uma espécie de super-nó capaz de unir vértices que estejam distantes uns dos outros, mas que sejam conexos e que estejam de acordo com o critério de capacidade pré-estabelecido no problema. Além disso, o SVNS5 demonstra ser um algoritmo eficiente pois converge mais rápido do que todas as outras versões para boas soluções, especialmente no caso de soluções alvo difíceis.

Em uma segunda etapa foi realizada uma comparação entre todas as heurísticas no que se refere a uma avaliação probabilística dos resultados e obteve-se a seguinte constatação: o SVNS5 obteve o melhor desempenho, permitindo melhor aproveitamento para os melhores valores (alvo difícil) e piores valores (alvo fácil) da função objetivo durante a análise probabilística empírica. Ao realizar os testes envolvendo soluções alvo, o RVNS5, RVNS3,

GVNS5 e GVNS3 conseguiram atingir os maiores números de alvos em tempos menores do que o algoritmo G5 (GRASP com Construtor 5) e G3 (GRASP com Construtor 3)

Percebe-se que os algoritmos que utilizaram o Construtor 1 apresentaram os piores resultados na obtenção de soluções válidas em todos os experimentos realizados. O segundo pior resultado fica com o construtor 2 que consegue melhor o desempenho dos algoritmos que utilizaram o Construtor 1, mas não consegue alcançar os resultados do construtor 4, que surge como um melhoramento do Construtor 2. Já o Construtor 3 consegue alcançar um grande número de soluções válidas, com um grande número de soluções interessantes e um menor número de soluções péssimas nos primeiros experimentos realizados. Mas nada comparado ao excelente resultado do Construtor 5 que pela própria essência deste método, busca soluções diversificadas e consegue alcançar o maior número de soluções melhores e um pequeno número de soluções péssimas nas primeiras análises realizadas.

E na análise probabilística a maioria das versões, principalmente algoritmos construídos com Grafo Original e que utilizaram o Construtor 5 conseguiram alcançar o alvo fácil e o alvo difícil. Percebe-se que a construção de soluções iniciais melhores (Construtor 3 e Construtor 5) permite que a busca local consiga tratar de soluções diferentes e próximas (maior variabilidade de soluções) de ótimos locais, e por consequência, próximas de soluções de melhor qualidade para tentar encontrar um ótimo global. E outra constatação foi que os algoritmos convergiram para a solução alvo de acordo com a sequência: primeiro o SVNS, segundo o RVNS e posteriormente o GVNS, o VNS, o GRVND, o GVND, o GPR e por último o GRASP G. Os experimentos computacionais para análise de robustez dos algoritmos mostram que a abordagem proposta é competitiva, pois consegue obter bons resultados. Além disso, apresentar um valor baixo do coeficiente de variação, que mostra que o algoritmo é robusto, e gera soluções com baixa variabilidade. E que relação entre a solução média dos melhores algoritmos com a solução *best* é de proximidade, mostrando o quão perto da meta esses algoritmos conseguem chegar.

Assim, conclui-se que tenha-se atingido o objetivo principal deste trabalho, ou seja, desenvolver formas eficientes e robustas da metaheurística GRASP e VNS para o problema de clusterização com restrições de capacidade e de conectividade.

Como desdobramentos deste trabalho de tese foram desenvolvidos os seguintes artigos:

Santos, Nádia Mendes, Gustavo Silva Semaan, and Luiz Satoru Ochi. "*Metaheuristic GRASP with path-relinking to the solution of the graph partitioning problem with capacity*

and connexity constraints." Intelligent Data Engineering and Automated Learning-IDEAL 2012. Springer Berlin Heidelberg, 2012. 630-641.

Santos, Nádia Mendes, Gustavo Silva Semaan, and Luiz Satoru Ochi, Brito, José André Moura. Metaheurística híbrida para a solução de problema de particionamento de grafos com restrições de capacidade e de conexidade. X OPTIMA , Concepción, CHILE, 2013.

Santos, Nádia Mendes, Gustavo Silva Semaan, and Luiz Satoru Ochi, Brito, José André Moura. Metaheurística híbrida para a solução de problema de particionamento de grafos com restrições de capacidade e de conexidade. ELAVIO (Escola Latino-Iberoamericana de Verão em Pesquisa Operacional), Areia-PB, BRASIL, Fev-2014.

Santos, Nádia Mendes, Gustavo Silva Semaan, and Luiz Satoru Ochi, Brito, José André Moura. Metaheurística GRASP e GRASP-RVND aplicadas a problemas agrupamento com restrição de capacidade e de conexidade. CLAIO XVII (XVII Congresso Latino-Ibero-Americano em Pesquisa Operacional), Monterrey, MEXICO, Outubro-2014 (**Aprovado**).

Santos, Nádia Mendes, Gustavo Silva Semaan, and Luiz Satoru Ochi, Brito, José André Moura. Metaheuristic GRASP and GRASP-RVND applied to clustering problems with capacity and connexity constraints. Pattern Recognition Letters. (**Submetido**).

5.2 TRABALHOS FUTUROS

Durante a realização deste doutorado várias possibilidades de pesquisas mostraram-se interessantes. Não obstante, por mais que não se tenha tido tempo suficiente para implementá-las, as mesmas estão descritas a seguir como trabalhos futuros a serem executados e submetidos em revistas ou eventos científicos, são elas:

- Penalização das soluções: inserir nos algoritmos uma variável referente às eventuais penalidades existentes nos *clusters*. Para isto, deve-se agregar ao custo da solução um custo adicional conforme o grau de inviabilidade da solução, ou seja, deve-se agregar na função objetivo um fator de penalização que possui valor proporcional à inviabilidade da solução.

- Desenvolvimento de uma formulação de programação inteira para o problema de clusterização com restrições de capacidade e de conexidade;

- Implementar a formulação matemática e utilizar um bom *Upper Bound* gerado a partir de uma solução viável de boa qualidade obtida pela melhor resultado das metaheurísticas aplicadas ao problema de clusterização com restrições de capacidade e de conexidade. A expectativa é reduzir o tempo de processamento da formulação para produzir dessa forma soluções viáveis, ou tentar reduzir o tempo para atingir o ótimo global.

REFERÊNCIAS

- [AGRAVAL ET AL 2005] Agraval, R.; Automatic Subspace Clustering of High Dimensional Data, *Data Mining and Knowledge Discovery* 11, pp. 5-33, 2005.
- [AIEX ET AL. 2007] Aiex, R. M., Resende, M. G. C., and Ribeiro, C. C. (2007). TTT plots: a perl program to create time-to-target plots. *Optimization Letters*, 1:355_366.
- [ANDRADE E CUNHA 2011] Andrade L, Cunha C. Algoritmo de colônia artificial de abelhas para um problema de clusterização capacitado. Escola Politécnica da USP, Brasil (2011).
- [ANDRADE 2009] Andrade, A.V., Assis, L.P., Caires, L.F.V.: Aplicação do Método Path-Relinking na resolução do Problema Roteamento de Veículos com Coleta e Entrega Simultâneas. XLIISBPO (2009).
- [AQUINO 2010] Aquino, A. A. Otimização em grafos: árvores geradoras com restrições. Monografia da Graduação de Computação. Universidade Federal de Pernambuco (UFPE). Centro de informática
- [ASSUNÇÃO ET AL., 2006] Assunção, R. M.; Neves, M. C.; Câmara, G., Freitas, C. Efficient regionalization techniques for socio-economic geographical units using minimum spanning trees. *International Journal of Geographical Information Science* 20(7): 797-811, 2006.
- [BASTOS ET AL., 2005] Bastos, L. O., Ochi, L. S.; Macambira, E.M. GRASP with Path Relinking for the SONET Ring Assignment Problem. *Proc. of the 5th International Conference on Hybrid Intelligent Systems (HIS2005)*, pp. 239-244, 2005.
- [BAUM, 1986] Baum, E.B. Iterated descent: A better algorithm for local search in combinatorial optimization problems. Technical report Caltech, Pasadena, CA. 1986.
- [BAXTER, 1981] Baxter, J. Local optima avoidance in depot location. *Journal of the Operational Research Society* 32, 1981.
- [BERKHIN 2002] Berkhin, P. Survey of Clustering Data Mining Techniques. *Accrue Software*, 2002
- [BINATO ET AL 2001] Binato, S.; Pereira, M. & Granville, S. A new Benders decomposition approach to solve power transmission network design problems. *IEEE Transactions on Power Systems*, 16(2), 235-240, May, 2001.
- [BLUM AND ROLI 2003] Blum, C.; Roli, A. Metaheuristics in Combinatorial Optimization: Overview and Conceptual Comparison. *ACM Computing Surveys*, ACM, Nova York, NY, EUA, v. 35, n. 3, p. 268-308, 2003.
- [BOLEY ET AL 1999] Boley, D.; Gini, M.; Gross, R.; Han, E.H.; Hastings, K.; Karypis, G.; Kumar, V.; Mobasher, B. & Moore, J. Partitioning based clustering for Web document categorization. *Decision Support Systems*, 27, 329-341, 1999.

[BONAMI 2012] Bonami, Pierre, et al. "On the solution of a graph partitioning problem under capacity constraints." *Combinatorial Optimization*. Springer Berlin Heidelberg, 2012. 285-296.

[BRITO E MONTENEGRO 2010] Brito, J. A. M. ; Montenegro, F. M. T.. Um Algoritmo VNS Aplicado ao Problema de Definição de Áreas de Ponderação. In: Simpósio de Pesquisa Operacional e Logística da Marinha, 2010, (Rio de Janeiro). Anais do SPOLM 2010, 2010.

[BRITO ET AL., 2010] Brito, J. A. M.; Antonio, J. R. D.; Bruno, F.C; Flávio, M. T. M. Um algoritmo de agrupamento aplicado à Definição das áreas de ponderação do Censo Demográfico 2010.

[BRITO ET AL., 2004] Brito, J. A. M.; Montenegro , F. M. T.; Brito L. R.; Passini , M. M.. Uma formulação de programação inteira para o problema de criação de áreas de ponderação agregadas, Anais do SOBRAPO, 2004.

[BROWN AND BOLKER 2004] Brown, D.H., AND Bolker B.M.. The effects of disease dispersal and host clustering on the epidemic threshold in plants. *Bulletin of Mathematical Biology* 66 (March 2004), 341-371.

[CENSO DEMOGRÁFICO 2010] Censo Demografico 2010- Resultados Gerais da Amostra – IBGE – ISSN 0104-3145.

[CESELLI ET AL 2013] Ceselli, Alberto, Fabio Colombo, Roberto Cordone, and Marco Trubian. "Employee workload balancing by graph partitioning." *Discrete Applied Mathematics* (2013). Volume 165, 2014, pp 112-129. Elsevier Science Publishers B. V. Amsterdam, The Netherlands, The Netherlands. ISSN 0166-218X

[CERVEIRA 2014] CERVEIRA A.; BAPTISTA J.; PIRES, E. J. S.; *Advances in Intelligent Systems and Computing* Volume 239, 2014, pp 109-119 ISBN 978-3-319-01853-9. Salamanca, Spain 2014.

[CHAVES E LORENA, 2005] Chaves, A. A.; Lorena, L. A. N. Hybrid Algorithms with Detection of Promising Areas for the Prize Collecting Travelling Salesman Problem. In: *Proceedings of the Fifth International Conference on Hybrid Intelligent Systems (HIS '05)*. Washington, DC, EUA: IEEE Computer Society, 2005. p. 49-54. ISBN 0-7695-2457-5.

[CHIOU AND LAN, 2001] Chiou, Y.C. Lan, L.W. Genetic Clustering Algorithms. *European Journal of operational Research* 135, 2001.

[COLGANO 2012] Aquino, A. A. Uma proposta para a formalização do problema de Clusterização em grafos. Dissertação de Mestrado de Ciência em Computação. Universidade Federal do Paraná (UFPE). Centro de informática.

[CORTEZ ET AL 2012] Cortez, B.F; Brito, J.A.M. ; Dias, A.J.R; Montenegro, F.M.T.. Um algoritmo de agrupamento aplicado à definição das áreas de ponderação do Censo Demográfico de 2010. 20º Simpósio Nacional de Probabilidade e Estatística (JP). 2012.

[DAMODAR E PRASANTA, 2013] Edla, Damodar Reddy, and Prasanta K. Jana. "Minimum Spanning Tree Based Clustering Using Partitional Approach." *Proceedings of the*

International Conference on Frontiers of Intelligent Computing: Theory and Applications (FICTA). Springer Berlin Heidelberg, 2013.

[DENG AND BARD 2011] Deng, Yumin, and Jonathan F. Bard. "A reactive GRASP with path relinking for capacitated clustering." *Journal of Heuristics* 17.2 (2011): 119-152.

[DIAS AND OCHI, 2003] Dias, C. R., and Ochi, L. S. Efficient evolutionary algorithms for the clustering problem in directed graphs. In *IEEE-CEC Congress on Evolutionary Computation em CD-ROM* (Canberra – Austrália, 2003), pp. 983-990

[DIAS, 2004] Dias, C.R. Algoritmos Evolutivos para o Problema de Clusterização de Grafos Orientados - Desenvolvimento e Análise Experimental. Dissertação de Mestrado, Universidade Federal Fluminense (UFF), 2004.

[DOVAL ET AL., 1999] Doval, D., Mancoridis, S. e Mitchell, B. S. Automatic Clustering of Software Systems using a Genetic Algorithm. In 1999 International Conference on Software Tools and Engineering Practice (STEP '99), 1999

[DREW, 2003] Drew, M. S., and Au, J. Clustering of compressed illumination-invariant chromaticity signatures for efficient video summarization. *Image and Vision Computing* 21 (August 2003), 705-716.

[FANG ET AL, 2003] Fang, J. T., Shyu, W. L., Wu, C. S., and Chen, K. J. Clustering source output bits and equalizing bit error sensitivity to improve the quality and robustness of transmitted images over wireless channels. *Signal Processing: Image Communication* 18 (November 2003), 947-956.

[FASULO, 1999] Fasulo, D. An Analysis of Recent Work on Clustering Algorithms. Technical Report, Dept. of Computer Science and Engineering, Univ. of Washington, 1999.

[FESTA 2007] Festa, P.; Pitsoulis, P.M; L. S and Resende, M.C.G. GRASP with path-relinking for the weighted MAXSAT problem. *Journal of Experimental Algorithms*, 11, 2007 Article 2-4: 1-16.

[FEO AND RESENDE, 1995] Feo, T.A.; Resende, M.G.C., Greedy randomized adaptive search procedures, *Journal. of Global Optimization*, 6, 109—133, 1995.

[FISHER 1987] FISHER, L. Knowledge acquisition via incremental conceptual clustering, *Machine Learning* 2, pp. 139-172. 1987

[GARAI AND CHAUDHURI 2004] Garai, G., Chaudhuri, B. B.; A novel genetic algorithm for automatic clustering *Pattern Recognition Letters*. pp. 173-187. 2004

[GLOVER ET AL, 2004] Glover, F.; Laguna, M.; Martí, R. Scatter Search and Path Relinking: Foundations and Advanced Designs. In: Onwubolu, G. C.; Babu, B. V. (Ed.). *New Optimization Techniques in Engineering*. Heidelberg: Springer-Verlag, 2004. p. 87-100.

[GLOVER AND KOCHENBERGER, 2002] Glover, F. ; Kochenberger, G. A. *Handbook of Metaheuristics*. Kluwer Academic Publishers, 2002.

[GLOVER ET AL, 2000] Glover, F.; Laguna, M.; Martí, R. Fundamentals of Scatter Search and Path Relinking. *Control and Cybernetics*, v. 29, n. 3, p. 653-684, 2000.

[GLOVER 1999] Glover F. "Scatter Search and Path Relinking," In: D Corne, M Dorigo and F Glover (eds.) *New Ideas in Optimisation*, Wiley, 1999.

[GLOVER 1996] Glover, F. Tabu Search and Adaptive Memory Programming - Advances, Applications and Challenges. In: Barr, R. S.; Helgason, R. V.; KENNINGTON, J. L. (Ed.). *Interfaces in Computer Science and Operations Research*. Dordrecht, MA, EUA: Kluwer Academic Publishers, 1996. p. 1-75.

[GLOVER AND LAGUNA, 1997] Glover, F., Laguna, M.: *Tabu Search*. Kluwer, Boston (1997) ISBN 0-7923-9965-X.

[GLOVER AND MARTI, 2006] Glover, F. And Marti, R. (2006) "Metaheuristics for Training Neural Networks", Springer Science, New York, Chapter 4.

[GUO ET AL, 2003] GUO, H., Renaut, R., Chen, K. and Reiman, E. Clustering huge data sets for parametric pet imaging. *Biosystems* 71 (Septembr 2003), 81-92.

[GREISTORFER 2004] Greistorfer, P., 2004. Experimental pool design: Input, output and combination strategies for scatter search. In: Resende, M. G. C., de Sousa, J. P. (Eds.), *Metaheuristics: Computer Decision-Making*, Kluwer Academic Publishers, Boston, pp. 1-18.

[HAN AND KAMBER, 2001] Han, J., and Kamber, M. *Data Mining: Concepts and Techniques*. Morgan Kaufmann, 2001.

[HANSEN AND MLADENOVIC 2003] Hansen, P.; Mladenovic, N. Variable Neighborhood Search. In: GLOVER, F. W.; KOCHENBERGER, G. A. (Ed.). *Handbook of Metaheuristics*. Boston, Dordrecht: London: Kluwer Academic Publisher, 2003. p. 145-184.

[HANSEN AND MLADENOVIC 2001] Hansen, P.; Mladenovic, J-Means: A new local search heuristic for minimum sum-of-squares clustering, *Pattern Recognition* 34: 405-413, 2001.

[HARTUV AND SHAMIR, 1999] Hartuv, E.; Shamir, R.. A Clustering Algorithm based on Graph Connectivity. Technical Report, Tel Aviv University, Dept. of Computer Science, 1999.

[HERNÁNDEZ-PÉREZ ET AL 2009] Hernández-pérez, H.; Rodríguez-martín, I.; Salazar-gonzález, J. J. A hybrid GRASP/VND heuristic for the one-commodity pickup-and-delivery traveling salesman problem. *Computers & Operations Research*, v. 36, n. 5, p. 1639 - 1645, 2009

[HO AND GENDREAU, 2006] Ho, S.C., Gendreau, M.: Path-relinking for the vehicle routing problem. *Journal of Heuristics* 12(1), 55–72 (2006).

[HRUSCHKA, E. R, 2001] Algoritmos genéticos de agrupamento para extração de regras de redes neurais. Tese de Mestrado, Universidade Federal do Rio de Janeiro, 2001.

[JAIN, 2010] Jain, A. K., "Data Clustering: 50 Years Beyond K-Means" , Pattern Recognition Letters, Vol. 31, No. 8, pp. 651-666, 2010.

[LAGUNA AND MARTI, 1999] Laguna, M.; Martí, R. Grasp and Path Relinking for 2-Layer Straight Line Crossing Minimization. INFORMS Journal on Computing, INFORMS, Institute for Operations Research and the Management Sciences (INFORMS), Linthicum, Maryland, USA, v. 11, n. 1, p. 44-52, 1999.

[LI ET AL 1994] Li, Y.; Pardalos, P.M.; Ramakrishnan, K.G. & Resende, M.G.C. (1994). Lower bounds for the quadratic assignment problem. Operations Research, 50, 387-410

[LOURENÇO ET AL 2002] Lourenço, H. R.; Martin, O. C.; Stützle, T. Iterated Local Search. In: Glover, F.; Kochenberger, G. (Ed.). Handbook of Metaheuristics. [S.l.]: Kluwer Academic Publishers, Boston, 2002. p. 321-353

[KAUFMAN 1990]KAUFMAN, Leonard; ROUSSEEUW, Peter J. Finding groups in data: an introduction to cluster analysis. New York: Wiley, 1990.

[MLADENOVIC AND HANSEN, 1997] Mladenovic, N.; Hansen, P. Variable Neighborhood Search. Computers Operations Research 24,1997.

[MLADENOVIC, 1995] Mladenovic, N. A Variable neighborhood algorithm: a new metaheuristic for combinatorial optimization. Abstracts of papers presented at Optimization Days, Montréal, 1995.

[NEIL AND RICO, 2013] Neil O., and Rico Z.. "Chain-Constrained Spanning Trees." Integer Programming and Combinatorial Optimization. Springer Berlin Heidelberg, 2013. 324-335.

[NEVES, 2003] Neves, M.C. Procedimentos Eficientes para Regionalização de Unidades Socioeconômicas em Bancos de Dados Geográficos. Tese de Doutorado, INPE, São José dos Campos, 2003.

[MATEUS ET AL 2011] Mateus, G.R, Resende, M.G.C. and Silva, R.M.A. GRASP with path-relinking for the generalized quadratic assignment problem. J. of Heuristics, 17:527–565, 2011.

[MANDAL ET AL 2012] Mandal, A., Dutta, J., & Pal, S. C. (2012). A New Efficient Technique to Construct a Minimum Spanning Tree. International Journal, 2(10).

[MONTEIRO 2009] Monteiro, J. B. Indicador de Criminalidade Geral Baseado em Métodos Multivariados e Estatística Espacial para Controle na Segurança Pública do Estado Monografia de Conclusão do Bacharelado em Estatística. Instituto de Matemática, UFRGS.

[MURTY ET AL 2014] MURTY, M. R.; MURTHY, J. V.R.; REDDY P.V.G.D Prasad.; NAIK, A.; SATAPATHY, S.C. Homogeneity Separateness: A new validity measure for clustering problems. CT and Critical Infrastructure: Proceedings of the 48th Annual Convention of Computer Society of India- Vol I Advances in Intelligent Systems and Computing Volume 248, 2014, pp 1-10

[OPENSHAW 1977] Openshaw, S., A geographical solution to scale and aggregation problems in regionbuilding, partitioning and spatial modelling. Transactions of the Institute of British Geographers (New Series), 2, pp. 459–472, 1977.

[PENA ET AL 1999] PENA, J. M., Lazano, J. A., and Larranaga, P. An empirical comparison of four initialization methods for the K-means algorithm. Pattern Recognition Lett., 1999, 20, 1027–1040.

[PIAGET 1996] PIAGET. J Biologia e Conhecimento. 2ª Ed. Vozes : Petrópolis, 1996

[PITSOULIS AND RESENDE 2002] Pitsoulis, L. and Resende, M.G.C. (2002) Greedy randomized adaptive search procedures.. In P.M.Pardalos and M.G.C.Resende, editors, Handbook of Applied Optimization, pp. 168–181, Oxford University Press.

[RAIDL, 2006] Raidl, G.R. 2006. A unified view on hybrid metaheuristics. In Hybrid metaheuristics, Lecture notes in computer science 4030. Springer, Berlin, Heidelberg, 1-12.

[RESENDE AND FEO 1996] Resende, M. G. C. e Feo, T. A GRASP for satisfiability, em Johnson, D. S. e Trick M. A. (Eds) Cliques, Coloring, and Satisfiability: Second DIMACS Implementation Challenge, 26, 499-520. DIMACS Series on Discrete Mathematics and Theoretical Computer Science, American Mathematical Society, 1996

[RESENDE E RIBEIRO, 1997] Resende, M.G.C., Ribeiro, C.C., 1997 “A GRASP for Graph Planarization”, Networks, 29:173-189.

[RESENDE E RIBEIRO 2002] Resende, M.G.C., Ribeiro, C.C., 2003. Greedy randomized adaptive search procedures. In Glover, F., Kochenberger, G. (eds) Handbook of Metaheuristics. Kluwer, Dordrecht, pp. 219–249.

[RIBEIRO E SOUZA 2002] Ribeiro, C.C., Souza, M.C., 2002. Variable neighborhood search for the degree-constrained minimum spanning tree problem. Discrete Applied Mathematics, 118, 43–54.

[RIBEIRO E VIANA 2005] Ribeiro, C.C. Ribeiro and Vianna, D.S. A GRASP/VND heuristic for the phylogeny problem using a new neighborhood structure. International Transactions in Operational Research, 12:325–338, 2005.

[RODRIGUES 2001] Rodrigues, F. L. Metaheurística e sistema de suporte à decisão no gerenciamento de recursos florestais. 2001. 225 f. Tese (Doutorado em Manejo Florestal) – Universidade Federal de Viçosa, Viçosa, 2001.

[SANTOS ET AL 2012] Santos, Nádia Mendes, Gustavo Silva Semaan, and Luiz Satoru Ochi. "Metaheuristic GRASP with path-relinking to the solution of the graph partitioning problem with capacity and connectivity constraints." Intelligent Data Engineering and Automated Learning-IDEAL 2012. Springer Berlin Heidelberg, 2012. 630-641.

[SANTOS ET AL 2013] Santos, Nádia Mendes, Gustavo Silva Semaan, and Luiz Satoru Ochi. Brito, José André Moura. Metaheurística híbrida para a solução de problema de particionamento de grafos com restrições de capacidade e de conectividade. X OPTIMA , Concepción, CHILE, 2013.

[SANTOS ET AL 2014] Santos, Nádia Mendes, Gustavo Silva Semaan, and Luiz Satoru Ochi. Brito, José André Moura. Metaheurística híbrida para a solução de problema de particionamento de grafos com restrições de capacidade e de conectividade. ELAVIO (Escola Latino-Iberoamericana de Verão em Pesquisa Operacional), Areia-PB, BRASIL, Fev-2014.

[SCHEUERER, 2006] Scheuerer, S. W. , R. A scatter search heuristic for the capacitated clustering problem. European Journal of Operational Research vol. 169, 2006.

[SEMAAN ET AL., 2008] Semaan, G. S., Ochi, L. S., Brito, J. A. M.; Montenegro, F. An Efficient Evolutionary Algorithm for the Aggregated Weighting Areas Problem. Proc. of the International Conference on Engineering Optimization, 2008.

[SEMAAN ET AL., 2009] Semaan, G.S., Brito, J. A. M.; Ochi, L. S. Um algoritmo evolutivo híbrido aplicado ao problema de clusterização em grafos com restrições de capacidade e contiguidade. Anais do IX Congresso Brasileiro de Redes Neurais e Inteligência Computacional (IX CBRN),Ouro Preto/MG, 2009.

[SEMAAN 2010] Semaan, G.S.: Algoritmos Heurísticos para o Problema de Particionamento de Grafos com Restrições de Capacidade e Conectividade. Dissertação de Mestrado, Universidade Federal Fluminense (UFF), Niterói – RJ (2010)

[SHIEH AND MAY, 2001] Shieh, H.M., May, M.D. Solving the Capacitated Clustering Problem with Genetic Algorithms. Journal of the Chinese Institute of Industrial Engineers, Vol. 18, 2001.

[SILVA ET AL 2000] Silva, M. B. da; Drummond, L. M. de A.; Ochi, L. S. Metaheurística GRASP/VNS para a solução de Problemas de Otimização Combinatória. In: Anais do XXXII Simpósio Brasileiro de Pesquisa Operacional (SBPO). [S.l.: s.n.], 2000. v. 1, p. 352-360.

[SOARES, 2004] Soares, S.S.R.F. Metaheurísticas para o Problema da Clusterização Automática, Dissertação de Mestrado, (UFF), Niterói-RJ, 2004.

[SOUZA 2011] Souza, R. F.F.: Planejamento da Expansão de Sistemas de Distribuição Usando a Metaheurística de Busca em Vizinhança Variável. Dissertação de Mestrado, Universidade Estadual Paulista “Julio de Mesquita Filho” (Campus de Ilha Solteira), Ilha Solteira – SP (2011)

[SPATH, 1980] Spath, H. Cluster Analysis Algorithms for Data Reduction and Classification of Objects. John Wiley & Sons, Ellis Horwood Ltd., 1980.

[STEINLEY AND BRUSCO 2007] Steinley, Douglas and Michael J. Brusco, “A comparison of heuristic procedures for minimum within-cluster Sums of squares partitioning” Psychometrika—vol. 72, no. 4, 583–600, 2007

[TRINDADE AND OCHI, 2006] Trindade, A.R.; Ochi, L.S. Um algoritmo evolutivo híbrido para a formação de células de manufatura em sistemas de produção. Abstracts in Operational Research / Statistical Theory and Methods Abstracts) vol. 26(2), 2006.

[TRINDADE AND OCHI, 2004] Trindade, A. R., and Ochi. Desenvolvimento e análise experimental de um algoritmo evolutivo para o problema de clusterização em sistemas de manufatura. In *Congresso Brasileiro de Computação (IV CBcomp) – 2004*.

[VANETIK, 2013] Vanetik, Natalia. "Mining Graphs of Prescribed Connectivity." *Knowledge Discovery, Knowledge Engineering and Knowledge Management*. Springer Berlin Heidelberg, 2011. 29-44.]

[WADSWORTH 1996] Wadsworth, B.J. *Inteligência e afetividade da criança na teoria de Piaget*. São Paulo: Pioneira, 1996.

[WANG, 2003] Wang, J. Formation of machine cells and families in cellular manufacturing systems using a linear assignment algorithm. *Automatica* 39 (April 2003), 1607-1615.

[WELCH, 1983] Welch, J. W. Algorithmic complexity: three NP-hard problems in computational statistics. *Journal of Statistical Computation and Simulation*, 15, 17-25. DOI: 10.1080/00959658208810560.

[ZAGOURAS ET AL 2012] Zagouras, Athanassios, Athanassios A. Argiriou, Helena A. Flocas, George Economou, and Spiros Fotopoulos. "An advanced method for classifying atmospheric circulation types based on prototypes connectivity graph." *Atmospheric Research* (2012).

APÊNDICE A – APRESENTAÇÃO DAS TABELAS COM OS RESULTADOS COMPUTACIONAIS OBTIDOS NA EXECUÇÃO DOS ALGORITMOS PROPOSTOS NESTE TRABALHO PARA CADA UMA DAS 64 INSTÂNCIAS OBTIDAS DO CENSO DEMOGRÁFICO 2010.

Tabela A.1 – Resultados GRASP Padrão – Grafo Original para obtenção de 3 clusters

I	Solução best	GRASP PADRÃO									
		G1		G2		G3		G4		G5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	35	112	23	95	21	106	28	109	19	104
2	39,08	42	214	34	208	24	171	33	204	22	183
3	5,72	45	28	38	15	29	27	26	29	20	24
4	26,14	47	162	43	137	32	119	35	162	28	119
5	7,35	27	65	21	34	10	33	18	67	12	30
6	6,41	21	57	17	21	0	27	8	52	3	30
7	6,17	14	44	1	20	0	27	8	38	0	29
8	4,96	17	32	0	22	0	25	0	29	0	20
9	14,35	36	85	6	61	12	52	21	63	18	55
10	19,78	39	117	32	91	19	98	27	104	22	86
11	10,27	47	86	41	45	28	40	33	83	25	39
12	17,33	20	116	19	80	15	71	17	104	13	65
13	7,42	27	77	24	51	7	33	18	70	11	31
14	5,94	45	73	44	43	19	27	36	64	29	29
15	18,53	41	80	31	92	13	71	25	102	17	75
16	7,09	38	69	33	33	19	25	28	65	21	29
17	10,81	59	96	47	51	32	43	43	84	29	40
18	6,33	30	57	18	29	1	26	8	42	2	31
19	57,14	47	1479	39	1467	27	1381	42	1449	37	1368
20	49,02	91	1404	83	1374	66	1307	74	1340	69	1299
21	70,51	23	1603	18	1582	11	1412	15	1467	10	1398
22	22,17	16	117	12	82	7	91	0	113	2	100
23	6,39	25	68	0	25	0	27	7	48	0	31
24	6,30	13	57	11	28	0	23	9	42	2	30
25	82,44	22	51	6	19	2	26	0	41	2	23
26	12,68	128	476	114	388	97	451	104	476	85	417
27	3,27	63	114	56	53	45	32	49	98	46	41
28	25,89	12	33	8	28	0	20	5	24	0	17
29	26,01	66	151	57	127	38	143	52	139	41	114
30	15,48	71	184	68	149	32	177	43	165	29	123
31	78,30	50	101	35	76	18	65	23	79	17	64
32	6,41	127	1883	101	1860	76	1671	80	1764	75	1693
33	20,08	32	55	19	30	1	27	7	45	0	30
34	8,15	43	61	28	29	17	36	28	48	10	22
35	25,44	34	129	33	87	12	92	29	110	15	88
36	37,83	63	110	57	98	14	119	31	135	10	111
37	56,91	59	181	46	163	28	168	39	174	25	154
38	53,49	98	1460	64	1439	55	1335	60	1417	52	1352
39	73,06	82	1444	67	1402	47	1329	53	1391	41	1314
40	5,37	20	43	9	19	0	22	0	28	0	23
41	19,24	31	101	22	79	11	75	18	98	13	72
42	25,67	33	146	24	123	19	117	24	135	16	108
43	93,18	187	2002	146	1995	131	1811	149	1830	138	1797
44	6,53	29	70	23	49	2	34	8	51	4	30
45	39,41	62	217	57	194	43	228	46	215	39	183
46	24,37	51	140	39	134	32	129	34	125	28	112
47	12,99	55	136	48	70	31	69	42	117	35	44
48	45,78	83	302	67	244	48	237	50	259	42	215
49	16,04	46	90	37	81	26	72	32	93	28	67
50	26,07	49	171	48	155	29	130	33	148	27	129

51	98,16	134	2009	126	2001	99	1915	109	1997	102	1903
52	3,08	10	27	0	20	0	19	0	23	0	19
53	38,50	58	209	47	154	29	168	36	204	29	171
54	22,01	39	116	35	85	14	99	23	102	18	93
55	74,19	82	1692	78	1673	60	1495	80	1661	61	1510
56	68,27	77	1495	72	1481	53	1408	69	1450	57	1384
57	15,91	45	82	36	69	29	55	32	74	24	52
58	5,33	21	32	0	23	0	30	3	27	0	24
59	40,21	62	336	57	281	41	294	48	328	33	201
60	108,73	153	2038	149	2019	122	1971	137	2010	114	1908
61	60,49	82	370	76	292	57	354	64	312	59	333
62	102,53	165	2015	158	2011	127	1980	144	2013	118	1925
63	15,67	69	104	57	72	28	58	39	97	20	59
64	80,24	117	1898	104	1881	89	1722	99	1885	96	1702

Tabela A.2 – Resultados GRASP Padrão - AGM *Kruskal* modificado para obtenção de 3 clusters

I	Solução best	GRASP PADRÃO									
		AGMM1		AGMM2		AGMM3		AGMM4		AGMM5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	108	106	106	104	101	96	104	105	102	94
2	39,08	125	113	124	110	121	117	122	111	123	115
3	5,72	69	38	68	35	63	33	67	36	65	32
4	26,14	78	132	77	129	72	124	75	130	71	121
5	7,35	67	49	66	44	61	47	64	48	62	49
6	6,41	64	40	68	37	62	33	60	39	59	36
7	6,17	71	48	70	42	68	41	0	44	69	39
8	4,96	62	47	60	45	59	44	60	46	58	42
9	14,35	121	102	122	97	111	93	119	98	113	95
10	19,78	108	107	109	102	104	101	105	108	102	99
11	10,27	149	116	147	111	138	97	144	115	140	110
12	17,33	81	48	83	41	79	40	80	46	78	37
13	7,42	93	69	90	65	88	66	91	67	89	64
14	5,94	67	93	69	90	61	87	64	92	63	88
15	18,53	104	77	102	74	99	73	102	75	98	70
16	7,09	125	101	127	93	0	96	124	99	118	95
17	10,81	93	69	93	66	89	64	91	67	88	65
18	6,33	157	35	155	32	144	30	148	34	143	33
19	57,14	194	1924	194	1915	188	1903	193	1918	187	1900
20	49,02	187	2173	184	2154	173	2148	182	2164	179	2140
21	70,51	151	2100	153	2084	148	2077	0	2093	147	2081
22	22,17	94	41	92	36	89	34	93	38	88	33
23	6,39	102	36	104	32	96	30	100	35	97	27
24	6,30	75	39	75	31	72	36	73	37	71	35
25	82,44	187	397	186	381	181	385	183	388	179	383
26	12,68	214	125	215	120	206	118	212	122	208	119
27	3,27	67	24	66	21	0	24	62	23	59	22
28	25,89	101	127	104	124	98	119	99	125	97	118
29	26,01	138	121	135	117	129	118	132	120	128	121
30	15,48	142	154	141	148	135	147	140	149	137	145
31	78,30	164	2095	163	2114	159	2066	162	2087	158	2065
32	6,41	157	98	158	93	150	94	155	95	152	92
33	20,08	143	42	142	47	138	43	140	45	139	41
34	8,15	98	99	100	102	92	100	97	104	93	98
35	25,44	105	87	108	88	101	83	104	86	103	85
36	37,83	183	121	182	116	177	117	180	119	178	116
37	56,91	94	206	95	201	93	191	92	204	91	195
38	53,49	179	2033	173	2015	169	2017	170	2021	168	2016
39	73,06	228	2084	229	2066	226	2063	224	2071	221	2058
40	5,37	63	38	62	31	58	36	61	37	0	35
41	19,24	101	55	100	53	0	50	99	52	96	48
42	25,67	97	104	95	97	93	100	94	103	92	98

43	93,18	294	2113	293	2081	285	2077	291	2108	287	2071
44	6,53	81	47	81	41	75	45	80	46	77	47
45	39,41	143	243	142	236	139	230	140	239	138	228
46	24,37	218	152	217	144	214	140	215	148	212	142
47	12,99	137	97	136	91	125	91	128	93	124	92
48	45,78	141	204	142	195	134	187	139	198	137	194
49	16,04	95	117	96	114	89	108	93	115	89	110
50	26,07	102	135	104	127	98	125	100	133	96	131
51	98,16	293	2102	295	2081	289	2074	291	2090	287	2083
52	3,08	57	22	56	18	53	15	56	19	0	16
53	38,50	108	217	107	213	104	207	104	215	105	210
54	22,01	67	154	66	142	69	140	65	144	63	143
55	74,19	191	2187	190	2164	188	2165	190	2172	187	2152
56	68,27	218	104	216	102	211	100	215	103	212	98
57	15,91	92	116	93	119	89	121	90	118	88	117
58	5,33	53	27	51	32	49	30	50	31	48	27
59	40,21	74	393	74	384	71	379	73	387	72	368
60	108,73	427	2415	425	2404	422	2401	424	2425	420	2411
61	60,49	182	318	180	320	173	318	180	319	0	319
62	102,53	455	2488	453	2472	449	2464	453	2477	450	2456
63	15,67	184	115	182	114	173	112	181	116	177	115
64	80,24	293	2101	287	2095	280	2076	284	2085	281	2079

Tabela A.3 – Resultados GRASP Padrão - AGM *Kruskal* padrão para obtenção de 3 clusters

I	Solução best	GRASP PADRÃO									
		AGM1		AGM2		AGM3		AGM4		AGM5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	129	99	128	95	126	87	129	96	124	83
2	39,08	148	120	144	117	135	114	141	118	137	112
3	5,72	73	39	60	38	61	31	69	33	66	30
4	26,14	88	129	85	126	76	122	79	128	75	119
5	7,35	74	52	73	49	65	43	68	49	67	44
6	6,41	68	39	66	35	63	32	64	36	61	31
7	6,17	87	44	83	38	76	34	81	40	78	32
8	4,96	71	47	67	43	60	43	63	44	59	41
9	14,35	129	98	126	94	115	87	124	96	118	90
10	19,78	122	104	117	98	112	95	115	101	0	86
11	10,27	198	115	177	110	163	93	179	112	159	107
12	17,33	104	46	99	40	86	39	88	43	83	35
13	7,42	118	67	112	63	99	61	103	64	95	59
14	5,94	73	98	74	92	65	85	69	95	67	84
15	18,53	120	75	116	69	104	66	111	71	101	65
16	7,09	141	99	128	91	118	94	127	96	123	92
17	10,81	117	67	109	64	101	62	102	65	95	61
18	6,33	163	34	156	29	148	30	155	32	147	30
19	57,14	214	1919	205	1901	196	1893	199	1904	194	1891
20	49,02	188	2165	188	2128	185	2119	187	2137	183	2112
21	70,51	163	2093	161	2077	157	2057	0	2085	154	2069
22	22,17	105	38	100	34	91	33	99	35	93	32
23	6,39	116	39	115	35	96	28	112	37	107	25
24	6,30	83	40	80	36	78	34	80	38	76	34
25	82,44	204	383	189	375	181	371	183	376	180	369
26	12,68	250	119	244	116	225	102	241	117	236	103
27	3,27	70	24	71	19	66	23	69	22	68	20
28	25,89	104	125	100	120	99	112	98	119	95	109
29	26,01	147	120	148	117	135	114	139	118	133	116
30	15,48	168	143	155	128	141	140	153	140	144	129
31	78,30	177	2078	173	2069	174	2053	173	2071	171	2048
32	6,41	166	96	164	91	153	88	160	93	152	87
33	20,08	148	44	144	42	141	41	142	43	140	40
34	8,15	104	102	102	101	97	98	100	99	99	91

35	25,44	118	85	116	80	102	73	115	82	108	76
36	37,83	197	118	194	112	181	110	190	115	183	110
37	56,91	109	201	108	195	99	183	102	197	99	181
38	53,49	201	2023	194	2016	0	2009	191	2018	182	2003
39	73,06	258	2067	251	2051	245	2046	247	2055	238	2037
40	5,37	66	36	48	32	61	33	45	35	35	32
41	19,24	117	53	110	51	112	47	113	50	106	43
42	25,67	99	101	99	99	97	98	98	100	94	95
43	93,18	348	2110	325	2093	289	2064	314	2095	291	2053
44	6,53	88	49	84	45	73	40	83	46	79	43
45	39,41	166	234	157	227	146	222	151	229	145	217
46	24,37	248	148	244	143	224	141	239	144	221	140
47	12,99	144	94	140	89	124	90	142	91	128	90
48	45,78	153	199	150	191	144	184	149	193	140	187
49	16,04	96	111	94	106	91	101	93	109	90	104
50	26,07	150	129	142	127	112	124	141	128	98	123
51	98,16	321	2094	311	2082	304	2069	299	2084	306	2071
52	3,08	74	19	62	15	60	16	21	17	20	14
53	38,50	128	214	125	208	112	201	122	211	118	203
54	22,01	76	144	73	141	63	140	69	142	66	140
55	74,19	215	2128	212	2101	206	2081	208	2114	201	2098
56	68,27	248	102	241	97	222	99	239	100	227	96
57	15,91	111	124	105	117	99	118	101	115	97	114
58	5,33	59	32	56	33	53	29	52	30	51	26
59	40,21	97	381	92	369	87	367	91	373	88	358
60	108,73	458	2439	448	2402	444	2388	447	2419	441	2406
61	60,49	341	312	336	301	321	296	338	303	323	297
62	102,53	490	2475	483	2452	477	2448	480	2459	474	2440
63	15,67	202	120	197	116	192	110	199	118	191	114
64	80,24	324	2100	315	2079	304	2074	316	2080	308	2076

Tabela A.4 – Resultados GRASP com *Path-Relinking* – Grafo Original para obtenção de 3 clusters

I	Solução best	GRASP COM PATH-RELINKING									
		GPR1		GPR2		GPR3		GPR4		GPR5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	28	121	19	98	17	108	20	114	16	107
2	39,08	35	210	32	205	21	174	25	208	19	194
3	5,72	30	30	28	18	15	25	19	30	18	26
4	26,14	41	174	33	148	29	117	32	163	24	121
5	7,35	19	61	16	35	7	30	11	65	8	31
6	6,41	18	62	0	23	4	31	9	56	0	30
7	6,17	12	56	0	21	0	28	5	40	0	31
8	4,96	6	29	0	20	2	24	3	30	1	22
9	14,35	33	87	4	60	14	53	19	69	15	58
10	19,78	31	126	27	92	12	90	23	112	18	88
11	10,27	39	95	34	47	25	41	31	84	24	40
12	17,33	18	110	16	82	12	73	15	108	8	70
13	7,42	25	81	21	54	8	55	17	71	12	32
14	5,94	49	75	43	42	17	29	38	63	26	30
15	18,53	38	82	27	95	15	74	20	101	18	79
16	7,09	42	74	36	35	21	29	26	63	22	30
17	10,81	51	97	45	53	28	46	38	88	20	41
18	6,33	27	60	19	30	0	29	6	45	1	33
19	57,14	42	1574	35	1519	26	1433	39	1502	36	1423
20	49,02	74	1524	70	1504	57	1391	68	1475	64	1402
21	70,51	119	1699	96	1591	69	1508	92	1529	62	1496
22	22,17	14	124	11	87	5	93	9	117	1	102
23	6,39	13	74	9	27	0	28	0	49	2	34
24	6,30	10	61	8	29	1	28	6	41	0	32
25	82,44	14	54	5	20	2	27	4	42	1	25
26	12,68	115	483	107	381	93	459	99	480	82	420

27	3,27	61	111	54	52	44	30	48	99	41	42
28	25,89	4	36	2	29	0	21	0	28	0	19
29	26,01	57	155	48	139	26	154	47	146	39	117
30	15,48	66	189	52	141	27	183	39	174	27	128
31	78,30	49	104	33	73	9	69	22	81	14	62
32	6,41	123	1886	99	1875	77	1682	85	1776	78	1699
33	20,08	15	67	14	31	0	29	4	47	1	32
34	8,15	38	69	27	28	16	35	23	49	11	24
35	25,44	37	136	36	90	10	93	28	114	14	91
36	37,83	56	112	52	100	15	117	29	146	11	114
37	56,91	61	199	44	168	29	172	36	187	23	159
38	53,49	94	1514	67	1507	57	1409	62	1493	54	1415
39	73,06	85	1536	68	1518	50	1401	59	1499	48	1418
40	5,37	14	42	6	20	0	23	3	30	0	27
41	19,24	32	109	23	81	6	80	14	97	7	75
42	25,67	30	158	19	137	17	116	21	144	15	112
43	93,18	176	2012	140	2006	128	1813	145	1930	130	1827
44	6,53	23	73	19	44	3	29	6	57	4	32
45	39,41	61	225	58	183	40	207	48	212	36	198
46	24,37	49	144	36	122	29	119	31	138	28	115
47	12,99	59	148	44	71	28	74	35	126	30	48
48	45,78	78	299	61	241	40	248	52	273	43	235
49	16,04	32	93	28	82	23	69	31	97	25	66
50	26,07	41	165	37	148	29	132	30	159	24	128
51	98,16	124	2017	118	2010	93	1925	104	2008	99	1914
52	3,08	9	34	0	20	0	27	0	32	0	22
53	38,50	51	196	45	164	28	173	33	204	20	182
54	22,01	40	123	28	89	17	98	24	105	15	97
55	74,19	78	1752	74	1697	59	1525	78	1683	63	1514
56	68,27	73	1590	68	1534	47	1442	67	1517	55	1458
57	15,91	33	98	34	83	21	64	29	91	22	69
58	5,33	12	35	4	26	4	33	0	27	0	25
59	40,21	58	341	53	278	30	290	40	333	28	208
60	108,73	137	2045	122	2028	119	1973	125	2015	109	1914
61	60,49	92	364	88	281	63	349	69	311	57	336
62	102,53	153	2033	148	2015	115	1985	134	2029	112	1938
63	15,67	64	108	51	75	24	60	37	99	16	63
64	80,24	102	1904	99	1899	90	1735	92	1894	81	1719

Tabela A.5 – Resultados GRASP com Path-Relinking – AGM Kruskal modificado para obtenção de 3 clusters

I	Solução best	GRASP COM PATH-RELINKING									
		PR_AGMM1		PR_AGMM2		PR_AGMM3		PR_AGMM4		PR_AGMM5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	97	108	98	105	90	104	93	107	91	106
2	39,08	116	114	119	111	114	110	115	112	113	115
3	5,72	55	41	53	39	50	37	53	40	51	33
4	26,14	69	137	67	127	64	128	0	132	63	124
5	7,35	51	48	54	47	49	46	50	49	48	48
6	6,41	56	37	58	38	0	36	55	38	51	33
7	6,17	49	49	45	43	43	41	48	45	44	40
8	4,96	39	44	39	41	33	42	37	43	36	44
9	14,35	102	97	101	93	95	92	100	94	97	90
10	19,78	88	112	86	109	80	111	83	110	81	110
11	10,27	118	118	123	114	109	115	116	116	0	117
12	17,33	61	51	60	50	58	54	60	52	59	53
13	7,42	59	69	57	67	52	66	0	68	53	64
14	5,94	53	100	52	83	44	91	50	94	47	90
15	18,53	94	83	95	80	91	83	92	85	88	84
16	7,09	98	104	0	101	92	100	97	102	93	101
17	10,81	67	75	69	71	65	72	66	73	63	71
18	6,33	129	37	134	34	128	35	124	36	121	36
19	57,14	184	1944	181	1937	173	1931	179	1942	175	1942

20	49,02	153	2241	155	2239	147	2125	150	2240	148	2118
21	70,51	144	2095	146	2075	144	2079	141	2083	143	2074
22	22,17	78	41	77	42	75	41	0	44	73	42
23	6,39	89	37	88	33	80	30	86	35	81	34
24	6,30	45	39	46	31	39	37	44	38	42	36
25	82,44	177	40	179	32	174	35	176	37	171	30
26	12,68	208	127	207	119	197	120	206	123	0	118
27	3,27	62	25	63	21	59	20	61	22	59	19
28	25,89	88	123	86	125	84	126	85	124	82	125
29	26,01	119	136	122	131	116	132	117	135	114	134
30	15,48	98	152	99	138	91	136	97	141	92	139
31	78,30	141	2157	140	2122	135	2124	138	2149	133	2133
32	6,41	137	104	135	95	127	96	132	102	128	98
33	20,08	119	41	124	37	107	38	112	39	108	36
34	8,15	85	102	84	93	79	94	83	97	78	92
35	25,44	93	88	92	81	0	85	91	86	89	83
36	37,83	151	127	150	112	142	127	148	125	144	124
37	56,91	90	209	88	183	85	193	86	198	83	188
38	53,49	148	2033	144	2014	131	2011	140	2025	136	2008
39	73,06	209	2082	203	2061	184	2044	198	2073	183	2021
40	5,37	48	39	47	37	41	35	46	38	42	37
41	19,24	93	53	95	54	86	53	91	56	88	51
42	25,67	79	104	83	102	75	104	77	108	71	105
43	93,18	281	2118	280	2103	278	2099	279	2113	276	2100
44	6,53	65	49	64	46	0	49	63	48	61	45
45	39,41	118	248	116	227	111	228	112	239	110	224
46	24,37	201	151	208	138	191	139	199	144	193	141
47	12,99	99	93	100	90	84	88	97	91	86	85
48	45,78	104	209	103	184	95	173	100	192	98	174
49	16,04	77	114	77	115	72	117	76	116	73	118
50	26,07	75	136	78	124	69	125	0	132	68	121
51	98,16	283	2101	282	2088	274	2083	281	2096	277	2087
52	3,08	45	23	42	21	37	20	40	22	39	20
53	38,50	99	218	99	219	92	215	97	220	95	223
54	22,01	71	157	74	148	68	149	70	154	0	152
55	74,19	183	2004	181	1993	169	1987	180	1998	173	1985
56	68,27	209	101	210	89	201	92	204	93	202	91
57	15,91	77	109	76	104	70	105	75	106	71	103
58	5,33	42	25	44	23	39	25	40	24	39	22
59	40,21	45	392	43	395	38	396	42	393	37	392
60	108,73	394	2428	391	2415	0	2408	390	2419	385	2410
61	60,49	168	319	166	313	159	315	167	316	0	317
62	102,53	404	2487	408	2468	396	2474	402	2478	397	2469
63	15,67	142	114	144	106	128	109	137	110	132	108
64	80,24	269	2076	267	2048	261	2031	255	2063	258	2032

Tabela A.6 – Resultados GRASP com *Path-Relinking* – AGM Kruskal padrão para obtenção de 3 clusters

I	Solução best	GRASP COM PATH-RELINKING									
		PR_AGM1		PR_AGM2		PR_AGM3		PR_AGM4		PR_AGM5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	104	109	101	105	93	101	98	106	95	103
2	39,08	119	115	120	111	117	110	118	112	116	114
3	5,72	65	40	62	35	52	36	59	38	54	31
4	26,14	77	53	74	48	67	42	72	53	66	42
5	7,35	59	51	57	47	52	45	54	49	51	44
6	6,41	62	37	59	36	51	34	58	37	53	31
7	6,17	55	47	53	43	44	40	51	45	49	38
8	4,96	54	47	48	44	35	41	46	46	38	42
9	14,35	107	96	106	92	101	88	105	94	99	86
10	19,78	89	114	88	111	82	108	86	113	83	107
11	10,27	123	119	122	117	116	116	119	118	117	115
12	17,33	70	52	68	50	67	51	65	54	64	50

13	7,42	66	68	62	65	53	63	61	67	55	61
14	5,94	58	99	55	87	52	84	53	91	49	83
15	18,53	99	88	93	83	90	82	94	86	91	81
16	7,09	106	102	104	99	98	96	101	100	95	98
17	10,81	79	73	77	68	71	62	75	70	68	67
18	6,33	134	36	132	32	127	31	130	35	125	33
19	57,14	191	1931	188	1922	185	1907	183	1927	181	1915
20	49,02	160	2178	158	2110	150	2083	156	2138	151	2094
21	70,51	157	2075	153	2061	149	2062	150	2067	148	2055
22	22,17	86	44	80	40	76	41	81	42	77	40
23	6,39	99	36	97	31	0	27	94	33	89	29
24	6,30	49	37	48	32	44	33	47	35	46	31
25	82,44	187	39	183	30	179	28	180	32	178	26
26	12,68	128	125	128	118	125	117	127	121	122	109
27	3,27	73	22	74	17	71	15	69	19	67	13
28	25,89	90	124	88	121	85	120	87	122	86	118
29	26,01	127	135	123	130	118	132	121	131	116	129
30	15,48	108	142	104	131	95	128	99	135	97	130
31	78,30	149	2140	144	2116	132	2075	139	2128	0	2087
32	6,41	145	101	142	96	136	91	141	97	133	93
33	20,08	120	39	117	35	112	36	115	37	110	33
34	8,15	94	98	91	91	87	84	83	96	81	88
35	25,44	101	87	98	82	96	85	99	85	95	84
36	37,83	174	125	163	120	151	119	158	121	153	116
37	56,91	97	194	95	179	89	186	91	182	88	177
38	53,49	151	2021	146	2007	137	1999	142	2011	140	1995
39	73,06	204	2073	196	2054	189	2033	193	2068	188	2003
40	5,37	55	38	53	35	51	32	48	36	46	34
41	19,24	104	54	99	48	92	50	96	52	93	46
42	25,67	85	103	84	100	81	99	83	102	76	97
43	93,18	307	2116	293	2114	289	2085	281	2105	283	2089
44	6,53	70	48	71	45	63	48	69	47	66	41
45	39,41	121	236	119	218	117	219	115	229	111	216
46	24,37	222	144	215	136	196	138	208	140	199	137
47	12,99	107	89	95	83	93	77	92	86	89	74
48	45,78	121	190	114	181	101	155	108	184	103	161
49	16,04	85	123	83	114	81	110	79	115	77	112
50	26,07	84	122	79	115	73	108	75	119	72	104
51	98,16	315	2086	293	2071	281	2059	308	2075	285	2063
52	3,08	52	24	49	20	41	19	47	21	0	18
53	38,50	114	221	112	218	111	216	112	219	110	217
54	22,01	88	164	85	153	79	144	81	158	78	147
55	74,19	221	1993	202	1971	0	1968	194	1984	183	1960
56	68,27	234	96	227	90	211	84	215	91	209	88
57	15,91	90	108	86	103	78	102	83	104	76	101
58	5,33	52	29	47	21	41	26	0	22	43	19
59	40,21	55	402	49	390	42	389	46	391	38	387
60	108,73	412	2419	404	2406	386	2397	399	2407	391	2401
61	60,49	186	320	183	318	179	305	181	321	173	309
62	102,53	451	2473	428	2460	400	2451	416	2466	402	2444
63	15,67	157	111	153	108	138	106	150	109	143	103
64	80,24	296	2056	284	2039	269	2023	271	2041	265	2028

Tabela A.7 – Resultados GRASP com VND – Grafo Original para obtenção de 3 clusters

I	Solução best	GRASP COM VND									
		GVND1		GVND2		GVND3		GVND4		GVND5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	25	116	18	93	14	111	16	127	14	110
2	39,08	33	214	29	208	20	189	22	219	17	203
3	5,72	24	34	21	19	12	29	17	33	15	28
4	26,14	36	179	29	151	22	127	24	174	21	140
5	7,35	17	83	12	39	6	34	7	68	7	35

6	6,41	14	74	0	28	0	30	11	54	3	31
7	6,17	10	61	0	23	1	27	4	49	0	27
8	4,96	5	28	2	22	0	24	0	31	0	26
9	14,35	23	84	0	61	15	50	20	75	12	57
10	19,78	29	132	20	97	13	93	18	114	15	89
11	10,27	34	97	31	45	21	40	27	81	20	44
12	17,33	16	112	13	88	5	70	12	106	6	71
13	7,42	22	87	15	51	0	33	14	79	9	35
14	5,94	45	77	38	43	12	30	29	66	17	32
15	18,53	37	81	29	94	14	79	18	102	16	80
16	7,09	46	78	41	37	23	31	25	67	19	34
17	10,81	38	109	35	48	24	44	31	89	21	45
18	6,33	51	72	24	25	0	27	8	51	0	27
19	57,14	49	1997	37	1980	27	1932	33	1942	25	1947
20	49,02	72	2103	71	2059	55	1985	64	1997	59	1945
21	70,51	99	1948	76	1934	68	1940	45	1919	51	1994
22	22,17	15	136	14	93	4	95	8	122	0	99
23	6,39	12	77	7	28	0	30	4	53	1	31
24	6,30	8	71	6	23	2	27	0	49	0	28
25	82,44	10	68	3	21	1	26	0	48	0	27
26	12,68	103	496	92	382	80	463	88	491	83	421
27	3,27	64	115	51	53	39	33	43	101	34	45
28	25,89	1	34	0	28	0	27	0	29	0	24
29	26,01	55	167	48	132	27	144	45	164	32	123
30	15,48	72	206	69	148	28	182	36	190	24	140
31	78,30	42	101	33	74	10	63	18	88	11	64
32	6,41	114	2492	97	2462	74	2457	81	2477	75	2409
33	20,08	11	75	10	25	3	31	3	53	2	27
34	8,15	52	147	21	91	15	95	18	117	10	93
35	25,44	29	93	29	50	8	43	20	84	12	39
36	37,83	44	124	48	101	11	121	33	152	16	118
37	56,91	56	203	46	172	27	184	42	199	29	167
38	53,49	89	2022	65	1991	48	1931	59	1927	47	1981
39	73,06	73	2019	62	1972	40	1987	51	1909	44	1963
40	5,37	12	31	7	21	0	27	0	33	0	28
41	19,24	28	117	21	86	3	84	11	99	8	84
42	25,67	31	164	17	109	18	119	22	157	13	118
43	93,18	165	2088	143	2064	125	2053	138	2078	129	2004
44	6,53	18	81	16	37	4	30	2	62	2	31
45	39,41	59	235	59	190	41	212	45	224	37	201
46	24,37	40	158	35	129	21	114	29	147	25	116
47	12,99	42	142	38	69	27	73	32	127	27	49
48	45,78	53	303	54	243	42	259	48	281	39	237
49	16,04	34	90	27	89	26	65	29	94	22	67
50	26,07	38	179	34	142	20	121	25	167	23	140
51	98,16	112	2598	111	2583	91	2549	101	2590	96	2557
52	3,08	4	49	0	21	0	28	0	35	0	24
53	38,50	47	201	36	176	22	171	31	204	19	183
54	22,01	38	129	29	91	13	102	22	119	11	101
55	74,19	75	2434	71	2403	56	2394	60	2399	58	2390
56	68,27	69	1980	66	1961	48	1947	54	1957	51	1936
57	15,91	35	99	32	89	19	68	27	92	20	67
58	5,33	8	29	1	21	2	39	0	29	0	28
59	40,21	56	331	49	281	29	293	41	339	27	211
60	108,73	123	2715	114	2683	118	2641	112	2670	104	2644
61	60,49	85	358	86	297	59	353	67	309	56	338
62	102,53	137	2710	137	2671	111	2657	128	2699	113	2612
63	15,67	49	114	48	81	23	63	41	97	18	65
64	80,24	97	2071	91	2052	92	2028	88	2051	84	2012

Tabela A.8 – Resultados GRASP com VND – AGM *Kruskal modificado* para obtenção de 3 clusters

GRASP COM VND

I	Solução best	V_AGMM1		V_AGMM2		V_AGMM3		V_AGMM4		V_AGMM5	
		Gap	T(s)								
1	22,54	93	115	92	109	85	104	90	112	88	102
2	39,08	112	127	111	114	103	112	110	124	104	107
3	5,72	48	40	46	37	43	35	45	44	0	33
4	26,14	54	149	52	133	49	127	50	141	0	124
5	7,35	43	50	42	46	35	39	41	48	38	44
6	6,41	51	42	51	38	47	36	50	39	49	37
7	6,17	44	51	43	52	40	49	42	50	39	48
8	4,96	38	46	38	49	35	47	37	48	36	47
9	14,35	93	104	91	108	0	106	90	107	0	108
10	19,78	85	118	84	113	79	114	82	115	76	112
11	10,27	114	125	112	118	110	115	112	122	108	119
12	17,33	54	53	51	52	49	51	0	54	48	50
13	7,42	51	71	50	70	45	67	50	70	47	66
14	5,94	48	101	47	97	42	93	46	99	44	94
15	18,53	89	86	87	82	81	81	88	85	85	79
16	7,09	94	103	93	100	89	99	92	102	90	101
17	10,81	59	71	59	64	51	67	57	68	54	69
18	6,33	123	40	121	43	117	38	120	44	118	39
19	57,14	171	1959	170	1938	163	1925	168	1947	166	1921
20	49,02	149	2307	147	2294	0	2283	144	2304	0	2279
21	70,51	136	2115	135	2082	130	2065	133	2093	131	2068
22	22,17	75	43	74	41	72	40	74	42	71	40
23	6,39	87	38	86	39	83	38	0	40	85	36
24	6,30	44	40	43	44	40	43	42	45	40	41
25	82,44	162	41	161	37	155	36	159	38	157	33
26	12,68	191	132	190	120	181	123	189	127	183	126
27	3,27	58	27	0	25	51	24	54	26	52	23
28	25,89	87	136	85	131	80	129	83	135	81	127
29	26,01	117	148	115	142	0	140	114	144	110	141
30	15,48	93	171	90	164	88	166	92	169	88	165
31	78,30	129	2164	128	2138	119	2147	127	2153	124	2150
32	6,41	121	108	119	92	114	93	120	94	117	91
33	20,08	112	45	111	40	106	41	110	42	107	40
34	8,15	84	109	84	87	83	85	80	89	82	86
35	25,44	87	92	88	84	80	83	85	87	81	85
36	37,83	145	133	144	116	141	137	0	126	142	129
37	56,91	88	219	92	204	82	200	86	213	83	197
38	53,49	142	2053	139	2039	133	2021	137	2041	132	2036
39	73,06	203	2108	210	2088	193	2064	201	2093	197	2073
40	5,37	47	41	46	39	40	44	44	40	42	42
41	19,24	85	57	84	58	0	57	82	59	78	55
42	25,67	78	106	77	114	70	102	75	108	73	100
43	93,18	261	2124	264	2139	255	2130	258	2142	0	2133
44	6,53	59	51	63	49	56	52	56	50	53	55
45	39,41	111	257	115	264	109	261	0	258	108	263
46	24,37	194	163	192	189	188	177	189	174	187	179
47	12,99	93	108	111	106	104	109	106	110	103	114
48	45,78	98	212	97	210	92	214	95	209	93	211
49	16,04	63	121	64	117	58	119	62	118	59	116
50	26,07	74	147	73	139	70	145	71	141	70	140
51	98,16	266	2112	265	2103	260	2091	263	2107	261	2087
52	3,08	39	24	38	22	33	24	37	23	34	22
53	38,50	91	227	93	220	86	218	90	224	88	217
54	22,01	58	169	59	152	57	197	58	157	57	144
55	74,19	164	2012	161	2001	155	1993	162	2008	157	1987
56	68,27	203	116	208	118	197	119	202	117	199	115
57	15,91	69	118	73	111	66	113	65	114	66	116
58	5,33	38	28	37	27	0	28	35	29	34	28
59	40,21	44	395	43	382	42	386	41	387	40	385
60	108,73	391	2468	390	2442	385	2440	389	2451	386	2444
61	60,49	144	327	142	318	139	321	140	324	137	319

62	102,53	399	2501	401	2481	396	2485	397	2493	395	2490
63	15,67	138	125	139	122	128	123	135	124	129	125
64	80,24	251	2122	2109	2101	2076	2081	2100	2115	2087	2084

Tabela A.9 – Resultados GRASP com VND – AGM *Kruskal* padrão para obtenção de 3 clusters

I	Solução best	GRASP COM VND									
		V_AGM1		V_AGM2		V_AGM3		V_AGM4		V_AGM5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	115	112	113	104	91	97	102	106	94	99
2	39,08	114	123	112	121	104	108	109	122	103	103
3	5,72	59	45	57	42	51	31	54	44	48	30
4	26,14	62	143	59	137	52	119	53	141	51	120
5	7,35	73	51	64	46	59	38	55	48	56	41
6	6,41	58	40	55	37	48	35	54	36	51	34
7	6,17	50	51	49	48	43	47	46	50	44	46
8	4,96	44	48	41	45	38	46	39	47	38	43
9	14,35	119	103	118	106	107	105	110	106	108	104
10	19,78	90	115	88	113	81	112	84	111	80	110
11	10,27	122	124	119	120	114	113	117	117	110	116
12	17,33	63	50	61	52	54	50	53	51	52	48
13	7,42	70	69	64	67	0	65	59	68	53	62
14	5,94	51	98	49	91	39	90	48	95	41	83
15	18,53	103	84	94	83	83	80	88	79	0	76
16	7,09	99	101	99	100	96	98	97	99	95	97
17	10,81	68	70	66	67	51	65	61	63	57	66
18	6,33	129	39	128	42	119	35	126	41	122	37
19	57,14	173	1944	174	1922	171	1904	170	1927	168	1903
20	49,02	161	2305	155	2295	149	2261	153	2301	150	2254
21	70,51	150	2091	146	2071	138	2059	144	2075	140	2055
22	22,17	83	40	79	73	74	39	77	65	73	38
23	6,39	102	41	99	38	93	32	96	39	91	33
24	6,30	51	46	48	44	45	41	47	45	46	40
25	82,44	176	39	173	37	161	33	168	37	164	32
26	12,68	211	130	202	124	195	122	199	119	193	121
27	3,27	63	26	58	25	53	22	61	24	55	23
28	25,89	90	135	89	131	81	119	89	133	84	118
29	26,01	124	141	118	137	114	127	0	139	112	129
30	15,48	100	168	99	165	93	164	96	166	89	162
31	78,30	141	2148	137	2133	133	2119	129	2135	0	2126
32	6,41	127	107	122	92	115	95	121	100	116	88
33	20,08	115	41	112	41	110	40	113	37	109	38
34	8,15	96	94	94	88	86	82	87	89	84	83
35	25,44	89	90	89	85	82	81	88	86	85	82
36	37,83	157	129	153	123	141	124	151	125	144	117
37	56,91	98	215	96	210	87	193	94	212	89	185
38	53,49	146	2041	142	2032	138	2016	140	2037	135	2019
39	73,06	219	2088	213	2080	209	2060	210	2074	204	2061
40	5,37	47	47	47	43	43	38	46	45	44	37
41	19,24	89	60	88	55	77	54	84	56	79	52
42	25,67	77	104	76	98	72	100	75	103	74	93
43	93,18	304	2138	293	2116	275	2112	289	2124	271	2104
44	6,53	63	64	0	60	59	50	60	62	58	51
45	39,41	128	260	122	259	116	255	121	261	114	257
46	24,37	203	184	194	171	192	173	192	180	191	176
47	12,99	112	114	114	111	109	106	112	112	108	108
48	45,78	104	215	99	210	94	212	99	213	95	209
49	16,04	74	120	71	119	63	117	70	115	67	117
50	26,07	88	144	85	140	77	142	83	137	79	135
51	98,16	303	2108	291	2093	274	2071	289	2095	273	2059
52	3,08	44	24	41	21	37	23	40	21	36	20
53	38,50	98	225	96	215	91	211	88	218	95	209
54	22,01	69	163	67	148	63	179	60	151	64	132

55	74,19	180	2009	179	1996	165	1977	174	2000	163	1965
56	68,27	229	122	223	118	209	114	217	119	208	112
57	15,91	82	119	75	110	69	107	71	114	68	108
58	5,33	41	28	37	27	36	26	38	28	36	26
59	40,21	49	391	46	384	42	383	47	386	44	379
60	108,73	408	2465	403	2448	404	2417	402	2453	391	2420
61	60,49	153	319	147	308	145	299	144	312	142	296
62	102,53	422	2490	421	2483	410	2464	413	2487	409	2475
63	15,67	144	137	142	129	133	122	140	131	137	124
64	80,24	2173	2119	2158	2100	2142	2059	2150	2114	2141	2061

Tabela A.10 – Resultados GRASP com RVND – Grafo Original para obtenção de 3 clusters

I	Solução best	GRASP COM RVND									
		GRVND1		GRVND2		GRVND3		GRVND4		GRVND5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	28	124	19	91	13	104	15	114	12	108
2	39,08	31	209	27	202	12	161	20	185	13	159
3	5,72	20	33	16	30	10	27	14	32	11	23
4	26,14	34	152	28	144	17	131	22	167	16	132
5	7,35	18	53	14	47	0	32	8	59	3	31
6	6,41	13	48	9	36	2	29	4	41	2	30
7	6,17	11	57	7	29	0	18	1	32	0	24
8	4,96	4	26	0	22	0	12	0	28	20	18
9	14,35	19	109	16	102	9	98	11	84	10	104
10	19,78	32	87	21	74	16	54	18	76	14	69
11	10,27	39	95	33	89	15	87	24	93	18	101
12	17,33	18	61	14	53	3	49	9	59	5	48
13	7,42	19	77	12	68	6	53	10	75	2	67
14	5,94	42	117	39	114	18	84	35	121	14	108
15	18,53	31	89	27	77	13	68	19	87	12	73
16	7,09	44	93	30	89	14	71	21	92	14	80
17	10,81	39	91	28	74	12	55	26	77	15	69
18	6,33	53	65	39	33	0	20	0	36	0	24
19	57,14	38	2338	33	2272	21	2264	30	2281	22	2267
20	49,02	74	2391	69	2375	58	2359	68	2379	54	2373
21	70,51	123	2126	78	109	67	2093	42	2112	58	2098
22	22,17	15	85	12	43	3	26	11	48	0	39
23	6,39	10	62	8	34	0	27	3	40	0	28
24	6,30	9	53	7	31	0	20	0	34	0	23
25	82,44	12	59	5	27	0	19	0	32	0	23
26	12,68	106	488	98	479	77	461	82	482	75	475
27	3,27	51	197	44	185	18	154	37	189	28	171
28	25,89	4	24	0	19	0	14	0	24	0	15
29	26,01	52	161	45	157	33	132	41	161	30	155
30	15,48	73	229	54	182	18	151	37	187	19	186
31	78,30	35	104	22	85	9	62	16	85	9	83
32	6,41	104	2495	93	2508	71	2443	82	2511	73	2497
33	20,08	8	68	7	29	0	30	0	38	0	26
34	8,15	49	134	34	123	6	117	17	122	9	125
35	25,44	28	87	12	94	3	81	11	97	6	93
36	37,83	42	118	37	192	17	165	35	196	15	182
37	56,91	51	243	43	277	23	259	41	283	24	271
38	53,49	67	2315	74	2283	45	2264	67	2292	34	2268
39	73,06	68	2296	54	2311	39	2298	49	2315	37	2306
40	5,37	9	29	5	28	0	19	0	31	0	20
41	19,24	26	74	13	57	0	55	7	63	6	54
42	25,67	28	156	0	122	8	112	21	128	10	117
43	93,18	159	2202	141	2189	118	2173	142	2194	125	2186
44	6,53	18	51	12	35	1	27	5	43	1	30

45	39,41	56	294	44	281	31	264	36	287	32	274
46	24,37	37	182	31	170	23	156	27	174	21	162
47	12,99	40	163	35	157	23	144	30	169	24	153
48	45,78	55	342	49	330	40	316	41	331	37	327
49	16,04	31	109	23	114	11	98	19	108	15	111
50	26,07	37	215	32	212	17	203	25	216	19	208
51	98,16	114	2694	111	2687	94	2675	102	2693	93	2681
52	3,08	2	22	0	18	0	13	0	24	0	14
53	38,50	39	248	34	234	16	209	32	238	17	224
54	22,01	31	153	22	141	12	128	17	149	9	139
55	74,19	72	2431	67	2429	54	2414	61	2437	55	2422
56	68,27	68	2435	63	2424	47	2405	52	2428	48	2418
57	15,91	33	148	28	130	16	116	24	124	17	119
58	5,33	6	39	0	27	0	17	0	31	0	20
59	40,21	51	371	47	368	22	363	42	370	23	361
60	108,73	119	2779	110	2774	95	2778	109	2789	96	2772
61	60,49	84	364	73	351	50	337	63	353	52	348
62	102,53	132	2783	119	2776	99	2764	131	2784	102	2775
63	15,67	48	151	36	147	15	142	38	152	15	136
64	80,24	93	2093	88	2086	78	2503	79	2518	77	2492

Tabela A.11 – Resultados GRASP com RVND – AGM *Kruskal* modificado para obtenção de 3 clusters

I	Solução best	GRASP COM RVND									
		RV_AGMM1		RV_AGMM2		RV_AGMM3		RV_AGMM4		RV_AGMM5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	84	116	83	114	77	113	82	115	78	110
2	39,08	102	132	100	127	93	124	98	129	95	125
3	5,72	45	41	44	42	37	43	43	44	39	44
4	26,14	49	148	48	128	44	127	46	135	0	125
5	7,35	41	52	38	47	36	48	39	49	0	44
6	6,41	52	47	50	44	0	43	48	46	46	47
7	6,17	39	53	39	51	34	50	38	52	36	50
8	4,96	37	47	36	41	30	44	35	46	32	45
9	14,35	91	102	89	97	87	100	88	101	85	98
10	19,78	77	110	75	102	70	105	75	108	72	103
11	10,27	102	128	101	117	95	118	100	119	97	114
12	17,33	49	54	48	51	44	52	47	53	42	50
13	7,42	53	73	52	69	0	71	51	72	50	69
14	5,94	44	109	44	100	39	102	42	103	38	101
15	18,53	85	91	83	78	79	82	81	84	79	83
16	7,09	89	112	89	104	86	109	88	110	85	112
17	10,81	57	75	56	63	54	67	55	68	52	66
18	6,33	121	44	117	41	113	43	120	42	116	40
19	57,14	163	1967	160	1994	149	1966	157	1975	151	1958
20	49,02	137	2315	134	2303	126	2285	128	2309	124	2281
21	70,51	125	2132	123	2117	121	2107	123	2124	119	2095
22	22,17	69	49	68	48	0	46	67	47	66	44
23	6,39	84	40	84	42	83	39	82	41	80	38
24	6,30	43	44	41	37	37	38	40	40	0	39
25	82,44	157	39	156	41	144	42	153	43	148	40
26	12,68	182	141	179	127	159	123	171	139	167	124
27	3,27	54	28	51	26	47	27	50	27	48	28
28	25,89	85	140	84	133	78	126	83	137	80	125
29	26,01	112	153	112	145	111	147	110	148	108	142
30	15,48	89	188	88	171	84	173	86	175	83	174
31	78,30	125	2195	123	2132	116	2118	122	2188	119	2115
32	6,41	117	114	116	103	112	109	115	109	110	112
33	20,08	104	46	102	42	98	40	100	44	96	39
34	8,15	77	118	75	107	72	108	74	110	72	111
35	25,44	86	95	85	91	0	92	83	94	81	93
36	37,83	143	147	141	126	130	138	138	132	133	134
37	56,91	87	221	87	214	78	215	86	217	79	216

38	53,49	138	2076	136	2021	132	2008	135	2055	130	2001
39	73,06	191	2124	189	2118	173	2100	187	2122	178	2099
40	5,37	44	43	40	41	39	38	0	42	36	35
41	19,24	83	62	82	56	79	61	81	58	77	60
42	25,67	77	118	75	110	72	118	75	114	71	117
43	93,18	258	2137	252	2116	239	2103	247	2128	244	2096
44	6,53	57	55	48	50	50	51	55	53	0	50
45	39,41	109	263	105	246	101	244	104	251	102	248
46	24,37	181	168	180	159	172	153	177	164	175	165
47	12,99	88	122	86	120	82	117	85	124	0	119
48	45,78	97	217	94	211	88	204	93	215	90	202
49	16,04	56	123	53	118	52	120	55	119	0	119
50	26,07	73	154	71	151	69	153	70	152	68	151
51	98,16	257	2125	255	2117	247	2108	254	2120	250	2115
52	3,08	38	27	35	24	31	24	0	26	32	25
53	38,50	83	236	81	228	78	219	80	234	78	217
54	22,01	57	171	55	169	52	165	0	172	53	167
55	74,19	162	2021	161	2015	157	2013	160	2018	158	2012
56	68,27	194	118	193	107	189	101	191	109	188	100
57	15,91	68	119	68	103	62	104	66	115	64	111
58	5,33	32	28	0	26	27	26	0	27	29	28
59	40,21	43	397	41	385	0	377	40	392	38	373
60	108,73	388	2483	385	2468	379	2441	381	2471	380	2450
61	60,49	142	330	142	315	139	323	141	322	138	325
62	102,53	391	2512	388	2497	381	2481	383	2503	380	2473
63	15,67	124	133	123	115	115	118	122	128	118	122
64	80,24	222	2140	220	2112	211	2110	217	2136	213	2106

Tabela A.12 – Resultados GRASP com RVND – AGM Kruskal padrão para obtenção de 3 clusters

I	Solução best	GRASP COM RVND									
		RV_AGM1		RV_AGM2		RV_AGM3		RV_AGM4		RV_AGM5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	94	117	89	112	80	111	87	114	81	109
2	39,08	116	130	108	121	100	122	104	125	102	118
3	5,72	49	46	47	45	40	41	46	41	43	42
4	26,14	51	191	48	132	43	125	49	136	45	123
5	7,35	57	49	54	48	46	46	51	45	42	41
6	6,41	59	46	55	43	51	42	53	44	48	45
7	6,17	47	52	44	51	38	49	41	50	39	48
8	4,96	40	46	39	45	35	41	37	39	34	43
9	14,35	111	101	102	100	86	93	94	98	88	96
10	19,78	85	108	81	106	83	104	79	101	75	100
11	10,27	133	121	128	117	123	115	0	118	108	111
12	17,33	59	53	56	52	48	48	51	54	49	49
13	7,42	75	72	72	71	55	68	52	73	53	67
14	5,94	46	107	45	101	43	99	44	104	41	98
15	18,53	91	59	89	82	84	77	85	84	81	79
16	7,09	118	110	113	109	99	106	104	102	98	108
17	10,81	86	72	74	67	58	65	71	68	57	63
18	6,33	130	45	128	44	111	38	127	45	114	36
19	57,14	177	1990	170	1963	152	1949	163	1981	154	1947
20	49,02	142	2310	137	2295	129	2234	134	2300	128	2221
21	70,51	135	2124	129	2108	0	2095	127	2115	121	2092
22	22,17	77	51	75	48	72	42	71	49	69	46
23	6,39	96	39	93	37	85	38	89	40	0	35
24	6,30	51	40	49	38	41	37	44	36	42	36
25	82,44	63	37	57	41	48	41	51	40	49	38
26	12,68	192	140	185	136	171	120	182	123	174	122
27	3,27	67	27	62	25	57	26	58	27	54	27
28	25,89	96	138	94	131	86	121	92	132	85	122
29	26,01	126	150	122	144	115	145	119	141	114	140
30	15,48	99	184	97	171	91	170	94	173	89	169

31	78,30	139	2142	137	2118	124	2099	134	2125	127	2093
32	6,41	127	115	124	113	118	111	123	114	115	110
33	20,08	116	45	114	42	105	38	111	40	104	36
34	8,15	91	118	88	109	82	109	85	113	78	107
35	25,44	95	104	91	96	89	98	90	102	0	94
36	37,83	148	141	145	137	140	132	142	139	141	131
37	56,91	99	218	92	209	85	208	90	211	83	208
38	53,49	147	2015	144	1988	141	1991	142	2004	137	1983
39	73,06	195	2120	193	2114	179	2093	189	2116	186	2087
40	5,37	51	41	47	39	0	38	45	40	39	37
41	19,24	92	65	90	62	88	59	86	63	83	56
42	25,67	88	117	82	115	77	117	79	116	75	112
43	93,18	283	2126	276	2104	263	2098	271	2110	267	2083
44	6,53	70	54	68	51	64	49	62	53	59	47
45	39,41	119	251	117	243	110	238	113	247	107	235
46	24,37	201	169	194	167	181	160	188	168	183	162
47	12,99	99	123	96	121	91	115	90	118	85	114
48	45,78	123	210	118	204	101	199	112	207	97	197
49	16,04	69	121	66	118	54	112	61	119	58	113
50	26,07	92	155	87	150	77	149	84	152	75	147
51	98,16	289	2119	273	2103	259	2109	267	2112	264	2094
52	3,08	44	28	42	25	35	24	40	27	38	23
53	38,50	85	235	82	232	80	215	83	233	79	214
54	22,01	61	170	59	163	51	155	57	167	55	152
55	74,19	180	2015	177	2004	162	1997	173	2010	163	1991
56	68,27	199	116	196	103	194	98	199	105	191	97
57	15,91	81	115	77	112	71	107	75	113	72	110
58	5,33	38	30	35	33	29	28	33	32	31	29
59	40,21	55	392	49	384	42	359	44	387	40	355
60	108,73	418	2475	399	2463	385	2432	396	2469	394	2424
61	60,49	163	328	155	321	145	320	148	322	142	319
62	102,53	441	2501	428	2497	402	2463	417	2499	397	2451
63	15,67	148	129	154	124	147	119	151	127	142	118
64	80,24	239	2128	237	2123	221	2091	230	2115	224	2083

Tabela A.13 – Resultados VNS Padrão – Grafo Original para obtenção de 3 clusters

I	Solução best	VNS PADRÃO									
		VNS1		VNS2		VNS3		VNS4		VNS5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	29	129	20	108	12	115	16	119	11	114
2	39,08	28	197	25	184	11	171	18	193	10	169
3	5,72	17	45	14	31	8	24	11	35	9	25
4	26,14	33	186	25	160	12	159	23	168	15	147
5	7,35	15	73	12	42	0	40	9	57	1	31
6	6,41	11	69	8	24	0	35	2	58	0	30
7	6,17	8	72	4	37	0	32	0	44	0	26
8	4,96	6	35	2	29	0	27	0	32	0	24
9	14,35	17	79	14	64	7	64	12	67	8	58
10	19,78	25	140	19	108	13	102	18	115	12	94
11	10,27	34	83	28	46	14	58	22	68	16	41
12	17,33	19	117	17	101	7	94	15	117	6	75
13	7,42	20	78	13	62	5	57	11	68	2	38
14	5,94	46	85	41	70	22	61	37	74	16	34
15	18,53	28	139	24	108	10	105	16	110	8	82
16	7,09	31	67	0	41	12	48	19	53	15	37
17	10,81	42	114	35	86	17	69	23	102	11	39
18	6,33	9	81	4	50	0	48	0	54	0	31
19	57,14	50	2362	45	2335	18	2327	28	2348	20	2330
20	49,02	69	2289	63	2273	55	2264	67	2279	56	2255
21	70,51	88	2437	80	2358	47	2346	14	2361	36	2342
22	22,17	13	144	11	108	2	93	9	104	1	115
23	6,39	10	58	8	33	0	47	2	44	0	28

24	6,30	9	55	5	30	0	32	0	51	0	20
25	82,44	8	50	3	31	0	25	0	40	0	30
26	12,68	99	514	96	472	74	469	89	479	77	514
27	3,27	42	161	39	149	22	143	34	156	19	64
28	25,89	5	42	0	27	0	24	0	33	0	20
29	26,01	48	191	41	178	29	168	45	184	27	170
30	15,48	65	218	44	184	18	171	32	193	16	159
31	78,30	21	134	16	102	7	83	15	98	8	94
32	6,41	84	2515	79	2498	75	2485	78	2506	70	2490
33	20,08	9	82	6	53	0	41	0	63	0	52
34	8,15	35	139	29	114	10	97	18	125	7	119
35	25,44	22	126	18	107	5	74	13	116	4	99
36	37,83	37	204	33	188	12	138	31	193	16	184
37	56,91	41	281	39	246	25	241	38	252	22	218
38	53,49	80	2393	72	2270	41	2253	64	2275	42	2230
39	73,06	53	2336	48	2321	39	2285	42	2326	34	2314
40	5,37	6	50	3	39	0	37	0	41	0	35
41	19,24	24	127	15	108	1	88	7	115	3	101
42	25,67	27	209	0	181	7	160	14	197	5	178
43	93,18	151	2645	146	2627	103	2573	90	2633	98	2605
44	6,53	10	71	8	34	0	62	4	64	0	58
45	39,41	42	270	39	261	30	257	34	266	27	233
46	24,37	33	167	30	148	19	131	23	159	14	115
47	12,99	39	157	33	123	25	123	28	131	22	119
48	45,78	52	361	48	335	39	315	42	349	34	287
49	16,04	30	129	22	98	12	101	19	115	13	85
50	26,07	33	227	29	191	18	186	22	203	15	173
51	98,16	110	2656	107	2632	91	2629	99	2641	87	2604
52	3,08	3	40	0	30	0	28	0	38	0	33
53	38,50	36	231	29	207	13	212	31	229	15	201
54	22,01	24	172	17	154	5	137	14	141	8	115
55	74,19	69	2455	61	2416	53	2393	62	2421	54	2381
56	68,27	63	2439	62	2378	44	2407	53	409	46	2384
57	15,91	30	127	29	109	12	93	22	115	14	100
58	5,33	7	42	0	31	0	25	0	33	0	29
59	40,21	49	401	42	372	20	367	44	386	21	331
60	108,73	112	2793	107	740	94	2731	101	2748	92	2694
61	60,49	77	367	65	322	49	317	59	329	46	298
62	102,53	129	2814	114	2241	98	2711	122	2757	100	2703
63	15,67	26	132	23	102	14	95	20	116	12	89
64	80,24	99	2509	94	2464	76	2451	84	2484	75	2446

Tabela A.14 – Resultados VNS Padrão – AGM Kruskal modificado para obtenção de 3 clusters

I	Solução best	VNS PADRÃO									
		VNS_AGMM1		VNS_AGMM2		VNS_AGMM3		VNS_AGMM4		VNS_AGMM5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	72	119	71	107	69	105	70	112	68	108
2	39,08	93	146	92	138	87	134	92	141	89	132
3	5,72	41	42	41	37	38	36	40	38	40	36
4	26,14	47	157	47	144	43	143	46	146	44	145
5	7,35	38	53	36	51	34	49	35	52	0	47
6	6,41	51	49	50	37	42	38	49	39	44	36
7	6,17	37	57	35	58	29	55	33	59	31	56
8	4,96	33	50	32	45	28	48	31	44	29	47
9	14,35	89	104	87	101	84	97	85	108	0	104
10	19,78	75	113	75	107	70	110	72	113	71	109
11	10,27	101	137	99	129	93	127	98	132	95	125
12	17,33	48	55	47	52	40	51	45	54	41	53
13	7,42	46	77	44	68	39	64	42	69	40	66
14	5,94	39	112	38	117	0	111	37	115	34	108
15	18,53	84	93	81	86	78	84	80	88	77	82
16	7,09	80	117	79	110	0	107	76	115	73	112

17	10,81	46	79	46	69	44	78	45	74	42	69
18	6,33	118	45	117	42	109	41	115	44	110	43
19	57,14	149	1973	145	1952	140	1947	144	1966	142	1961
20	49,02	125	2321	124	2304	119	2285	123	2312	118	2296
21	70,51	116	2154	115	2118	112	2099	114	2148	110	2104
22	22,17	58	52	56	47	45	46	56	49	51	45
23	6,39	78	41	77	38	72	39	75	40	73	41
24	6,30	37	45	35	33	0	30	34	38	32	34
25	82,44	149	43	147	39	138	43	146	42	144	41
26	12,68	178	147	175	142	172	138	173	144	169	135
27	3,27	53	27	51	40	0	39	49	34	50	37
28	25,89	78	141	78	138	74	133	77	140	76	136
29	26,01	104	158	103	151	101	154	102	155	100	152
30	15,48	85	193	84	186	80	185	82	190	0	187
31	78,30	117	2200	116	2187	110	2179	115	2193	108	2185
32	6,41	108	117	106	112	97	110	104	114	99	113
33	20,08	99	48	98	49	92	47	97	51	91	48
34	8,15	68	129	66	131	62	123	65	130	63	127
35	25,44	81	97	81	93	71	96	80	95	74	94
36	37,83	137	154	129	149	120	144	125	152	122	142
37	56,91	82	235	81	221	74	227	80	233	76	231
38	53,49	124	2081	121	2028	115	2014	120	2069	117	2016
39	73,06	178	2136	173	2100	166	2093	167	2124	164	2087
40	5,37	41	45	38	42	36	40	40	41	0	39
41	19,24	79	61	78	58	71	55	75	60	70	59
42	25,67	64	114	63	106	59	107	62	109	59	109
43	93,18	244	2128	241	2094	234	2083	0	2115	237	2080
44	6,53	48	57	0	52	42	51	46	53	40	52
45	39,41	101	266	99	248	93	237	98	255	95	242
46	24,37	173	171	0	167	165	168	167	169	164	166
47	12,99	86	127	85	122	79	119	83	124	78	116
48	45,78	94	221	93	218	91	204	90	220	92	202
49	16,04	55	128	55	125	48	121	53	127	50	119
50	26,07	69	167	68	163	65	161	67	164	65	166
51	98,16	254	2141	250	2112	239	2107	248	2138	242	2099
52	3,08	37	30	34	33	32	34	0	34	33	36
53	38,50	79	241	76	219	72	204	75	227	71	221
54	22,01	53	175	52	172	44	170	51	174	47	173
55	74,19	157	2039	155	2006	151	1983	152	2014	149	1982
56	68,27	182	120	181	119	180	121	179	122	181	118
57	15,91	64	128	63	133	57	128	62	131	59	126
58	5,33	33	30	32	37	28	36	31	35	0	38
59	40,21	49	395	49	376	44	381	48	388	47	373
60	108,73	375	2517	372	2429	367	2414	369	2504	363	2400
61	60,49	137	336	134	315	125	323	133	328	128	319
62	102,53	382	2518	379	2467	371	2455	375	2493	368	2472
63	15,67	118	139	115	128	107	124	114	131	109	129
64	80,24	215	2152	214	2114	210	2100	0	2145	212	2094

Tabela A.15 – Resultados VNS Padrão – AGM *Kruskal* padrão para obtenção de 3 clusters

I	Solução best	VNS PADRÃO									
		VNS_AGM1		VNS_AGM2		VNS_AGM3		VNS_AGM4		VNS_AGM5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	93	114	87	109	79	103	82	105	77	104
2	39,08	120	144	112	138	92	131	101	136	94	129
3	5,72	53	41	49	36	43	35	48	35	42	33
4	26,14	69	149	63	144	51	143	57	145	53	142
5	7,35	62	54	59	53	50	48	55	52	51	45
6	6,41	73	42	65	38	49	35	53	37	49	33
7	6,17	45	58	42	57	36	54	39	56	38	52
8	4,96	44	49	41	43	38	46	39	45	35	44
9	14,35	102	106	96	107	89	100	94	105	88	102

10	19,78	95	112	92	111	80	109	87	106	81	107
11	10,27	116	134	111	128	100	122	104	129	99	119
12	17,33	58	54	53	53	48	50	50	54	47	52
13	7,42	61	73	57	65	44	62	49	67	42	63
14	5,94	42	118	41	112	38	110	0	115	38	106
15	18,53	98	90	94	86	85	83	89	88	82	81
16	7,09	89	116	85	114	77	104	83	112	78	107
17	10,81	74	75	66	71	54	73	55	73	52	66
18	6,33	130	44	126	42	117	40	123	44	112	41
19	57,14	174	1966	164	1960	156	1953	158	1959	153	1958
20	49,02	128	2314	129	2291	125	2189	127	2299	122	2187
21	70,51	125	2123	122	2115	117	2096	119	2113	118	2093
22	22,17	63	50	62	46	54	42	57	46	56	41
23	6,39	89	40	81	41	77	38	80	36	79	39
24	6,30	42	44	40	36	38	32	39	31	35	33
25	82,44	153	45	152	41	149	42	151	44	148	40
26	12,68	195	154	194	138	183	125	186	143	177	122
27	3,27	64	41	63	35	60	36	58	39	61	33
28	25,89	91	140	84	139	81	128	80	139	83	127
29	26,01	118	155	117	153	107	151	111	149	109	148
30	15,48	99	189	96	183	89	180	93	184	88	182
31	78,30	124	2186	121	2165	112	2158	116	2170	109	2143
32	6,41	122	115	118	112	108	109	112	113	104	110
33	20,08	57	50	55	50	49	43	53	51	49	42
34	8,15	78	127	74	123	67	115	69	125	68	118
35	25,44	94	98	81	94	0	91	84	97	78	92
36	37,83	149	151	135	145	131	136	136	146	129	137
37	56,91	90	242	86	232	82	228	81	219	84	230
38	53,49	138	2075	132	2041	123	1998	127	2042	120	2002
39	73,06	192	2128	189	2103	176	2084	188	2117	173	2071
40	5,37	61	44	55	40	42	37	49	41	44	36
41	19,24	99	63	94	57	81	54	89	62	85	53
42	25,67	75	112	69	108	62	104	60	105	61	108
43	93,18	266	2120	251	2100	244	2071	248	2112	245	2063
44	6,53	63	56	55	53	0	50	53	49	49	51
45	39,41	119	253	116	107	98	239	107	244	0	236
46	24,37	199	174	189	184	175	167	184	172	179	165
47	12,99	104	123	93	120	83	114	89	119	85	113
48	45,78	116	218	114	215	105	199	112	216	103	197
49	16,04	68	124	67	123	64	120	68	123	63	115
50	26,07	80	165	75	163	72	159	74	162	71	160
51	98,16	283	2133	279	2114	266	2085	271	2124	265	2071
52	3,08	51	35	42	32	37	32	41	33	39	33
53	38,50	97	237	93	275	81	199	86	226	80	219
54	22,01	56	174	56	171	49	168	54	173	48	165
55	74,19	170	2028	167	2012	159	1981	168	2015	165	1977
56	68,27	211	126	209	121	193	118	204	124	194	116
57	15,91	73	137	71	130	65	127	69	132	67	123
58	5,33	44	36	42	33	37	35	41	32	38	36
59	40,21	60	392	56	385	51	374	50	387	49	369
60	108,73	391	2504	386	2480	377	2397	381	2485	0	2381
61	60,49	142	328	137	314	127	299	135	316	129	293
62	102,53	346	2441	390	2471	386	2408	394	2455	381	2412
63	15,67	124	135	120	130	117	122	118	132	112	121
64	80,24	231	2104	224	2098	210	2057	221	2083	208	2064

Tabela A.16 – Resultados GVNS – Grafo Original para obtenção de 3 clusters

I	Solução best	GVNS									
		GVNS1		GVNS2		GVNS3		GVNS4		GVNS5	
		Gap	T(s)								
1	22,54	22	117	18	99	10	106	15	114	9	108

2	39,08	27	203	21	172	11	154	19	187	12	163
3	5,72	15	31	13	19	8	21	12	29	6	26
4	26,14	32	166	27	147	14	129	21	163	11	151
5	7,35	10	83	0	40	0	33	6	51	0	34
6	6,41	11	81	8	27	0	29	3	49	0	32
7	6,17	12	75	4	32	0	25	0	42	0	27
8	4,96	5	29	0	27	0	23	0	37	0	25
9	14,35	14	80	10	53	6	51	8	69	3	54
10	19,78	25	156	17	99	10	102	15	118	11	91
11	10,27	36	108	29	42	17	40	25	76	12	44
12	17,33	19	129	18	81	9	67	13	98	4	70
13	7,42	16	74	12	55	3	32	7	67	1	34
14	5,94	48	92	43	61	21	30	38	72	13	38
15	18,53	29	117	25	102	12	81	23	114	5	78
16	7,09	36	74	33	35	18	28	31	59	14	30
17	10,81	39	126	34	46	15	40	29	87	12	44
18	6,33	8	63	3	47	0	29	0	55	0	27
19	57,14	41	2351	37	2334	0	2367	33	2351	0	2338
20	49,02	62	2291	38	2341	0	2279	29	2282	58	2229
21	70,51	94	2448	81	2375	36	2428	45	2403	37	2391
22	22,17	11	151	9	104	1	94	8	117	2	96
23	6,39	11	75	7	21	0	25	2	51	0	28
24	6,30	10	70	4	22	0	29	0	48	0	29
25	82,44	11	62	3	24	0	26	0	46	6	28
26	12,68	101	503	86	468	78	504	97	483	75	450
27	3,27	50	125	44	116	18	93	39	137	20	41
28	25,89	5	44	0	27	0	15	0	25	0	24
29	26,01	49	207	37	181	28	172	42	193	26	127
30	15,48	54	198	40	166	17	164	39	187	15	115
31	78,30	26	128	19	101	9	91	17	104	8	72
32	6,41	97	2516	85	2485	72	2489	79	2491	69	2424
33	20,08	9	78	5	52	0	49	1	69	0	39
34	8,15	28	152	23	111	5	108	19	116	8	91
35	25,44	19	135	16	83	2	97	12	100	6	47
36	37,83	33	197	29	161	13	164	27	171	15	128
37	56,91	39	2234	32	2205	24	2209	34	2227	21	2173
38	53,49	73	2315	58	2259	40	2244	51	2261	44	2299
39	73,06	59	2327	42	2291	38	2289	39	2293	35	2254
40	5,37	10	43	0	28	0	28	0	31	0	28
41	19,24	23	121	17	91	1	94	8	96	2	88
42	25,67	22	198	15	171	4	167	11	174	3	127
43	93,18	148	2633	91	2612	77	2609	87	2615	72	2512
44	6,53	12	85	10	44	0	69	3	63	1	31
45	39,41	41	282	38	251	28	247	35	268	25	214
46	24,37	35	173	27	143	15	102	22	122	12	118
47	12,99	38	140	32	118	23	122	29	134	19	51
48	45,78	51	315	49	271	38	284	45	280	33	243
49	16,04	32	99	24	74	12	87	19	90	11	65
50	26,07	29	206	28	189	14	181	23	198	12	144
51	98,16	104	2649	102	2612	89	2599	97	2617	85	2556
52	3,08	4	45	0	21	0	31	0	33	0	25
53	38,50	43	220	3	173	12	198	28	201	17	192
54	22,01	25	137	18	115	5	112	15	122	4	100
55	74,19	67	2474	56	2392	51	2439	63	2408	56	2405
56	68,27	62	2421	59	2331	43	2376	52	2389	47	2354
57	15,91	29	94	27	72	15	108	21	91	12	69
58	5,33	12	37	0	18	0	32	0	30	0	24
59	40,21	43	361	38	294	22	327	41	348	20	203
60	108,73	119	2763	114	2694	89	2715	102	2742	94	2658
61	60,49	75	341	72	302	48	305	63	308	42	329
62	102,53	123	2728	119	2683	99	2717	115	2719	101	2621
63	15,67	28	109	22	73	11	84	20	104	14	66
64	80,24	102	2484	101	2421	74	2440	92	2466	73	2402

Tabela A.17 – Resultados GVNS – AGM *Kruskal modificado* para obtenção de 3 clusters

I	Solução best	GVNS									
		GVNS_AGMM1		GVNS_AGMM2		GVNS_AGMM3		GVNS_AGMM4		GVNS_AGMM5	
		Gap	T(s)								
1	22,54	67	123	65	118	59	120	63	121	58	115
2	39,08	88	159	84	166	77	162	79	163	75	157
3	5,72	39	44	37	40	34	43	0	42	35	41
4	26,14	48	161	46	153	41	159	45	155	43	158
5	7,35	37	55	37	52	32	48	36	54	30	50
6	6,41	52	48	51	40	48	41	50	43	45	37
7	6,17	38	60	36	51	0	55	35	57	32	53
8	4,96	29	51	27	47	0	44	26	48	23	46
9	14,35	88	109	87	102	83	99	85	107	83	103
10	19,78	69	116	68	114	61	112	67	115	63	110
11	10,27	94	142	89	138	84	136	0	140	82	134
12	17,33	43	57	42	51	39	49	41	53	38	45
13	7,42	45	76	43	55	38	66	40	67	39	64
14	5,94	32	114	32	108	25	97	30	110	27	94
15	18,53	79	92	76	90	73	83	75	91	71	88
16	7,09	72	116	0	111	61	109	68	113	63	110
17	10,81	44	83	42	77	38	73	41	79	0	72
18	6,33	115	47	112	43	101	41	109	45	103	43
19	57,14	139	1980	138	1949	132	1953	135	1967	129	1962
20	49,02	124	2374	123	2359	115	2355	122	2361	118	2358
21	70,51	118	2191	115	2125	108	2149	109	2154	103	2144
22	22,17	59	58	57	51	0	48	55	53	49	45
23	6,39	70	63	69	65	62	57	68	58	64	59
24	6,30	36	48	35	35	34	41	34	42	31	37
25	82,44	157	46	152	49	131	46	148	51	134	42
26	12,68	158	154	155	155	144	147	152	156	147	151
27	3,27	49	38	47	44	42	35	45	47	42	37
28	25,89	74	163	72	152	68	144	70	155	67	149
29	26,01	98	174	95	166	89	161	93	169	88	163
30	15,48	77	202	76	195	68	199	75	200	69	193
31	78,30	115	2227	111	2201	108	2183	109	2215	104	2197
32	6,41	99	130	93	125	89	122	0	128	87	124
33	20,08	96	51	95	54	85	48	94	57	89	48
34	8,15	57	132	54	128	47	117	51	129	48	122
35	25,44	63	104	62	91	58	93	61	102	58	91
36	37,83	115	176	110	161	105	157	108	167	103	152
37	56,91	74	237	73	219	70	215	71	225	69	218
38	53,49	116	2095	115	2040	106	2014	112	2083	108	2009
39	73,06	163	2142	158	2113	148	2111	153	2138	0	2115
40	5,37	34	47	33	48	29	46	31	49	28	44
41	19,24	77	63	76	60	68	62	76	61	0	66
42	25,67	53	121	49	117	41	118	47	119	42	120
43	93,18	246	2139	241	2102	0	2097	238	2124	233	2095
44	6,53	42	67	0	62	38	63	40	65	35	61
45	39,41	103	271	100	268	93	262	97	269	95	266
46	24,37	184	189	181	173	175	163	179	177	172	169
47	12,99	75	139	74	118	69	114	71	122	67	112
48	45,78	83	244	81	227	75	225	80	239	78	228
49	16,04	54	131	53	125	44	124	52	129	46	121
50	26,07	66	181	64	172	57	167	60	175	0	164
51	98,16	241	2168	240	2127	230	2118	237	2144	233	2122
52	3,08	33	32	31	30	28	29	29	31	26	28
53	38,50	78	240	77	225	70	228	74	233	71	226
54	22,01	49	174	48	161	39	157	44	165	0	159
55	74,19	142	2057	139	2011	135	2004	138	2038	133	1998
56	68,27	163	141	159	128	156	125	157	134	154	121
57	15,91	58	133	57	119	50	120	55	125	51	123

58	5,33	24	32	23	28	21	34	0	29	0	32
59	40,21	41	402	38	393	35	388	38	397	36	394
60	108,73	368	2569	364	2431	357	2418	360	2495	352	2401
61	60,49	129	358	127	339	121	327	123	344	118	324
62	102,53	371	2553	371	2451	355	2412	369	2512	358	2410
63	15,67	114	148	112	144	109	145	111	147	108	144
64	80,24	203	2187	193	2139	187	2124	188	2160	184	2128

Tabela A.18 – Resultados GVNS – AGM *Kruskal* padrão para obtenção de 3 clusters

I	Solução best	GVNS									
		GVNS_AGM1		GVNS_AGM2		GVNS_AGM3		GVNS_AGM4		GVNS_AGM5	
		Gap	T(s)								
1	22,54	83	124	79	116	69	121	74	119	66	112
2	39,08	99	159	92	169	88	163	91	165	84	153
3	5,72	55	46	53	41	45	44	48	43	42	42
4	26,14	66	166	61	149	53	157	59	156	55	159
5	7,35	49	59	44	54	40	49	43	55	39	53
6	6,41	68	46	61	41	49	38	56	42	53	36
7	6,17	51	57	48	50	37	53	42	55	39	51
8	4,96	40	50	41	45	34	42	39	46	32	44
9	14,35	93	107	90	101	86	97	88	105	85	100
10	19,78	89	115	84	111	71	110	76	112	0	108
11	10,27	122	174	115	159	99	142	104	153	91	149
12	17,33	57	53	55	50	48	42	52	49	45	41
13	7,42	51	72	48	59	39	64	44	66	41	62
14	5,94	40	110	37	104	31	93	35	108	32	91
15	18,53	91	93	88	89	79	81	84	90	77	83
16	7,09	79	118	76	112	62	108	73	111	69	107
17	10,81	48	81	45	79	40	74	44	77	40	73
18	6,33	124	45	121	42	112	42	118	44	115	40
19	57,14	161	1974	155	1953	148	1941	153	1956	140	1932
20	49,02	142	2359	134	2351	127	2314	132	2341	122	2308
21	70,51	144	2148	135	2119	118	2095	128	2112	112	2083
22	22,17	73	56	64	50	52	47	62	51	53	42
23	6,39	88	64	81	63	71	56	77	55	70	53
24	6,30	47	42	44	33	38	33	0	39	39	35
25	82,44	163	43	155	45	142	44	148	52	140	41
26	12,68	172	151	169	148	150	137	161	142	153	139
27	3,27	55	42	53	41	47	39	50	43	48	34
28	25,89	88	161	82	150	72	135	79	150	74	137
29	26,01	109	172	95	165	91	160	93	167	90	162
30	15,48	81	200	78	193	72	195	75	198	73	191
31	78,30	132	2215	128	2195	118	2149	122	2203	113	2142
32	6,41	116	129	104	124	97	120	99	126	95	122
33	20,08	98	50	95	52	91	40	93	51	91	42
34	8,15	66	130	54	124	48	114	54	123	49	117
35	25,44	74	102	70	92	61	92	69	100	64	90
36	37,83	129	174	122	160	114	149	119	159	112	148
37	56,91	83	221	84	213	72	211	81	217	73	209
38	53,49	145	2073	128	2021	117	1985	124	2013	0	1993
39	73,06	174	2122	169	2115	158	2099	163	2116	155	2100
40	5,37	48	46	44	43	0	44	39	45	36	41
41	19,24	102	69	99	66	82	61	93	64	84	63
42	25,67	57	120	53	119	45	111	51	118	48	112
43	93,18	316	2115	291	2094	269	2073	280	2093	264	2075
44	6,53	59	65	55	63	38	62	41	63	37	60
45	39,41	126	270	117	266	101	251	113	264	104	253
46	24,37	204	183	199	175	180	160	194	173	182	162
47	12,99	89	135	84	122	70	114	83	121	71	110
48	45,78	98	240	95	224	88	222	91	230	85	221
49	16,04	70	130	69	123	51	120	67	121	52	117
50	26,07	74	179	68	170	58	164	60	169	59	162

51	98,16	285	2144	277	2116	259	2109	273	2138	251	2107
52	3,08	49	33	42	32	38	28	40	30	37	26
53	38,50	91	238	83	227	75	224	79	230	78	218
54	22,01	66	172	59	159	46	156	54	159	45	147
55	74,19	163	2051	155	2036	147	1993	151	2021	142	1983
56	68,27	184	139	172	124	163	128	167	132	162	120
57	15,91	68	128	64	125	51	114	58	124	55	112
58	5,33	42	35	40	34	0	31	41	32	39	30
59	40,21	50	397	48	391	42	386	47	389	44	386
60	108,73	381	2499	377	2415	362	2387	374	2396	363	2385
61	60,49	139	396	133	338	124	325	130	337	127	321
62	102,53	388	2512	381	2444	362	2393	374	2499	365	2385
63	15,67	130	149	127	148	119	141	123	145	117	139
64	80,24	228	2174	226	2135	205	2115	214	2154	203	2116

Tabela A.19 – Resultados RVNS – Grafo Original para obtenção de 3 clusters

I	Solução best	RVNS									
		RVNS1		RVNS2		RVNS3		RVNS4		RVNS5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	17	143	14	129	7	125	8	132	1	123
2	39,08	29	205	23	192	15	174	19	197	8	184
3	5,72	22	48	17	37	7	36	11	38	4	30
4	26,14	20	196	19	175	8	171	16	184	7	167
5	7,35	19	62	3	51	0	49	1	55	0	48
6	6,41	12	65	2	57	0	44	0	59	0	45
7	6,17	8	73	0	42	0	35	0	44	0	38
8	4,96	7	44	0	36	0	29	0	38	0	29
9	14,35	24	124	7	118	0	117	3	121	2	112
10	19,78	33	82	4	66	0	65	1	69	0	64
11	10,27	32	151	21	114	9	109	12	124	2	107
12	17,33	40	84	18	72	9	61	13	78	1	65
13	7,42	15	99	5	80	1	73	3	86	0	71
14	5,94	27	147	0	115	0	111	0	129	0	109
15	18,53	26	86	19	69	11	59	14	74	1	58
16	7,09	18	132	8	104	2	90	5	118	0	93
17	10,81	33	117	23	81	10	69	18	94	0	68
18	6,33	19	64	0	46	0	48	0	50	0	47
19	57,14	59	2331	38	2292	0	2284	0	2316	11	2272
20	49,02	53	2396	24	2374	17	2361	21	2382	0	2354
21	70,51	86	2151	79	2128	42	2104	0	2134	0	2099
22	22,17	35	63	13	47	5	38	9	59	28	41
23	6,39	14	68	0	49	0	45	0	56	0	44
24	6,30	11	66	0	47	1	46	0	48	0	42
25	82,44	10	69	0	41	0	37	0	44	0	39
26	12,68	133	543	78	522	71	481	75	526	0	473
27	3,27	38	194	24	167	18	158	21	181	6	152
28	25,89	9	58	0	49	0	31	0	55	0	32
29	26,01	38	215	35	183	22	170	29	198	11	171
30	15,48	29	228	27	192	13	181	18	203	6	179
31	78,30	41	137	18	104	6	94	12	118	10	91
32	6,41	117	2581	77	2515	0	2497	0	2526	32	2502
33	20,08	14	66	8	47	2	47	5	53	0	43
34	8,15	42	149	6	134	0	122	4	147	2	117
35	25,44	29	118	14	107	2	99	9	113	0	94
36	37,83	37	190	19	173	14	162	17	188	10	168
37	56,91	48	305	24	257	18	253	23	292	15	249
38	53,49	66	2322	49	2291	0	2267	47	2303	0	2261
39	73,06	63	2331	45	2371	34	2315	39	2319	0	2317
40	5,37	10	71	4	40	0	36	3	42	0	39
41	19,24	21	64	11	53	0	48	9	57	2	46

42	25,67	35	138	28	113	19	104	24	126	7	97
43	93,18	162	2216	102	2184	64	2178	31	2192	0	2173
44	6,53	14	65	27	60	0	45	2	63	0	48
45	39,41	18	301	33	286	17	270	29	299	14	261
46	24,37	23	193	16	168	10	149	14	171	6	144
47	12,99	38	175	22	142	18	133	2	151	12	128
48	45,78	42	368	34	339	27	319	35	348	19	324
49	16,04	20	147	12	126	9	111	12	137	5	109
50	26,07	21	230	15	181	8	196	14	221	6	193
51	98,16	173	2689	104	2655	83	2642	88	2674	0	2636
52	3,08	5	42	0	30	0	28	0	33	0	27
53	38,50	20	257	19	236	14	224	18	246	10	218
54	22,01	22	183	5	157	1	145	6	179	0	139
55	74,19	86	2471	60	2434	0	2418	32	2460	0	2415
56	68,27	73	2454	49	2426	44	2414	2481	2437	0	2405
57	15,91	37	135	8	128	7	114	17	129	12	109
58	5,33	11	69	4	40	0	39	0	41	0	38
59	40,21	35	432	25	395	18	380	24	418	11	375
60	108,73	226	2918	99	2861	93	2776	97	2894	0	2741
61	60,49	63	389	42	353	39	341	43	369	41	326
62	102,53	151	2791	99	2774	98	2769	0	2787	92	2738
63	15,67	129	147	14	129	9	123	11	136	6	119
64	80,24	83	2502	75	2497	70	2485	51	2503	0	2470

Tabela A.20 – Resultados RVNS – AGM *Kruskal modificado* para obtenção de 3 clusters

I	Solução best	RVNS									
		RVNS_AGMM1		RVNS_AGMM2		RVNS_AGMM3		RVNS_AGMM4		RVNS_AGMM5	
		Gap	T(s)								
1	22,54	63	127	61	121	48	121	57	124	43	119
2	39,08	84	164	83	153	72	144	79	159	67	147
3	5,72	38	46	34	42	26	38	27	44	24	41
4	26,14	46	163	42	155	35	147	39	159	33	156
5	7,35	38	59	37	53	26	50	35	57	29	58
6	6,41	49	50	44	43	34	48	38	52	32	41
7	6,17	35	63	32	61	0	57	29	64	27	53
8	4,96	28	54	27	52	0	49	25	53	23	42
9	14,35	85	118	83	109	64	113	79	112	68	110
10	19,78	67	115	62	112	57	110	60	114	55	107
11	10,27	86	136	84	128	75	122	81	132	77	126
12	17,33	39	58	38	51	0	57	36	56	29	49
13	7,42	44	80	42	74	36	68	41	77	38	63
14	5,94	28	117	27	114	25	109	26	116	24	110
15	18,53	75	98	71	93	53	92	68	94	57	96
16	7,09	69	118	67	116	59	117	65	119	0	115
17	10,81	41	86	38	82	0	84	36	85	0	82
18	6,33	104	49	102	48	94	44	101	46	97	43
19	57,14	124	1981	118	1952	110	1971	115	1974	108	1963
20	49,02	113	2397	110	2371	93	2381	109	2385	95	2379
21	70,51	106	2274	104	2093	101	2117	103	2138	102	2124
22	22,17	51	61	50	58	37	59	48	60	39	56
23	6,39	68	52	63	47	44	48	57	49	46	43
24	6,30	34	43	32	40	28	39	30	42	29	41
25	82,44	159	49	154	46	141	45	143	47	139	46
26	12,68	153	482	151	471	0	467	149	473	142	462
27	3,27	47	171	46	167	41	158	45	169	42	155
28	25,89	69	40	63	48	49	54	58	52	51	52
29	26,01	94	187	90	192	76	189	88	196	0	194
30	15,48	76	204	72	182	65	178	71	199	69	180
31	78,30	105	2241	0	2207	0	2219	98	2233	87	2203
32	6,41	98	133	94	129	86	127	90	135	83	124
33	20,08	88	52	85	48	79	51	83	49	76	46
34	8,15	54	137	50	124	41	121	48	128	43	127

35	25,44	57	108	55	98	51	99	54	104	49	101
36	37,83	108	185	107	173	93	175	106	182	97	167
37	56,91	69	252	64	241	52	236	60	249	54	232
38	53,49	111	2104	109	2082	0	2071	103	2093	97	2068
39	73,06	152	2183	148	2124	135	2113	142	2167	137	2104
40	5,37	28	52	27	49	21	47	23	51	0	50
41	19,24	75	67	72	65	69	64	71	74	68	67
42	25,67	49	138	0	144	41	135	44	142	40	137
43	93,18	231	2153	230	2114	216	2102	228	2139	218	2093
44	6,53	37	72	37	69	32	63	36	71	0	61
45	39,41	96	284	92	291	81	282	89	286	83	273
46	24,37	179	201	170	212	152	203	164	208	155	207
47	12,99	68	146	65	127	52	116	63	137	51	122
48	45,78	76	257	76	241	67	248	74	251	69	245
49	16,04	51	135	48	127	41	123	45	128	38	126
50	26,07	67	182	65	163	46	169	53	174	47	173
51	98,16	239	2173	233	2132	214	2125	228	2150	217	2131
52	3,08	28	34	24	33	18	25	0	27	19	26
53	38,50	77	242	69	239	63	237	65	240	61	239
54	22,01	45	186	43	175	39	178	43	177	38	174
55	74,19	139	2064	134	2017	126	2034	125	2042	127	2037
56	68,27	154	2038	151	1992	142	2023	146	2025	139	2008
57	15,91	53	142	52	133	49	129	51	137	47	128
58	5,33	21	33	20	30	0	31	18	32	0	31
59	40,21	42	409	40	399	38	397	39	402	35	395
60	108,73	346	2585	337	2493	322	2528	328	2541	324	2533
61	60,49	115	364	113	351	107	352	112	357	108	354
62	102,53	344	2599	342	2470	324	2481	340	2493	325	2477
63	15,67	101	153	99	159	85	160	97	164	86	157
64	80,24	192	2191	187	2164	173	2175	183	2177	177	2169

Tabela A.21 – Resultados RVNS – AGM *Kruskal* padrão para obtenção de 3 clusters

I	Solução best	RVNS									
		RVNS_AGM1		RVNS_AGM2		RVNS_AGM3		RVNS_AGM4		RVNS_AGM5	
		Gap	T(s)								
1	22,54	93	123	84	119	61	117	79	120	55	115
2	39,08	99	151	91	148	79	135	84	142	73	137
3	5,72	51	45	49	43	38	39	42	42	37	40
4	26,14	73	159	66	154	44	144	57	151	0	148
5	7,35	49	64	43	57	35	49	41	54	34	51
6	6,41	57	52	55	44	36	43	48	50	37	38
7	6,17	48	61	42	56	28	51	39	59	31	47
8	4,96	42	53	40	50	29	47	41	51	30	40
9	14,35	91	117	88	112	73	110	82	114	76	108
10	19,78	89	113	75	111	60	109	74	112	63	105
11	10,27	102	135	94	127	85	120	89	128	81	119
12	17,33	48	57	43	52	37	55	41	53	35	46
13	7,42	69	79	61	71	44	64	56	74	42	61
14	5,94	42	114	39	112	33	105	38	111	33	104
15	18,53	83	101	77	92	67	91	72	98	68	93
16	7,09	81	119	78	116	65	113	74	117	61	112
17	10,81	56	84	49	81	38	83	42	84	35	80
18	6,33	123	47	118	46	101	42	115	43	104	41
19	57,14	146	1978	133	1943	118	1964	126	1955	113	1923
20	49,02	119	2356	115	2348	97	2327	100	2332	99	2314
21	70,51	128	2147	124	2081	118	2095	121	2125	115	2104
22	22,17	64	60	58	59	47	55	53	58	46	53
23	6,39	77	51	69	50	54	42	62	48	51	41
24	6,30	46	44	42	42	35	36	39	40	37	38
25	82,44	168	50	162	47	149	44	153	48	144	45
26	12,68	189	475	171	469	155	465	168	470	153	461
27	3,27	74	169	66	163	56	151	61	159	55	148

28	25,89	82	56	74	47	62	52	68	53	63	49
29	26,01	110	193	99	189	81	185	94	191	82	187
30	15,48	85	199	79	180	74	174	77	183	73	175
31	78,30	126	2206	119	2184	96	2154	113	2195	0	2168
32	6,41	111	130	108	128	90	118	104	126	92	117
33	20,08	99	50	93	46	85	49	89	43	82	42
34	8,15	61	135	59	124	48	116	53	127	49	121
35	25,44	84	109	75	100	63	95	72	102	67	97
36	37,83	127	181	124	175	105	163	119	179	108	154
37	56,91	83	239	79	233	66	219	68	228	63	214
38	53,49	118	2099	116	2085	104	2014	109	2093	102	2008
39	73,06	159	2140	155	2120	141	2038	147	2119	139	2027
40	5,37	48	50	43	48	32	46	39	49	33	45
41	19,24	89	65	85	62	73	69	78	66	75	63
42	25,67	72	148	61	141	0	132	52	140	49	129
43	93,18	289	2006	272	1990	245	1985	267	1993	238	1987
44	6,53	64	74	53	63	46	58	51	69	45	55
45	39,41	118	291	115	285	93	267	104	279	97	261
46	24,37	199	194	191	177	165	186	165	188	163	183
47	12,99	72	138	68	122	59	110	64	129	60	115
48	45,78	89	255	81	244	74	236	78	247	71	228
49	16,04	69	131	57	123	49	121	55	126	48	123
50	26,07	75	175	69	169	55	165	67	172	53	162
51	98,16	258	2117	241	2099	220	2093	236	2108	222	2085
52	3,08	30	33	28	32	19	24	0	28	21	23
53	38,50	89	240	83	241	74	235	79	242	69	231
54	22,01	55	181	52	173	41	176	48	175	42	171
55	74,19	154	2045	148	2026	135	2017	141	2028	133	2010
56	68,27	178	2013	170	1985	150	1993	156	1999	148	1997
57	15,91	73	134	68	129	57	118	63	127	56	116
58	5,33	28	32	22	31	0	29	19	30	17	29
59	40,21	57	404	53	397	42	386	48	395	44	383
60	108,73	369	2549	364	2528	350	2514	359	2536	351	2508
61	60,49	138	359	134	350	123	336	131	348	127	337
62	102,53	373	2601	362	2495	348	2473	359	2492	354	2451
63	15,67	114	165	109	152	92	159	101	163	93	152
64	80,24	216	480	208	2159	194	2134	199	2156	196	2123

Tabela A.22 – Resultados SVNS – Grafo Original para obtenção de 3 clusters

I	Solução best	SVNS									
		SVNS1		SVNS2		SVNS3		SVNS4		SVNS5	
		Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)	Gap	T(s)
1	22,54	15	141	7	135	0	128	4	139	0	124
2	39,08	18	193	9	184	2	167	11	172	0	163
3	5,72	17	49	10	41	1	37	6	44	0	38
4	26,14	23	198	14	185	4	168	9	191	0	176
5	7,35	18	68	2	59	0	50	0	62	0	53
6	6,41	6	62	0	47	0	44	0	51	0	42
7	6,17	4	57	0	45	0	38	0	48	0	36
8	4,96	5	49	1	36	0	30	2	38	0	28
9	14,35	22	131	4	122	0	115	0	129	0	119
10	19,78	31	108	3	94	0	71	0	83	0	67
11	10,27	27	149	11	123	2	101	5	118	0	104
12	17,33	38	77	17	68	4	63	10	74	0	59
13	7,42	7	91	0	82	0	79	0	88	0	75
14	5,94	23	139	4	128	0	115	0	135	3	108
15	18,53	21	92	16	79	1	73	8	87	0	62
16	7,09	12	119	1	98	0	86	1	102	0	91
17	10,81	28	122	13	86	0	72	11	99	0	63
18	6,33	16	56	2	47	0	47	0	48	0	45
19	57,14	65	2289	43	2269	15	2265	0	2271	0	2284

20	49,02	50	2406	39	2381	10	2371	18	2395	0	2379
21	70,51	64	2139	50	417	30	2104	14	2122	0	2101
22	22,17	33	61	8	54	0	43	1	58	0	39
23	6,39	10	57	0	50	0	41	0	52	0	41
24	6,30	13	55	1	49	0	42	0	50	0	40
25	82,44	18	58	11	42	0	39	0	44	0	37
26	12,68	127	541	81	527	21	470	68	541	4	498
27	3,27	28	193	19	182	8	178	15	183	0	164
28	25,89	8	50	0	33	0	30	0	36	0	30
29	26,01	33	214	29	192	10	181	18	204	0	173
30	15,48	20	233	17	203	4	194	10	217	0	189
31	78,30	37	127	9	101	8	82	15	103	2	90
32	6,41	94	2579	71	2512	0	2519	0	2521	15	2501
33	20,08	11	55	0	44	0	43	16	48	10	41
34	8,15	38	166	3	148	0	137	0	152	0	125
35	25,44	25	141	7	119	0	102	0	127	0	98
36	37,83	30	202	22	183	8	169	16	194	6	175
37	56,91	41	314	37	291	10	284	16	300	8	263
38	53,49	59	2337	41	2282	0	2263	31	2291	0	2269
39	73,06	57	2344	42	2329	20	2321	22	2337	0	2308
40	5,37	15	54	3	38	0	32	0	41	0	31
41	19,24	23	67	7	54	0	53	1	56	0	56
42	25,67	31	150	28	137	8	124	12	141	4	112
43	93,18	145	2226	94	2192	44	2185	23	2218	0	2171
44	6,53	12	59	0	49	0	44	1	53	0	46
45	39,41	47	296	33	281	12	276	18	288	1	269
46	24,37	22	185	17	157	5	152	8	169	0	147
47	12,99	39	162	29	138	14	141	21	149	0	135
48	45,78	44	353	35	340	18	338	22	344	1	321
49	16,04	35	151	12	136	6	110	8	141	0	114
50	26,07	17	234	10	203	9	209	11	218	2	199
51	98,16	182	2709	101	2672	69	2664	75	2693	0	2658
52	3,08	10	48	0	30	0	30	0	34	0	26
53	38,50	33	261	21	245	10	218	15	252	4	223
54	22,01	22	195	10	166	0	139	1	173	0	152
55	74,19	78	2462	59	2448	0	2421	0	2457	1	2427
56	68,27	76	2456	48	2433	0	2415	40	2441	1	2419
57	15,91	29	144	8	127	9	111	5	133	0	118
58	5,33	10	51	2	39	0	31	0	40	0	30
59	40,21	32	429	27	416	11	374	21	428	0	377
60	108,73	201	2814	90	2783	88	2773	95	2796	0	2760
61	60,49	65	371	45	352	39	347	40	354	0	339
62	102,53	184	2804	101	2780	94	2745	0	2798	10	2765
63	15,67	33	152	12	146	4	138	8	151	0	128
64	80,24	72	2511	67	504	55	2491	45	2500	0	2482

Tabela A.23 – Resultados SVNS – AGM *kruskal* modificado para obtenção de 3 clusters

I	Solução best	SVNS									
		SVNS_AGMM1		SVNS_AGMM2		SVNS_AGMM3		SVNS_AGMM4		SVNS_AGMM5	
		Gap	T(s)								
1	22,54	57	131	43	127	26	119	38	128	24	120
2	39,08	79	165	74	156	61	148	66	163	58	143
3	5,72	30	51	29	48	0	44	28	49	24	45
4	26,14	44	169	41	162	34	155	37	165	31	157
5	7,35	37	58	32	51	16	42	29	53	18	44
6	6,41	46	52	43	48	38	43	44	51	0	47
7	6,17	33	62	30	60	24	54	29	61	21	53
8	4,96	25	57	23	53	22	51	0	55	20	49
9	14,35	81	123	78	117	61	115	77	121	65	113
10	19,78	64	110	0	103	43	96	56	108	47	100
11	10,27	85	149	84	137	78	133	82	144	77	131
12	17,33	35	61	33	55	22	54	28	58	21	51

13	7,42	38	85	37	81	29	75	34	83	30	79
14	5,94	24	122	21	119	20	108	0	120	0	112
15	18,53	71	101	69	97	0	98	63	99	56	95
16	7,09	67	119	64	114	51	108	55	116	48	110
17	10,81	42	85	41	80	39	80	0	83	37	79
18	6,33	99	48	93	44	78	45	85	46	81	43
19	57,14	123	1996	119	1983	112	1973	118	1987	104	1981
20	49,02	114	2400	112	2391	97	2364	109	2396	0	2373
21	70,51	108	2285	105	2107	98	2098	104	2215	97	2085
22	22,17	57	66	49	49	41	41	43	53	38	45
23	6,39	61	53	60	55	0	54	58	56	43	52
24	6,30	32	44	31	41	21	39	29	42	22	38
25	82,44	151	49	144	42	129	40	138	47	133	40
26	12,68	144	490	139	486	121	475	127	489	119	473
27	3,27	43	183	34	172	33	164	36	177	28	159
28	25,89	68	41	59	30	51	33	55	38	49	35
29	26,01	90	193	0	181	76	183	81	187	73	180
30	15,48	71	202	68	197	57	198	63	199	54	195
31	78,30	107	2263	101	2251	0	2225	97	2257	92	2235
32	6,41	94	125	84	108	71	116	75	114	62	110
33	20,08	85	57	82	50	73	48	76	54	69	45
34	8,15	49	142	44	132	29	127	35	139	31	135
35	25,44	56	109	53	100	38	109	48	104	0	108
36	37,83	98	193	92	185	72	178	85	187	73	183
37	56,91	67	264	64	255	52	241	0	258	55	244
38	53,49	101	2113	99	2104	81	2097	95	2109	83	2085
39	73,06	143	2196	141	2182	132	2185	136	2187	128	2183
40	5,37	22	55	19	49	13	50	19	52	0	47
41	19,24	68	69	62	60	51	62	53	64	47	58
42	25,67	47	141	41	132	27	135	38	139	23	133
43	93,18	225	2160	220	2144	203	2149	218	2155	204	2153
44	6,53	31	71	28	67	0	65	27	69	0	67
45	39,41	89	297	84	284	62	271	73	285	67	252
46	24,37	178	203	173	189	151	187	164	192	152	183
47	12,99	67	154	62	131	38	128	58	144	42	125
48	45,78	73	261	70	249	63	242	67	253	59	251
49	16,04	48	142	41	133	24	137	37	137	28	139
50	26,07	66	197	59	174	41	163	54	182	45	159
51	98,16	218	2190	214	2152	193	2169	208	2173	197	2170
52	3,08	22	36	20	32	0	34	19	35	0	33
53	38,50	75	258	69	243	52	239	65	244	56	235
54	22,01	44	194	38	182	29	174	36	185	30	171
55	74,19	133	2096	127	2041	120	2069	0	2074	121	2072
56	68,27	151	2042	149	2008	129	2031	146	2035	133	2028
57	15,91	46	143	45	131	42	135	44	138	41	133
58	5,33	18	36	17	35	0	36	15	37	0	39
59	40,21	46	417	42	404	32	408	38	412	33	411
60	108,73	337	2609	325	2503	313	2571	318	2582	309	2568
61	60,49	104	376	101	354	87	360	99	364	83	357
62	102,53	339	2613	328	2597	315	2593	0	2610	317	2599
63	15,67	98	168	92	163	72	157	86	165	75	153
64	80,24	194	2297	152	2271	155	2264	175	2283	169	2269

Tabela A.24 – Resultados SVNS – AGM *kruskal* padrão para obtenção de 3 clusters

I	Solução best	SVNS									
		SVNS_AGM1		SVNS_AGM2		SVNS_AGM3		SVNS_AGM4		SVNS_AGM5	
		Gap	T(s)								
1	22,54	65	122	61	117	29	106	41	119	28	108
2	39,08	83	145	85	142	66	131	74	142	63	134
3	5,72	59	47	54	48	25	41	35	39	27	42
4	26,14	48	173	52	153	39	151	40	160	38	149
5	7,35	44	55	36	51	19	41	38	49	21	38

6	6,41	71	54	68	49	52	40	69	42	55	43
7	6,17	69	69	50	58	39	51	40	63	33	49
8	4,96	70	59	65	53	0	49	43	58	34	44
9	14,35	157	121	96	119	81	114	154	115	78	111
10	19,78	113	107	99	104	55	93	63	101	51	97
11	10,27	145	139	108	140	98	127	107	135	93	124
12	17,33	102	67	68	64	35	55	51	63	38	52
13	7,42	53	84	37	85	27	79	40	80	29	72
14	5,94	96	118	81	117	68	106	74	113	65	110
15	18,53	82	110	77	95	66	97	81	99	68	90
16	7,09	89	116	75	114	41	105	69	111	44	107
17	10,81	151	93	118	87	101	82	123	81	106	84
18	6,33	128	64	112	47	85	44	107	52	99	45
19	57,14	164	1985	151	1974	142	1960	155	1977	0	1963
20	49,02	156	2301	140	2285	133	2235	141	2296	125	2251
21	70,51	145	2205	139	2115	110	2008	136	2173	114	1998
22	22,17	73	57	66	48	49	37	58	44	45	40
23	6,39	81	56	79	53	65	52	74	53	68	51
24	6,30	63	42	58	39	37	33	50	40	39	35
25	82,44	205	48	177	45	161	37	184	44	167	32
26	12,68	169	483	156	479	141	462	148	481	135	451
27	3,27	62	174	45	167	42	159	46	162	39	153
28	25,89	85	39	79	36	74	30	0	33	67	32
29	26,01	101	190	96	174	88	167	104	185	90	163
30	15,48	90	198	78	189	69	185	72	194	63	182
31	78,30	156	2185	121	2159	117	2138	122	2170	115	2145
32	6,41	143	115	97	112	88	109	96	98	84	104
33	20,08	72	61	99	52	86	46	91	54	84	43
34	8,15	57	139	60	129	44	120	38	133	42	124
35	25,44	74	112	69	99	48	95	63	108	40	93
36	37,83	130	185	113	172	88	157	96	174	85	161
37	56,91	82	251	85	243	71	236	83	249	70	233
38	53,49	149	2104	112	2057	96	2012	108	2097	91	2001
39	73,06	158	2167	165	2145	142	2124	152	2159	135	2114
40	5,37	44	63	31	44	24	42	33	54	25	39
41	19,24	89	65	85	61	0	58	71	59	53	55
42	25,67	55	139	54	128	39	125	46	133	37	122
43	93,18	251	2144	238	2112	242	2083	233	2128	241	2098
44	6,53	40	70	37	74	18	65	31	68	15	63
45	39,41	105	277	93	268	77	259	79	275	74	241
46	24,37	246	196	214	189	171	185	188	192	173	181
47	12,99	81	142	74	139	59	121	63	137	57	118
48	45,78	89	251	84	252	72	238	79	244	65	247
49	16,04	64	141	48	138	31	130	44	129	33	134
50	26,07	82	184	69	175	50	161	65	169	57	163
51	98,16	257	2135	245	2107	212	2023	236	2128	215	2014
52	3,08	44	34	41	34	25	31	39	30	24	32
53	38,50	82	255	77	239	61	229	73	241	68	228
54	22,01	49	184	45	171	39	169	41	173	37	163
55	74,19	155	2088	153	2065	136	2054	149	2071	138	2059
56	68,27	179	2053	162	2023	141	2017	157	2039	144	2014
57	15,91	74	146	69	129	53	127	66	135	0	128
58	5,33	33	42	27	38	14	33	24	39	12	35
59	40,21	68	410	58	401	46	395	55	402	45	397
60	108,73	362	2599	349	2524	323	2508	341	2537	315	2503
61	60,49	128	368	117	355	93	352	104	366	95	349
62	102,53	356	2627	342	2593	321	2564	339	2615	329	2571
63	15,67	112	172	99	163	84	155	93	164	81	152
64	80,24	217	2246	193	2201	168	2218	188	2214	179	2185