

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE COMPUTAÇÃO**

RÔMULO LOUZADA RABELLO

**APLICAÇÃO DA META-HEURÍSTICA CLUSTERING
SEARCH AO PROBLEMA DE ROTULAÇÃO
CARTOGRÁFICA DE PONTOS**

ALEGRE - ES

2013

RÔMULO LOUZADA RABELLO

**APLICAÇÃO DA META-HEURÍSTICA CLUSTERING
SEARCH AO PROBLEMA DE ROTULAÇÃO
CARTOGRÁFICA DE PONTOS**

Trabalho de conclusão de curso apresentado ao Departamento de Computação do Centro de Ciências Agrárias da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Geraldo Regis Mauri.

ALEGRE - ES

2013

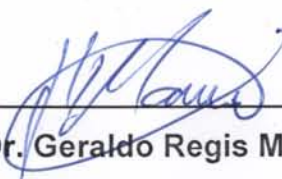
RÔMULO LOUZADA RABELLO

**APLICAÇÃO DA META-HEURÍSTICA CLUSTERING
SEARCH AO PROBLEMA DE ROTULAÇÃO
CARTOGRÁFICA DE PONTOS**

Trabalho de conclusão de curso apresentado ao Departamento de Computação do Centro de Ciências Agrárias da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do grau de Bacharel em Ciência da Computação.

Aprovado em 03 de setembro de 2013.

COMISSÃO EXAMIDADORA



Prof. Dr. Geraldo Regis Mauri
Universidade Federal do Espírito Santo
Orientador



Prof. M.Sc. Antonio Almeida de Barros Junior
Universidade Federal do Espírito Santo



Prof. M.Sc. Edmar Hell Kampke
Universidade Federal do Espírito Santo

A meus pais, Neuza e Júlio que me apoiaram e me deram força durante toda graduação.

AGRADECIMENTOS

A Deus, por guiar e permitir encerrar essa etapa de minha vida.

A toda minha família, especialmente meus pais Neuza e Júlio, por enfrentar tantas dificuldades nesses anos de graduação, mas mesmo assim, nunca desistirem e estarem sempre com um sorriso no rosto e confiança que tudo daria certo.

Aos meus amigos, Vinícius, Pablo e André, por todos os trabalhos do professor Clayton enfrentados juntos.

A todos os professores do DCOMP, pelos ensinamentos transmitidos.

Ao professor Geraldo, pela orientação desde o projeto de iniciação científica até este trabalho de conclusão de curso.

Aos professores Luiz Antonio Nogueira Lorena (INPE) e Glaydston Mattos Ribeiro (UFRJ) pela coorientação na Iniciação Científica que deu origem a este trabalho.

A Sara, por todo companheirismo, carinho e todos os momentos vividos nestes 4 anos.

A todas as amigas construídas na faculdade, pelos trabalhos, peladas, festas e momentos que nunca esquecerei.

A todos, muito obrigado.

RESUMO

Este trabalho tem como objetivo apresentar uma alternativa para a resolução do Problema de Rotulação Cartográfica de Pontos (PRCP). Em mapas cartográficos, existe a necessidade de delimitar áreas de interesse como cidades, edificações, estações de trem, etc., conferindo rótulos (textos) a essas áreas. O PRCP consiste em organizar esses rótulos, referentes a cada área de um mapa, de modo que não ocorram sobreposições, proporcionando assim uma melhor clareza na visualização dos mesmos. O PRCP é de grande importância para aplicações que fazem uso de recursos computacionais na geração de mapas como, por exemplo, sistemas comerciais de georreferenciamento e aplicações *Web*. A ideia central deste trabalho consiste na aplicação da meta-heurística híbrida *Clustering Search* para resolução do PRCP. Para verificar o desempenho do método proposto, foram utilizadas instâncias encontradas na literatura, e os resultados obtidos foram comparados a outros métodos já estudados para a resolução do PRCP.

Palavras-chave: *Clustering Search*; Problema de Rotulação Cartográfica de Pontos; Meta-heurística Híbrida.

APPLYING A CLUSTERING SEARCH METAHEURISTIC FOR THE POINT-FEATURE CARTOGRAPHIC LABEL PLACEMENT PROBLEM

ABSTRACT

An alternative methodology to solve the Point-Feature Cartographic Label Placement (PFCLP) is the main objective of this work. In cartographic maps, there is necessary to assign labels (texts) to areas, for example: cities, buildings, train stations, etc. The PFCLP consists of organize these text labels on a map avoiding overlaps to improve the map visualization. The PFCLP has a great importance for applications that use computational resources to generate maps, for example, georeferencing systems and web applications. The main idea of this work is based on applying the Clustering Search hybrid metaheuristic to solve the PFCLP. Instances found in the literature were used to verify the performance of the proposed method and computational results were compared against other methods that have been studied for solving the PFCLP.

Keywords: Clustering Search, Point-Feature Cartographic Label Placement, Hybrid Metaheuristic.

LISTA DE FIGURAS

Figura 1 - Exemplo de mapa com sobreposições de rótulos.....	13
Figura 2 - Padronização proposta por Christensen et al. (1995).....	13
Figura 3 - Exemplo da modelagem do problema.....	18
Figura 4 - Fluxograma da CS.	20
Figura 5 - Exemplo do cálculo da distância de Hamming.....	21
Figura 6 - Pseudocódigo da CS implementada.	22
Figura 7 - <i>Crossover</i>	24
Figura 8 - Mutação.	25
Figura 9 - Pseudocódigo da ECS implementada.....	25

LISTA DE TABELAS

Tabela 1 - Parâmetros finais das meta-heurísticas ECS, CS e CS*	28
Tabela 2 - Resultados obtidos para as instâncias com 750 pontos.....	30
Tabela 3 - Resultados obtidos para as instâncias com 1000 pontos.....	31
Tabela 4 - Comparação dos resultados obtidos (%RL) com a literatura (250, 500, 750 e 1000 pontos).	32
Tabela 5 - Resultados obtidos para as instâncias com 13206 pontos considerando 4 posições candidatas.....	33
Tabela 6 - Comparação dos resultados obtidos (%RL) com a literatura (13206 pontos - 4 posições candidatas).	34
Tabela 7 - Resultados obtidos para as instâncias com 13206 pontos considerando 8 posições candidatas.....	35
Tabela 8 - Comparação dos resultados obtidos (%RL) com a literatura (13206 pontos - 8 posições candidatas).	36

LISTA DE ABREVIATURAS E SIGLAS

AG – Algoritmo Genético

CS – *Clustering Search*

ECS – *Evolutionary Clustering Search*

GRASP – *Greedy Randomized Adaptive Search Procedure*

ILS – *Iterated Local Search*

OC – Otimização Combinatória

POPMUSIC – *Partial Optimization Metaheuristic under Special Intensification Conditions*

PRCP – Problema de Rotulação Cartográfica de Pontos

RL – Rótulos Livres

SA – *Simulated Annealing*

SUMÁRIO

1 INTRODUÇÃO	12
1.1 O PROBLEMA E SUA IMPORTÂNCIA.....	12
1.2 OBJETIVOS.....	14
1.2.1 Objetivo geral.....	14
1.2.2 Objetivos específicos.....	14
2 REVISÃO DA LITERATURA	16
3 METODOLOGIA	18
3.1 MODELAGEM DO PROBLEMA	18
3.2 CLUSTERING SEARCH (CS).....	18
3.3 PRINCIPAIS COMPONENTES DA CS.....	20
3.3.1 Gerador de soluções.....	20
3.3.2 Agrupamento iterativo.....	20
3.3.3 Função objetivo	21
3.3.4 Processo de assimilação	21
3.3.5 Processo de análise para execução de busca local	22
3.4 EVOLUTIONARY CLUSTERING SEARCH (ECS)	23
3.5 PRINCIPAIS COMPONENTES DA ECS	24
3.5.1 Seleção.....	24
3.5.2 Cruzamento	24
3.5.3 Mutação.....	25
3.6 TESTES COMPUTACIONAIS	26
4 RESULTADOS	27
5 CONCLUSÕES	38
REFERÊNCIAS BIBLIOGRÁFICAS	39

1 INTRODUÇÃO

Problemas de Otimização Combinatória (OC) têm como objetivo geral minimizar ou maximizar uma função matemática na qual as variáveis estão limitadas a um conjunto de restrições. Esses problemas estão presentes em diversas áreas e podem ser encontrados em atividades do dia-a-dia como a criação de horários escolares, a elaboração de mapas cartográficos, o controle de tráfego de veículos, entre outros. Problemas de OC são em grande parte difíceis de obter soluções ótimas ou até mesmo aproximadas. Para alguns desses problemas, encontrar soluções viáveis manualmente é uma tarefa quase impossível, ou pelo menos, impraticável.

1.1 O PROBLEMA E SUA IMPORTÂNCIA

A rotulação cartográfica é o processo de atribuir rótulos (textos) referenciando objetos cartográficos em diagramas, gráficos ou mapas (WOLFF, 1999). De modo geral, objetos cartográficos carregam informações usadas para representação de cidades, edificações, estações de trem, rios, estradas, países, oceanos, etc.

O Problema de Rotulação Cartográfica de Pontos (PRCP) é uma tarefa importante na cartografia e consiste em determinar posições de pontos em um mapa levando em conta a restrição de não ocasionar conflitos entre os rótulos desses pontos, ou seja, alcançar o maior número possível de pontos sem sobreposições, proporcionando assim uma maior clareza na visualização. A Figura 1 ilustra um mapa com sobreposições de rótulos, sendo que as setas indicam os locais identificados com grande “poluição visual”.

Pode-se observar, de acordo com a Figura 1, que o Problema de Rotulação Cartográfica de Pontos (PRCP) é de grande importância para aplicações que utilizam recursos computacionais na geração de mapas.

O PRCP é um problema de otimização combinatória e faz parte da classe de problemas classificados na literatura como *NP-Hard* (MARKS; SHIEBER, 1991). Segundo Yamamoto (1998), a rotulação cartográfica de pontos executada de forma manual leva cerca de 1 ano para ser concluída. Visto que o tempo gasto

manualmente no processo é muito longo, é possível perceber a necessidade da aplicação de métodos computacionais para a resolução do problema em tempo hábil.

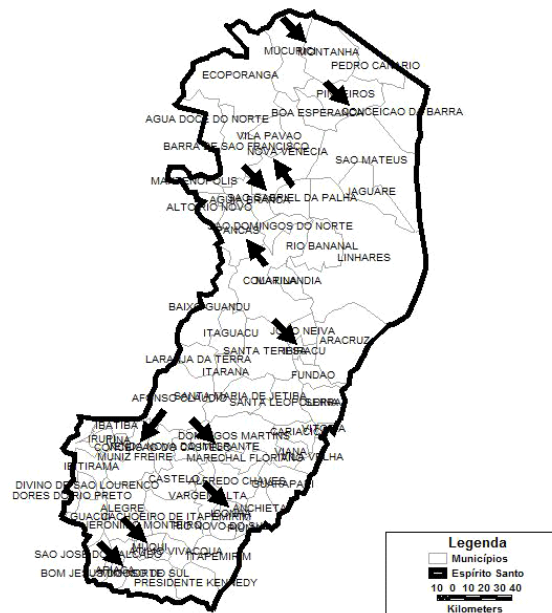


Figura 1 - Exemplo de mapa com sobreposições de rótulos.

Fonte: Ribeiro e Lorena (2008b).

Uma alternativa para melhorar a visualização e reduzir as sobreposições é deslocando os rótulos de modo a não conflituarem, respeitando sempre que os mesmos devem estar situados perto de seus respectivos pontos. Com isso, é apresentado o conceito de posição candidata. As posições candidatas são as possíveis posições que um rótulo pode ocupar, obedecendo sempre a uma padronização cartográfica.




Figura 2 - Padronização proposta por Christensen et al. (1995).

Uma das padronizações cartográficas mais conhecidas e utilizadas na literatura é a padronização proposta por Christensen et al. (1995), ilustrada na Figura 2. Como pode ser observado, as regiões de 1 a 8 representam as posições que um rótulo

pode assumir, sendo que quanto menor o número da região, maior é sua preferência cartográfica (OLIVEIRA et al., 2010).

No PRCP, as sobreposições de rótulos podem ser aceitas ou não. Quando as sobreposições são aceitas, todos os pontos serão rotulados, porém, deve-se rotular o maior número de pontos sem conflitos minimizando o número de conflitos entre os pontos. Caso as sobreposições não sejam permitidas, deve-se rotular o maior número possível de pontos, sendo que alguns pontos poderão ficar sem rótulos. Nesse caso, o PRCP pode ser visto como um Problema de Máximo Conjunto Independente (STRIJK et al., 2000; RIBEIRO et al., 2011). A abordagem escolhida para estudo neste trabalho foi a de aceitar sobreposições. Nesse caso, o objetivo é maximizar o número de rótulos “livres” (ALVIM e TAILLARD, 2009; MAURI et al., 2010). Uma formulação matemática para essa abordagem é apresentada em Mauri et al. (2010).

1.2 OBJETIVOS

A seguir são descritos os objetivos gerais e específicos relacionados a este trabalho.

1.2.1 Objetivo geral

O objetivo geral deste trabalho é a aplicação da meta-heurística híbrida *Clustering Search* (CS) ao Problema de Rotulação Cartográfica de Pontos, ou seja, apresentar uma alternativa para a resolução do problema em questão.

1.2.2 Objetivos específicos

- a) Desenvolver as adaptações necessárias para modelagem do PRCP e aplicação da CS;
- b) Aplicar o método proposto às principais instâncias (*benchmarks*) encontradas na literatura;

- c) Avaliar o desempenho do método por meio de experimentos computacionais comparados a outros trabalhos e/ou métodos existentes na literatura.

O restante deste trabalho está dividido da seguinte forma: No Capítulo 2 é apresentada uma revisão bibliográfica dos principais e mais recentes trabalhos sobre o PRCP. O Capítulo 3 detalha a metodologia utilizada para o desenvolvimento deste trabalho e os resultados obtidos são descritos no Capítulo 4. Por fim, no Capítulo 5, são apresentadas as conclusões deste trabalho.

2 REVISÃO DA LITERATURA

Constam na literatura diversos trabalhos sobre o Problema de Rotulação Cartográfica de Pontos (PRCP). A seguir, é apresentada uma revisão bibliográfica em ordem cronológica dos principais trabalhos sobre este problema.

Christensen et al. (1995) apresentaram um dos primeiros e principais trabalhos referentes ao PRCP, no qual foram propostos diversos algoritmos para sua resolução, entre eles um algoritmo guloso com sucessivas otimizações locais.

Verner et al. (1997) fizeram uso de um Algoritmo Genético e um Algoritmo Genético com Máscaras. O trabalho com máscaras se dava de modo que, se houvesse conflito, era liberada a troca de posições por meio de mutações e cruzamentos.

Uma Busca Tabu eficiente foi proposta por Yamamoto et al. (2002), que forneceu os melhores resultados quando comparados a literatura até então. Esses resultados foram superados pelo trabalho de Yamamoto e Lorena (2005), no qual foi apresentado um Algoritmo Genético Construtivo, proposto por Lorena e Furtado (2001), que foi testado para as instâncias com até 1000 pontos.

Cravo et al. (2008) propuseram um algoritmo *Greedy Randomized Adaptive Search Procedure* (GRASP) como alternativa de resolução do PRCP. Na fase construtiva do método proposto, uma solução viável é montada ponto a ponto e, na segunda fase, são executados movimentos de troca nas posições candidatas, analisando e armazenando sempre a melhor solução. Os resultados obtidos foram superiores aos de Yamamoto e Lorena (2005).

Ribeiro e Lorena (2008b,a) apresentaram, respectivamente, uma Relaxação Lagrangiana com *Clusters* (LagClus) e uma Geração de Colunas combinada com a LagClus, e os resultados obtidos provaram a otimalidade de algumas instâncias, além de apresentarem algumas soluções superiores às obtidas por Cravo et al. (2008).

A meta-heurística *Partial Optimization Metaheuristic under Special Intensification Conditions* (POPMUSIC), proposta por Taillard e Voss (2001), foi utilizada por Alvim e Taillard (2009). A POPMUSIC divide o problema em subproblemas e aplica uma

Busca Tabu, baseada na proposta por Yamamoto et al. (2002), para otimizar os subproblemas. Diversas variações tanto da POPMUSIC quanto da Busca Tabu foram apresentadas. Para as instâncias mais conhecidas até então, com até 1000 pontos a serem rotulados, o método proposto superou os resultados conhecidos. Os autores ainda propuseram um conjunto de instâncias com 13206 pontos.

Mauri et al. (2010) apresentaram novas abordagens para resolução do PRCP, propondo uma nova formulação matemática e uma técnica baseada na Decomposição Lagrangiana. Os autores apresentaram melhores soluções e provaram a otimalidade, até então desconhecida, para diversas instâncias com até 1000 pontos. O modelo proposto por Mauri et al. (2010) foi utilizado por Ribeiro et al. (2009), que propuseram algumas desigualdades para fortalecer o modelo, e obtiveram melhores soluções para as instâncias com 1000 pontos.

Oliveira et al. (2009,2010) apresentaram uma heurística de *Backtracking* e uma *Iterated Local Search* (ILS), as quais obtiveram os melhores resultados para as instâncias de 1000 e 13206 pontos.

3 METODOLOGIA

A metodologia utilizada neste trabalho pode ser dividida em duas partes. A primeira parte consiste na descrição minuciosa sobre a meta-heurística *Clustering Search* (CS). E a segunda é um detalhamento a respeito da meta-heurística *Evolutionary Clustering Search* (ECS), também implementada ao longo deste trabalho. Finalizando este capítulo, há uma explicação de como foram executados os testes computacionais para verificação do desempenho dos métodos propostos.

3.1 MODELAGEM DO PROBLEMA

Visando à implementação, foi realizada uma modelagem do problema de modo a tornar essa etapa o mais simples possível. Para isso, foi utilizada uma estrutura de vetor de números inteiros, na qual cada posição do vetor representa uma posição candidata do respectivo rótulo. Exemplificando, na primeira posição do vetor o valor presente é referente à posição candidata do rótulo para o ponto 1, a segunda é referente ao ponto 2 e assim por diante. Com isso, foi possível representar as posições candidatas de todos os pontos, assim como ilustrado na Figura 3, que apresenta um exemplo hipotético com 8 pontos a serem rotulados considerando 4 posições candidatas.

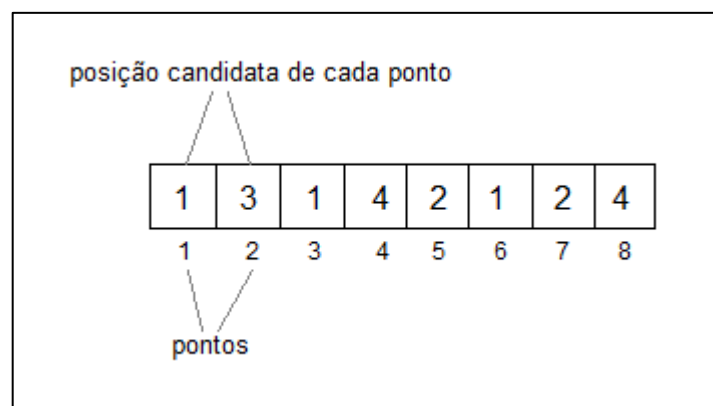


Figura 3 - Exemplo da modelagem do problema.

3.2 CLUSTERING SEARCH (CS)

De uma forma geral, a metodologia proposta neste trabalho como alternativa de resolução do Problema de Rotulação Cartográfica de Pontos (PRCP) consiste na

aplicação da meta-heurística *Clustering Search* (CS). A CS é uma meta-heurística híbrida, proposta por Oliveira e Lorena (2007), que faz uso de agrupamentos para identificar regiões promissoras no espaço de busca. A CS é uma generalização da meta-heurística ECS (*Evolutionary Clustering Search*), proposta por Oliveira e Lorena (2004), na qual há a substituição do algoritmo evolutivo por outras meta-heurísticas como, GRASP, *Simulated Annealing* (SA), etc.

A CS trabalha com o agrupamento de cada nova solução em *clusters*, associando-a a um *cluster* de acordo com uma métrica de distância. A CS utiliza uma quantidade de *clusters* definida previamente. Com o decorrer da execução, a CS acrescenta uma “inteligência” para a escolha dos *clusters* mais promissores, e nesses, é aplicada uma busca mais específica.

Um *cluster* C_i pode ser definido como uma tupla (c_i, v_i, r_i) , onde c_i , v_i e r_i representam o centro, o volume e o índice de ineficácia do *cluster* i . O centro c_i do *cluster* armazena uma solução que representa o *cluster* i , v_i representa o volume do *cluster* i , ou seja, a quantidade de soluções que estão presentes naquele *cluster* e r_i controla a execução da busca local, guardando o número de vezes em que a busca foi executada no *cluster* i e não obteve melhora na solução presente no seu centro.

A execução de uma iteração do método é descrita a seguir. Inicialmente, uma meta-heurística geradora de soluções faz o papel de “alimentar” a CS. Quando uma nova solução chega à CS, ela é atribuída ao *cluster* i mais similar. Com essa assimilação, o *cluster* i é posto em estudo, verificando seu volume v_i e seu índice de ineficácia r_i . Por meio do volume, é verificado se o *cluster* i em estudo é promissor, ou seja, seu volume v_i atingiu um limitante λ . Caso seja, a busca local é aplicada em seu centro. Se a estratégia de busca é aplicada r_{max} vezes sem sucesso (sem melhorar o centro do *cluster*), uma perturbação é aplicada no centro do *cluster*. Isso evita intensificar a busca em áreas que já foram suficientemente exploradas.

Neste trabalho, a CS foi implementada com base na proposta por Ribeiro et al. (2012). A Figura 4 ilustra o fluxograma de execução da CS. Mais detalhes sobre esse método são apresentados em Chaves e Lorena (2010).

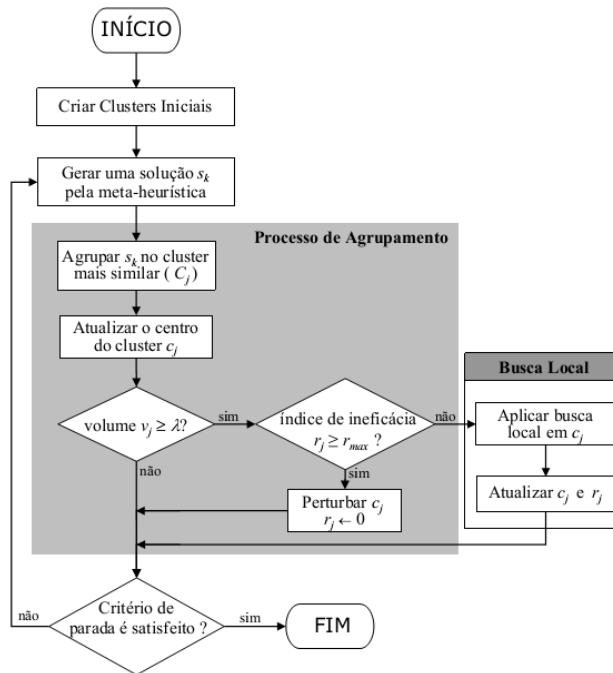


Figura 4 - Fluxograma da CS.

Fonte: Chaves e Lorena (2010).

3.3 PRINCIPAIS COMPONENTES DA CS

3.3.1 Gerador de soluções

O gerador de soluções da CS deve ser uma meta-heurística, e essa meta-heurística deve ter a capacidade de gerar um grande número de soluções diferentes e enviá-las à CS. A capacidade de gerar soluções diferentes é importante para que seja possível uma análise ampla do espaço de busca. *Simulated Annealing* e Algoritmo Genético são exemplos de meta-heurísticas que já foram utilizadas como geradoras de soluções para a CS em outros trabalhos. Neste trabalho, um algoritmo *Simulated Annealing* (SA) foi utilizado como gerador de soluções, pelo fato deste ter apresentado bons resultados quando aplicado em conjunto com a CS para resolução de outros problemas de otimização. A vizinhança utilizada pelo SA é similar à mutação descrita na Seção 3.5.3.

3.3.2 Agrupamento iterativo

Considerando o número de *clusters* γ , uma nova solução s , concebida pelo gerador de soluções, é atribuída ao *cluster* i mais próximo, de acordo com a distância de

Hamming H_i (HAMMING, 1950) que, neste trabalho, foi calculada de acordo com o número de pontos cuja posição candidata selecionada é diferente entre as soluções s e c_i . Assim, nesse processo, a solução s é atribuída ao *cluster* i que minimiza a função $\arg \min_{i \in \{1, \dots, \gamma\}} \{H_i\}$. A Figura 5 apresenta um exemplo do cálculo da distância de Hamming, onde são apresentados dois vetores de posições candidatas representando duas soluções. As posições dos vetores destacadas em cor mais escura demonstram exatamente as posições em que os valores diferem um do outro, e o número de posições com valores diferentes representa o resultado do cálculo da distância de Hamming.




Figura 5 - Exemplo do cálculo da distância de Hamming.

3.3.3 Função objetivo

A função objetivo utilizada neste trabalho tenta maximizar o número de rótulos sem sobreposições, ou seja, $v(s)$ = número de rótulos sem sobreposição, sendo que $v(s)$ denota o valor da solução s . A padronização utilizada neste trabalho foi a proposta por Christensen et al. (1995), sem considerar a preferência de quanto menor a sua região maior a sua preferência, assim como nos principais trabalhos sobre o PRCP, ou seja, o rótulo poderá ser alocado em qualquer posição candidata do ponto.

3.3.4 Processo de assimilação

A partir do momento em que uma solução s chega da meta-heurística geradora e é assimilada a um *cluster* i , seu volume v_i e seu centro c_i são atualizados. Para atualização do centro do *cluster* i , será utilizada uma “assimilação direta”, ou seja, se a solução s for melhor que o centro do *cluster* i , então s se tornará o novo centro do mesmo, caso contrário o centro permanecerá inalterado.

3.3.5 Processo de análise para execução de busca local

Quando o volume v_i de um *cluster* i alcança um limite λ , significa que o número de soluções assimiladas naquele *cluster* foi alto, então uma busca local é aplicada no centro desse *cluster* para intensificar a exploração desse espaço que se tornou promissor. Caso a busca local seja aplicada mais de r_{max} vezes no *cluster* i , sem obter melhora, então é aplicada uma perturbação no centro desse *cluster*.

A partir desses componentes principais, tem-se a CS, baseada na proposta por Ribeiro et al. (2012). O pseudocódigo da CS utilizada neste trabalho é apresentado na Figura 6.

```

1. Criar  $\gamma$  novas soluções (clusters) aleatoriamente
2.  $v_i \leftarrow 0$ ; e  $r_i \leftarrow 0$ ;  $\forall i = 1, \dots, \gamma$ ;
3.  $s \leftarrow$  solução inicial;  $s^* \leftarrow s$ ;  $T \leftarrow T_0$ ;
4. ENQUANTO  $T > T_c$  FAÇA
5.    $iter \leftarrow 0$ ;
6.   ENQUANTO  $iter < SA_{max}$  FAÇA
7.      $iter \leftarrow iter + 1$ ;
8.      $s' \leftarrow$  uma solução vizinha de  $s$ ;
9.     SE  $v(s') > v(s)$  ENTÃO
10.       $s \leftarrow s'$ ;
11.     SENÃO
12.       Com probabilidade  $e^{-(v(s)-v(s'))/T}$   $s \leftarrow s'$ ;
13.     FIM-SE
14.   FIM-ENQUANTO
15.    $T \leftarrow \alpha T$ ;  $i \leftarrow \arg \min_{i \in \{1, \dots, \gamma\}} \{H_i\}$ ;  $v_i \leftarrow v_i + 1$ ;
16.    $c_i \leftarrow$  melhor( $s, c_i$ );
17.   SE  $v_i = \lambda$  ENTÃO
18.      $v_i \leftarrow 0$ ;  $s \leftarrow$  busca local( $c_i$ );
19.     SE  $v(s) = v(c_i)$  ENTÃO
20.        $r_i \leftarrow r_i + 1$ ;
21.       SE  $r_i = r_{max}$  ENTÃO
22.          $r_i \leftarrow 0$ ;  $c_i \leftarrow N(c_i)$ ;
23.       FIM-SE
24.     SENÃO
25.        $r_i \leftarrow 0$ ;
26.     FIM-SE
27.   FIM-SE
28.    $s^* \leftarrow \max(s^*, c_i)$ ;
29. FIM-ENQUANTO
30. Retornar  $s^*$ ;

```

Figura 6 - Pseudocódigo da CS implementada.

3.4 EVOLUTIONARY CLUSTERING SEARCH (ECS)

A *Evolutionary Clustering Search* (ECS) é uma meta-heurística proposta por Oliveira (2004). Tomando como base essa meta-heurística, o autor apresentou algumas modificações, com o intuito de generalizar sua utilização. Dessa forma, houve o surgimento da *Clustering Search* (CS), que foi descrita na Seção 3.2.

A tradução do termo ECS tem como significado *Busca Evolutiva por Agrupamentos*, sendo que, nesse caso, utiliza-se um algoritmo evolutivo na geração de soluções. Esse algoritmo evolutivo é o que difere a ECS da CS. Como foi apresentado anteriormente, a CS pode variar o componente gerador de soluções, como por exemplo, foi utilizado neste trabalho o algoritmo *Simulated Annealing*. Já no caso da ECS, o algoritmo gerador de soluções é sempre um algoritmo evolutivo. Neste trabalho, foi utilizado um dos principais algoritmos evolutivos conhecidos, o Algoritmo Genético.

O conceito de Algoritmo Genético (AG) foi iniciado por Holland (1975) e é fundamentado em uma analogia a processos naturais de evolução. O AG considera que indivíduos com melhores características genéticas possuem maiores chances de sobreviver e gerar filhos cada vez mais aptos. Já indivíduos com características genéticas inferiores, tendem a desaparecer.

A ECS trabalha da seguinte forma, inicialmente é gerada uma população inicial P com pop indivíduos (soluções). A partir da população gerada são selecionados dois pais (duas soluções). O primeiro pai, p_1 , é selecionado do conjunto formado por um percentual π de melhores indivíduos da população e o segundo pai, p_2 , é selecionado da população total. No passo seguinte, os dois pais são combinados (*crossover*) e geram um filho f . Com uma probabilidade igual a mut , o filho gerado pode sofrer uma mutação, ou seja, uma alteração no seu DNA, que nesse caso significa aplicar um movimento de troca na solução. Por fim, o filho f é adicionado em uma nova população nP . Esse processo se repete até que φ filhos sejam gerados.

Quando a população nP alcança o número máximo de indivíduos φ , é feita uma avaliação e os melhores indivíduos (soluções) são passados como parâmetros para o processo de agrupamento da ECS. Finalizando uma iteração do método, todos os

indivíduos da nova população nP são adicionados na população P , e é feita então uma avaliação na qual apenas os pop melhores indivíduos sobrevivem, ou seja, permanecem na população P . A quantidade de iterações do método é definida pelo parâmetro AG_{max} .

3.5 PRINCIPAIS COMPONENTES DA ECS

3.5.1 Seleção

Para escolha dos pais p_1 e p_2 , foi utilizado um critério de seleção chamado “Elite”. Esse critério é caracterizado pelo fato de que o primeiro pai p_1 deve estar entre um percentual π dos melhores indivíduos da população, e o segundo pai p_2 deve ser um indivíduo qualquer, desde que esteja na população P . Esse critério também define que a população sobrevivente é dada pela união da população P e da população nP . A partir da união, é feita uma classificação e apenas os pop melhores indivíduos continuam em P , e os outros são descartados.

3.5.2 Cruzamento

Um dos principais e mais importante componente da ECS é o cruzamento (*crossover*). O *crossover* é caracterizado por combinar os dois pais, p_1 e p_2 e gerar um novo filho f . Na Figura 7, é exemplificado o processo de geração do filho f , no qual são utilizadas as partes destacadas em cinza dos pais p_1 e p_2 .




Figura 7 - Crossover.

3.5.3 Mutaç o

A muta o   um componente da ECS que tem por objetivo manter a variedade gen tica da popula o. O par metro que a controla   representado por *mut*, e a mesma   executada da seguinte forma: ap s um filho *f* ser concebido e selecionado para passar pelo processo de muta o, uma posi o do vetor de posi es candidatas de *f*   selecionada aleatoriamente e, tamb m aleatoriamente, o seu valor   trocado para um valor diferente. A Figura 8 ilustra o processo, sendo uma posi o escolhida aleatoriamente e seu valor (posi o candidata) alterado de 1 para 3.




Figura 8 - Muta o.

Os demais componentes da ECS s o similares aos utilizados na CS, ou seja, aqueles descritos na Se o 3.3. A Figura 9 apresenta um pseudoc digo do algoritmo ECS implementado neste trabalho.

```

1. ECS ( $AG_{max}$ ,  $pop$ ,  $mut$ )
2.  $P \leftarrow$  Uma popula o inicial com  $pop$  indiv duos;
3.  $nP \leftarrow \emptyset$ ;  $g \leftarrow 0$ ;  $t \leftarrow 0$ ;
4. ENQUANTO ( $g < AG_{max}$ ) FA A
5.    $g \leftarrow g + 1$ ;
6.   ENQUANTO ( $t < \varphi$ ) FA A
7.      $t \leftarrow t + 1$ ;
8.      $p_1 \leftarrow$  um indiv duo dentre os  $n$  melhores de  $P$ ;
9.      $p_2 \leftarrow$  um indiv duo qualquer de  $P$ ;
10.     $f \leftarrow$  CROSSOVER ( $p_1, p_2$ );
11.    COM probabilidade  $mut = f \leftarrow$  MUTA O ( $f$ );
12.     $nP \leftarrow nP \cup f$ ;
13.  FIM-ENQUANTO;
14.   $nP \leftarrow$  apenas os melhores indiv duos de  $nP$ ;
15.  CLUSTERING-SEARCH ( $nP$ );
16.   $P \leftarrow P \cup nP$ ;
17.   $P \leftarrow$  apenas os  $pop$  melhores indiv duos de  $P$ ;
18.   $nP \leftarrow \emptyset$ ;
19. FIM-ENQUANTO;
20.  $I^* \leftarrow$  melhor indiv duo de  $P$ ;
21. RETORNA ( $I^*$ );

```

Figura 9 - Pseudoc digo da ECS implementada.

3.6 TESTES COMPUTACIONAIS

Para verificar o desempenho dos métodos propostos, foram utilizados dois conjuntos de instâncias (*benchmarks*) que são considerados nos principais e mais recentes trabalhos sobre o problema. Essas instâncias podem ser obtidas pelos endereços <http://www.lac.inpe.br/~lorena/instancias.html> e <http://mistic.heig-vd.ch/taillard/problemes.dir/problemes.html>.

O primeiro conjunto é formado por instâncias com 25, 100, 250, 500, 750 e 1000 pontos, todas com 4 posições candidatas, sendo 8 instâncias distintas com 25 pontos e 25 instâncias diferentes com 100, 250, 500 750 e 100 pontos. Já o segundo conjunto é formado por 40 instâncias com 13206 pontos, sendo 20 com 4 posições candidatas e outras 20 com 8 posições candidatas. Assim, foi utilizado um total de 173 instâncias distintas e de tamanhos variados.

Para cada instância do problema, os métodos foram executados 10 vezes, sendo que para cada uma das execuções foram analisados os seguintes dados:

- *Quantidade de Rótulos Livres*: representa o número total de pontos sem sobreposições de rótulos.
- *Percentual de Rótulos Livres*: é calculado de acordo com a seguinte fórmula

$$\%RL = (RL * 100) / N$$

RL indica o número de rótulos livres e *N* a quantidade total de pontos da instância, ou seja, seu tamanho.

- *Desvio Médio*: é dado pela fórmula

$$D = (((ML - ME) / ML) * 100)$$

ML representa o valor da melhor solução encontrada nas 10 execuções do método para cada instância; *ME* é o valor médio da solução nas 10 execuções.

- *Tempo*: é o tempo total gasto para a execução dos métodos para resolução de uma instância do problema.

4 RESULTADOS

Os resultados apresentados neste capítulo foram obtidos por meio da execução das duas meta-heurísticas implementadas: a *Clustering Search* (CS) e a *Evolutionary Clustering Search* (ECS). Para comparação, são apresentados os resultados de duas execuções da meta-heurística CS e uma execução da ECS. Os resultados obtidos pela primeira execução da CS resultaram em um artigo científico, publicado em Rabello et al. (2013). A segunda execução desse método, a partir deste ponto referenciada por CS*, é motivada por uma melhora no seu tempo de execução. Essa melhora está relacionada à otimização de código, na qual não são mais utilizadas variáveis dinâmicas, ou seja, toda a alocação de memória é feita de forma estática. Com essa nova abordagem, foi possível uma nova calibração dos parâmetros do método, fornecendo assim novos resultados.

Para calibração dos parâmetros da ECS, CS e CS* foram selecionadas, aleatoriamente, uma instância de cada tamanho (no caso de 13206 pontos, foram consideradas duas instâncias: com 4 e 8 posições candidatas), resultando em um subconjunto com 8 instâncias. A partir desse subconjunto, foram realizados vários experimentos variando o valor dos parâmetros. O ajuste dos parâmetros foi realizado da seguinte maneira: cada parâmetro recebeu vários valores enquanto os demais foram mantidos fixos. Os valores utilizados inicialmente para os parâmetros foram aqueles considerados durante o processo de implementação dos métodos. Os métodos então foram executados cinco vezes para cada configuração e cada instância e, aquele valor que resultou no melhor resultado médio foi então escolhido. Uma vez definido o valor ideal do parâmetro em fase de ajuste, outro parâmetro foi então avaliado seguindo a mesma metodologia, até que todos fossem fixados. Essa metodologia é similar à utilizada por Ribeiro et al. (2012). Os parâmetros escolhidos para a execução da ECS, CS e CS* são apresentados na Tabela 1, sendo que os parâmetros γ , λ e r_{max} são comuns aos três métodos. Já os parâmetros pop , mut , φ , π e AG_{max} são específicos da ECS e os parâmetros T_0 , T_C , α e SA_{max} são específicos da CS e CS*.

Tabela 1 - Parâmetros finais das meta-heurísticas ECS, CS e CS*.

Parâmetro	Descrição	ECS	CS	CS*
γ	Número máximo de <i>clusters</i>	10	10	10
λ	Volume máximo para aplicação da busca local	7	7	7
r_{max}	Limite para aplicação da perturbação	4	4	4
T_0	Temperatura inicial para o SA	-	40000	200000
T_C	Temperatura de congelamento para o SA	-	0,01	0,01
α	Taxa de resfriamento para o SA	-	0,975	0,975
SA_{max}	Número máximo de iterações para o SA	-	12000	12000
pop	Tamanho da população para o AG	100	-	-
mut	Taxa de mutação para o AG	20%	-	-
φ	Número de filhos da nova população para o AG	100	-	-
π	Percentual de melhores indivíduos para o AG	20%	-	-
AG_{max}	Número máximo de gerações do AG	45	-	-

Ainda durante a calibração dos parâmetros, notou-se que a melhor solução estava sendo encontrada ao final da execução dos métodos, ou seja, os métodos apresentavam indícios de que poderiam melhorar ainda mais as soluções. Logo, foi utilizada uma técnica que consiste em continuar a execução dos métodos até que a diferença do tempo atual com o tempo em que a última melhor solução foi encontrada ultrapasse 3 minutos e, caso o tempo seja maior, o processo é interrompido. Essa técnica para a CS e a CS* pode ser considerada um *re-annealing*, que consiste em “reaquecer” o SA (gerador de soluções para a CS), ou seja, o valor da temperatura corrente é “reaquecido” para o valor da temperatura inicial, e todo o processo é recomeçado, porém, a partir da melhor solução obtida até então. Já no caso da ECS, o processo é similar, porém, a diferença é que o parâmetro alterado é o AG_{max} , que retorna para seu valor inicial.

Após a calibração dos parâmetros, a CS e a CS* foram aplicadas dez vezes para cada instância. Para todas as instâncias com 25, 100, 250, 500 e 750 pontos, tanto a CS quanto a CS* encontraram as soluções ótimas (provadas por Mauri et al., 2010) em todas as 10 execuções (desvio = 0%). O tempo médio de processamento da CS para cada instância foi de 15,73, 0,00, 3,44, 15,61 e 27,98 segundos, respectivamente, e da CS* foi de 26,18, 0,00, 4,37, 22,41 e 41,96 segundos.

Na execução da ECS para as instâncias com 25, 100, 250 e 500 pontos, o método encontrou as soluções ótimas nas 10 iterações (com desvio = 0%) e o tempo médio de processamento foi de 0,11, 0,00, 0,04 e 0,13 segundos, respectivamente. Porém, considerando as instâncias com 750 pontos, o método não conseguiu alcançar o

ótimo como a CS e a CS*. Para essas instâncias, o desvio médio entre as 10 execuções foi de 0,12%, e o tempo médio de execução foi de 72,80 segundos. Os resultados da ECS, CS e CS* para as instâncias com 750 pontos são apresentados na Tabela 2. Essa tabela ainda contém, para cada instância, o número de rótulos livres para a melhor solução (RL), o percentual de rótulos livres (%RL) para a melhor solução, o número médio de rótulos livres entre as 10 execuções (%RL), o desvio e o tempo de execução.

Para as instâncias com 1000 pontos, a ECS, a CS e a CS* apresentaram tempo de processamento de 140,73, 94,18 e 136,61 segundos, e desvio de 0,49%, 0,02% e 0,02% em todas as 10 execuções, respectivamente. A principal diferença entre as execuções das três meta-heurísticas para essas instâncias está no %RL, para o qual a CS, assim como a CS*, superaram os melhores resultados da literatura. Todavia, a ECS obteve um percentual de rótulos livres inferior aos dois primeiros métodos. A Tabela 3 apresenta os resultados individuais para a ECS, CS e CS*, nessa ordem.

Para as instâncias com 1000 pontos, as melhores soluções encontradas na literatura, até então, eram aquelas obtidas pela heurística de *Backtracking* proposta por Oliveira et al. (2010), que por sua vez só apresentam a média do percentual de rótulos livres (%RL), ou seja, os autores não apresentam as soluções individuais para cada instância. Agora, as melhores soluções para essas instâncias são aquelas obtidas pela CS e CS* propostas neste trabalho.

A Tabela 4 apresenta uma comparação com a literatura dos resultados obtidos pela ECS, CS e CS* (destacados em cinza) para as instâncias com 250, 500, 750 e 1000 pontos. Os resultados apresentados nessa tabela foram obtidos através das médias dos percentuais de rótulos livres (%RL) para cada “tamanho” de instância. Os melhores resultados são destacados em negrito. A partir de uma análise dessa tabela, pode-se perceber que, para as instâncias com 250, 500 e 750 pontos, os resultados obtidos pela CS e pela CS* foram idênticos aos melhores resultados apresentados na literatura (soluções ótimas - já comprovadas). Já para as instâncias com 1000 pontos, a CS e a CS* apresentaram uma melhora de 0,01% de rótulos livres em relação ao melhor resultado da literatura. Já os resultados da ECS só se igualam aos da literatura para as instâncias com 250 e 500 pontos e, para 750 e 1000 pontos, a ECS apresenta uma queda no percentual de rótulos livres.

Tabela 2 - Resultados obtidos para as instâncias com 750 pontos.

Inst.	ECS					CS					CS*				
	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)
	RL	%RL	Rot. Livres			RL	%RL	Rot. Livres			RL	%RL	Rot. Livres		
1	739	98,53	738,50	0,07	84,36	739	98,53	739,00	0,00	28,98	739	98,53	739,00	0,00	40,75
2	736	98,13	734,00	0,27	88,48	736	98,13	736,00	0,00	27,45	736	98,13	736,00	0,00	42,95
3	731	97,47	730,50	0,07	73,75	731	97,47	731,00	0,00	26,00	731	97,47	731,00	0,00	39,81
4	741	98,80	738,90	0,28	74,02	741	98,80	741,00	0,00	27,26	741	98,80	741,00	0,00	41,04
5	739	98,53	738,80	0,03	62,09	739	98,53	739,00	0,00	25,26	739	98,53	739,00	0,00	39,54
6	730	97,33	728,80	0,16	100,23	730	97,33	730,00	0,00	27,51	730	97,33	730,00	0,00	42,69
7	737	98,27	736,10	0,12	92,98	737	98,27	737,00	0,00	27,07	737	98,27	737,00	0,00	42,14
8	736	98,13	735,60	0,05	56,35	736	98,13	736,00	0,00	26,20	736	98,13	736,00	0,00	41,34
9	725	96,67	724,20	0,11	85,94	726	96,80	726,00	0,00	26,07	726	96,80	726,00	0,00	46,78
10	743	99,07	742,30	0,10	70,58	743	99,07	743,00	0,00	26,29	743	99,07	743,00	0,00	38,56
11	732	97,60	730,80	0,16	76,59	733	97,73	733,00	0,00	38,52	733	97,73	733,00	0,00	42,61
12	734	97,87	732,50	0,20	94,16	734	97,87	734,00	0,00	25,36	734	97,87	734,00	0,00	40,90
13	743	99,07	742,40	0,08	43,86	743	99,07	743,00	0,00	23,73	743	99,07	743,00	0,00	38,31
14	726	96,80	725,20	0,11	77,90	728	97,07	728,00	0,00	27,29	728	97,07	728,00	0,00	43,74
15	730	97,33	728,50	0,21	78,72	730	97,33	730,00	0,00	38,69	730	97,33	730,00	0,00	47,55
16	727	96,93	726,20	0,11	104,05	729	97,20	729,00	0,00	35,09	729	97,20	729,00	0,00	42,34
17	729	97,20	727,80	0,16	29,06	729	97,20	729,00	0,00	24,74	729	97,20	729,00	0,00	40,19
18	736	98,13	735,70	0,04	84,54	737	98,27	737,00	0,00	25,86	737	98,27	737,00	0,00	41,71
19	740	98,67	738,40	0,22	92,78	740	98,67	740,00	0,00	26,11	740	98,67	740,00	0,00	41,95
20	737	98,27	736,70	0,04	40,32	737	98,27	737,00	0,00	26,34	737	98,27	737,00	0,00	42,76
21	730	97,33	728,40	0,22	69,50	731	97,47	731,00	0,00	28,49	731	97,47	731,00	0,00	45,73
22	744	99,20	744,00	0,00	7,64	744	99,20	744,00	0,00	24,72	744	99,20	744,00	0,00	39,47
23	730	97,33	728,50	0,21	117,19	731	97,47	731,00	0,00	35,00	731	97,47	731,00	0,00	45,48
24	732	97,60	731,70	0,04	81,57	732	97,60	732,00	0,00	26,26	732	97,60	732,00	0,00	41,26
25	732	97,60	732,00	0,00	33,34	732	97,60	732,00	0,00	25,22	732	97,60	732,00	0,00	40,07
Média	734,36	97,91	733,46	0,12	72,80	734,72	97,96	734,72	0,00	27,98	734,72	97,96	734,72	0,00	41,99

Tabela 3 - Resultados obtidos para as instâncias com 1000 pontos.

Inst.	ECS					CS					CS*				
	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)
	RL	%RL	Rot. Livres			RL	%RL	Rot. Livres			RL	%RL	Rot. Livres		
1	898	89,80	892,80	0,58	179,40	939	93,90	939,00	0,00	52,58	939	93,90	939,00	0,00	119,73
2	890	89,00	883,20	0,76	155,46	934	93,40	934,00	0,00	86,44	934	93,40	934,00	0,00	102,30
3	899	89,90	893,30	0,63	100,05	934	93,40	934,00	0,00	127,50	934	93,40	934,00	0,00	150,99
4	890	89,00	885,20	0,54	154,33	934	93,40	934,00	0,00	129,94	934	93,40	934,00	0,00	133,32
5	913	91,30	910,10	0,32	144,15	961	96,10	961,00	0,00	84,39	961	96,10	961,00	0,00	119,86
6	903	90,30	899,40	0,40	133,49	932	93,20	932,00	0,00	86,17	932	93,20	932,00	0,00	110,32
7	891	89,10	887,20	0,43	169,58	929	92,90	928,80	0,02	147,85	929	92,90	928,80	0,02	197,68
8	895	89,50	892,40	0,29	96,63	940	94,00	940,00	0,00	79,76	940	94,00	940,00	0,00	113,80
9	885	88,50	881,80	0,36	104,59	927	92,70	927,00	0,00	94,56	927	92,70	927,00	0,00	113,904
10	903	90,30	899,40	0,40	86,21	944	94,40	944,00	0,00	82,37	944	94,40	944,00	0,00	80,95
11	916	91,60	909,80	0,68	157,12	947	94,70	947,00	0,00	50,35	947	94,70	947,00	0,00	103,00
12	900	90,00	890,30	1,08	119,00	935	93,50	934,90	0,01	141,03	935	93,50	934,90	0,01	188,459
13	914	91,40	909,50	0,49	183,04	955	95,50	954,60	0,04	84,62	955	95,50	954,60	0,04	106,39
14	895	89,50	888,40	0,74	248,06	933	93,30	933,00	0,00	70,40	933	93,30	933,00	0,00	107,05
15	880	88,00	875,30	0,53	154,03	934	93,40	933,40	0,06	79,85	934	93,40	933,40	0,06	189,229
16	880	88,00	877,50	0,28	133,22	932	93,20	931,90	0,01	101,16	932	93,20	931,90	0,01	165,427
17	914	91,40	912,40	0,18	128,20	937	93,70	937,00	0,00	40,75	937	93,70	937,00	0,00	126,31
18	899	89,90	897,60	0,16	153,10	946	94,60	945,10	0,10	120,94	946	94,60	945,10	0,10	197,34
19	913	91,30	907,80	0,57	124,63	950	95,00	949,30	0,07	114,15	950	95,00	949,30	0,07	193,695
20	893	89,30	890,50	0,28	199,10	934	93,40	934,00	0,00	75,79	934	93,40	934,00	0,00	113,47
21	888	88,80	882,10	0,66	108,83	930	93,00	929,50	0,05	119,05	930	93,00	929,50	0,05	150,314
22	918	91,80	911,50	0,71	90,63	952	95,20	951,40	0,06	97,31	952	95,20	951,40	0,06	117,93
23	895	89,50	891,30	0,41	100,02	934	93,40	934,00	0,00	71,31	934	93,40	934,00	0,00	148,08
24	888	88,80	883,20	0,54	147,66	932	93,20	931,60	0,04	123,78	932	93,20	931,60	0,04	147,84
25	908	90,80	905,30	0,30	147,73	945	94,50	944,90	0,01	92,55	945	94,50	944,90	0,01	117,91
Média	898,72	89,87	894,29	0,49	140,73	938,8	93,88	938,62	0,02	94,18	938,8	93,88	938,62	0,02	136,61

Tabela 4 - Comparação dos resultados obtidos (%RL) com a literatura (250, 500, 750 e 1000 pontos).

Métodos de solução	Número de pontos - N			
	250	500	750	1000
<i>Clustering Search</i> (CS*)	100,00	99,68	97,96	93,88
<i>Clustering Search</i> (CS) (RABELLO et al., 2013)	100,00	99,68	97,96	93,88
<i>Backtracking</i> (OLIVEIRA et al., 2010)	100,00	99,68	97,96	93,87
Modelo C2 (RIBEIRO et al., 2009)	100,00**	99,68**	97,96	93,86
Modelo C1 (RIBEIRO et al., 2009)	100,00**	99,68**	97,96	93,84
Cplex com formulação forte (MAURI et al., 2010)	100,00**	99,68**	97,96	93,84
Decomposição Lagrangiana (MAURI et al., 2010)	100,00**	99,68**	97,96**	93,74
ILS (OLIVEIRA et al., 2009)	100,00	99,68	97,95	93,76
Cplex com formulação simples (MAURI et al., 2010)	100,00**	99,68**	97,91	90,13
<i>Evolutionary Clustering Search</i> (ECS)	100,00	99,68	97,91	89,87
Pop(asc) (ALVIN; TAILLARD, 2009)	100,00	99,67	97,72	92,68
Pop(10) (ALVIN; TAILLARD, 2009)	100,00	99,67	97,46	91,94
Pop(30) (ALVIN; TAILLARD, 2009)	100,00	99,67	97,72	92,54
Pop(70) (ALVIN; TAILLARD, 2009)	100,00	99,67	97,73	92,58
Pop(asc) (ALVIN; TAILLARD, 2009)	100,00	99,67	97,72	92,68
Tabu(50n) (ALVIN; TAILLARD, 2009)	100,00	99,57	97,53	91,54
Tabu(100n) (ALVIN; TAILLARD, 2009)	100,00	99,57	97,54	91,54
Tabu(500n) (ALVIN; TAILLARD, 2009)	100,00	99,57	97,55	91,59
Geração de Colunas (RIBEIRO; LORENA, 2008b)	100,00**	99,67	97,67	92,40
LagClus (RIBEIRO; LORENA, 2008a)	100,00**	99,67	97,65	91,42
GRASP(6) (CRAVO et al., 2008)	100,00	99,67	97,72	92,20
GRASP(5) (CRAVO et al., 2008)	100,00	99,67	97,70	92,02
Algoritmo Genético Construtivo (YAMAMOTO; LORENA, 2005)	100,00	99,60	97,10	90,70
Busca Tabu (YAMAMOTO et al., 2002)	100,00	99,26	96,76	90,00
Algoritmo Genético com Máscaras (VERNER et al., 1997)	99,98	98,79	95,99	88,96
Algoritmo Genético (VERNER et al., 1997)	98,40	92,59	82,38	65,70
<i>Simulated Annealing</i> (CHRISTENSEN et al., 1995)	99,90	98,30	92,30	82,09
<i>3-opt Gradient Descent</i> (CHRISTENSEN et al., 1995)	99,76	97,34	89,44	77,83
<i>2-opt Gradient Descent</i> (CHRISTENSEN et al., 1995)	99,36	95,62	85,60	73,37
<i>Gradient Descent</i> (CHRISTENSEN et al., 1995)	95,47	86,46	72,40	58,29
<i>Greedy Algorithm</i> (CHRISTENSEN et al., 1995)	88,82	75,15	58,57	43,41

Soluções obtidas por métodos que **comprovaram a otimalidade para todas as instâncias.

Na Tabela 5 são apresentados os resultados para as instâncias com 13206 pontos e 4 posições candidatas. O desvio médio entre as 10 execuções para cada instância foi de 0,38%, 0,13% e 0,12%, e o tempo médio de execução foi de 407,25, 1287,61 e 1653,12 segundos, para a ECS, CS e CS* respectivamente. Para essas instâncias, as melhores soluções encontradas na literatura eram aquelas obtidas pelo POPMUSIC ou Busca Tabu (ALVIN; TAILLARD, 2009) ou pelo ILS (OLIVEIRA et al., 2009). Uma comparação entre o percentual de rótulos livres (%RL) das melhores soluções obtidas pela ECS, CS e CS* com as melhores soluções apresentadas por esses métodos pode ser observada na Tabela 6. Os melhores resultados são destacados em negrito.

Tabela 5 - Resultados obtidos para as instâncias com 13206 pontos considerando 4 posições candidatas.

Inst.	ECS					CS					CS*				
	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)
	RL	%RL	Rot. Livres			RL	%RL	Rot. Livres			RL	%RL	Rot. Livres		
1	10434	79,01	10420,60	0,13	272,30	12478	94,49	12468,50	0,08	749,28	12488	94,56	12482,20	0,05	1156,59
2	9597	72,67	9573,70	0,24	323,00	12102	91,64	12096,50	0,05	837,60	12126	91,82	12113,20	0,11	1274,12
3	9168	69,42	9144,90	0,25	225,58	11884	89,99	11878,90	0,04	968,36	11910	90,19	11899,80	0,09	1098,64
4	8706	65,92	8682,10	0,27	565,85	11702	88,61	11692,60	0,08	1168,21	11717	88,72	11708,70	0,07	1719,76
5	9028	68,36	8982,60	0,50	306,33	11754	89,00	11742,10	0,10	787,37	11773	89,15	11759,70	0,11	920,29
6	7503	56,82	7471,70	0,42	436,92	10885	82,42	10872,00	0,12	956,02	10916	82,66	10902,40	0,12	1409,21
7	6852	51,89	6817,20	0,51	526,39	10491	79,44	10480,60	0,10	1234,69	10531	79,74	10512,80	0,17	1799,62
8	7378	55,87	7358,80	0,26	369,24	10816	81,90	10801,40	0,13	955,20	10840	82,08	10830,40	0,09	1349,16
9	7231	54,76	7216,90	0,19	459,98	10806	81,83	10794,80	0,10	1404,79	10838	82,07	10826,60	0,11	1643,33
10	6810	51,57	6758,30	0,76	496,90	10397	78,73	10383,00	0,13	1787,64	10425	78,94	10415,70	0,09	1810,34
11	6241	47,26	6210,50	0,49	426,97	10062	76,19	10052,90	0,09	1692,21	10101	76,49	10090,40	0,10	2129,93
12	6106	46,24	6074,40	0,52	426,48	9955	75,38	9930,10	0,25	1383,71	9980	75,57	9973,20	0,07	1726,97
13	7507	56,85	7492,50	0,19	251,88	10787	81,68	10774,10	0,12	1070,82	10831	82,02	10813,60	0,16	1303,93
14	6370	48,24	6348,40	0,34	365,23	10120	76,63	10103,70	0,16	1918,69	10162	76,95	10145,70	0,16	2459,27
15	5878	44,51	5863,80	0,24	484,13	9695	73,41	9681,90	0,14	1511,97	9739	73,75	9727,10	0,12	1432,11
16	5328	40,35	5301,80	0,49	340,60	9303	70,45	9284,70	0,20	1784,93	9349	70,79	9329,50	0,21	1577,36
17	6758	51,17	6733,60	0,36	431,79	10251	77,62	10234,40	0,16	1017,34	10289	77,91	10277,50	0,11	2145,45
18	5690	43,09	5664,50	0,45	560,73	9507	71,99	9494,00	0,14	1239,70	9548	72,30	9534,70	0,14	1453,63
19	5196	39,35	5163,30	0,63	380,27	9074	68,71	9045,10	0,32	1301,86	9111	68,99	9101,00	0,11	2369,75
20	4626	35,03	4609,20	0,36	494,45	8595	65,08	8583,90	0,13	1984,39	8651	65,51	8638,00	0,15	2283,08
Média	7120,35	53,92	7094,44	0,38	407,25	10533,2	79,76	10519,76	0,13	1287,74	10566,25	80,01	10554,11	0,12	1653,13

Tabela 6 - Comparação dos resultados obtidos (%RL) com a literatura (13206 pontos - 4 posições candidatas).

Inst.	Alvin e Taillard (2009)			Oliveira et al. (2009)	Métodos Propostos		
	Tabu(50n)	Pop(asc)	Pop(10)		ECS	CS	CS*
1	92,20	93,10	92,55	94,65	79,01	94,49	94,56
2	88,29	89,18	88,73	91,05	72,67	91,64	91,82
3	86,12	87,12	86,69	88,91	69,42	89,99	90,19
4	83,80	84,87	84,42	86,43	65,92	88,61	88,72
5	84,25	85,26	84,73	88,47	68,36	89,00	89,15
6	74,31	75,92	75,49	79,89	56,82	82,42	82,66
7	69,23	71,76	71,16	76,34	51,89	79,44	79,74
8	73,21	75,15	74,94	79,68	55,87	81,90	82,08
9	73,00	74,81	74,28	79,47	54,76	81,83	82,07
10	67,47	70,33	69,96	75,97	51,57	78,73	78,94
11	63,56	67,11	66,66	72,85	47,26	76,19	76,49
12	62,01	65,62	65,10	72,17	46,24	75,38	75,57
13	73,19	74,54	74,15	79,48	56,85	81,68	82,02
14	64,44	67,34	67,12	73,51	48,24	76,63	76,95
15	61,95	63,03	62,86	70,22	44,51	73,41	73,75
16	58,23	59,21	58,87	66,27	40,35	70,45	70,79
17	67,07	68,82	68,17	74,75	51,17	77,62	77,91
18	60,02	60,87	60,44	68,22	43,09	71,99	72,30
19	56,10	56,75	56,55	64,32	39,35	68,71	68,99
20	51,89	52,23	51,98	60,66	35,03	65,08	65,51
Média	70,52	72,15	71,74	77,17	53,92	79,76	80,01

Como pode ser observado na Tabela 6, a CS encontrou 19 soluções melhores que as apresentadas por Oliveira et al. (2009), ou seja, para apenas uma instância a CS não apresentou a melhor solução. Já em relação aos métodos propostos por Alvim e Taillard (2009), todas as soluções apresentadas pela CS e pela CS* foram melhores. De uma forma geral, pode-se notar que, em relação às melhores soluções conhecidas até então, a CS apresentou um aumento médio (por instância) de aproximadamente 344 pontos rotulados sem sobreposição. De acordo com os resultados da CS*, é possível perceber que houve uma melhora em relação à CS de 33 pontos (a mais) rotulados sem sobreposição, resultando então em 377 pontos “livres”.

A Tabela 7 apresenta os resultados para as instâncias com 13206 pontos considerando 8 posições candidatas. O desvio médio entre as 10 execuções para cada instância foi de 0,40%, 0,15% e 0,14%, e o tempo médio de execução foi de 454,54, 1754,60 e 2338,98 segundos, valores para a ECS, CS e CS*, respectivamente.

Tabela 7 - Resultados obtidos para as instâncias com 13206 pontos considerando 8 posições candidatas.

Inst.	ECS					CS					CS*				
	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)	Melhor Solução		Solução Média	Desvio (%)	Tempo (s)
	RL	%RL	Rot. Livres			RL	%RL	Rot. Livres			RL	%RL	Rot. Livres		
1	10499	79,50	10472,10	0,26	419,08	12911	97,77	12899,20	0,09	689,21	12926	97,88	12920,80	0,04	1091,54
2	9307	70,48	9280,40	0,29	418,37	12455	94,31	12445,80	0,07	1426,86	12486	94,55	12479,70	0,05	1617,39
3	9161	69,37	9118,20	0,47	339,93	12496	94,62	12481,20	0,12	1079,20	12529	94,87	12520,00	0,07	1587,93
4	8707	65,93	8671,60	0,41	596,30	12339	93,43	12327,30	0,09	1564,40	12372	93,68	12365,70	0,05	1342,23
5	9032	68,39	9003,30	0,32	340,82	12451	94,28	12435,30	0,13	995,25	12499	94,65	12486,40	0,10	1203,56
6	7524	56,97	7468,40	0,74	460,76	11688	88,51	11659,90	0,24	1535,81	11751	88,98	11734,20	0,14	1797,14
7	6835	51,76	6809,60	0,37	389,35	11328	85,78	11315,00	0,11	1430,55	11411	86,41	11394,20	0,15	2550,02
8	7340	55,58	7325,60	0,20	408,95	11641	88,15	11625,90	0,13	1784,80	11707	88,65	11689,90	0,15	1970,06
9	6889	52,17	6871,00	0,26	411,80	11313	85,67	11298,40	0,13	1860,62	11395	86,29	11375,30	0,17	2184,47
10	6754	51,14	6734,30	0,29	406,13	11257	85,24	11234,10	0,20	1587,48	11321	85,73	11309,70	0,10	2587,12
11	6249	47,32	6203,40	0,73	616,56	10944	82,87	10925,70	0,17	1915,37	11038	83,58	11024,80	0,12	2520,31
12	5982	45,30	5968,30	0,23	413,17	10708	81,08	10692,80	0,14	1946,41	10806	81,83	10794,00	0,11	2961,24
13	7547	57,15	7531,00	0,21	366,16	11686	88,49	11663,80	0,19	1852,03	11748	88,96	11737,40	0,09	2554,71
14	6012	45,52	5987,10	0,41	615,75	10663	80,74	10645,40	0,17	2428,07	10766	81,52	10738,60	0,25	2870,68
15	5829	44,14	5783,10	0,79	640,39	10552	79,90	10541,00	0,10	1871,71	10673	80,82	10640,30	0,31	2600,74
16	5263	39,85	5249,50	0,26	328,03	10226	77,43	10210,60	0,15	2147,30	10338	78,28	10318,90	0,18	3225,31
17	6775	51,30	6756,30	0,28	346,41	11246	85,16	11214,50	0,28	2199,06	11312	85,66	11295,00	0,15	2391,61
18	5317	40,26	5286,90	0,57	434,25	10082	76,34	10059,10	0,23	2032,38	10189	77,15	10175,40	0,13	2941,42
19	5105	38,66	5086,20	0,37	555,05	10024	75,90	10008,70	0,15	2146,21	10149	76,85	10122,00	0,27	2915,38
20	4554	34,48	4529,60	0,54	583,52	9572	72,48	9556,90	0,16	2599,21	9696	73,42	9685,20	0,11	3866,84
Média	7034,05	53,26	7006,80	0,40	454,54	11279,10	85,41	11262,03	0,15	1754,60	11355,6	85,99	11340,38	0,14	2338,98

Para as instâncias com 13206 pontos considerando 8 posições candidatas, as melhores soluções encontradas na literatura eram aquelas obtidas pelo POPMUSIC ou Busca Tabu (ALVIN; TAILLARD, 2009). Uma comparação entre o percentual de rótulos livres (%RL) das melhores soluções obtidas pelas meta-heurísticas utilizadas neste trabalho com as melhores soluções apresentadas por esses métodos pode ser vista na Tabela 8. A CS apresentou melhores soluções para todas as instâncias. Em relação às melhores soluções conhecidas até então, o aumento médio de pontos rotulados sem sobreposição (por instância) foi de aproximadamente 474 pontos. Por fim, a CS* obteve resultados superiores à CS. Essa diferença contabilizou um aumento de cerca de 76 rótulos livres de sobreposição. Oliveira et al. (2009) não apresentam resultados para essas instâncias.

Tabela 8 - Comparação dos resultados obtidos (%RL) com a literatura (13206 pontos - 8 posições candidatas).

Inst.	Alvin e Taillard (2009)			Métodos Propostos		
	Tabu(50n)	Pop(asc)	Pop(10)	ECS	CS	CS*
1	97,13	97,61	97,22	79,50	97,77	97,88
2	92,54	93,43	92,70	70,48	94,31	94,55
3	92,87	94,09	93,06	69,37	94,62	94,87
4	91,4	92,38	91,54	65,93	93,43	93,68
5	92,44	93,47	92,51	68,39	94,28	94,65
6	84,56	85,85	84,96	56,97	88,51	88,98
7	80,54	82,23	81,35	51,76	85,78	86,41
8	83,95	85,39	84,26	55,58	88,15	88,65
9	80,57	81,84	81,07	52,17	85,67	86,29
10	79,84	81,29	80,61	51,14	85,24	85,73
11	76,58	78,45	77,46	47,32	82,87	83,58
12	74,36	76,00	75,17	45,30	81,08	81,83
13	84,55	85,70	84,48	57,15	88,49	88,96
14	73,63	75,09	74,58	45,52	80,74	81,52
15	72,57	74,20	73,29	44,14	79,90	80,82
16	68,35	70,82	70,04	39,85	77,43	78,28
17	79,22	80,70	79,52	51,30	85,16	85,66
18	66,96	69,07	68,13	40,26	76,34	77,15
19	65,53	68,89	67,86	38,66	75,90	76,85
20	58,98	64,52	63,66	34,48	72,48	73,42
Média	79,83	81,55	80,67	53,26	85,41	85,99

A ECS, CS e CS* foram implementadas em C++ e todos os experimentos foram realizados em um PC com processador Intel Core i5 de 2.66GHz com 4GB de memória RAM.

Os resultados apresentados por Oliveira et al. (2009,2010) foram obtidos em um PC com processador Intel Pentium IV de 3.0GHz com 1GB de memória RAM, com um tempo limite de execução de 120 segundos por instância. Os autores não apresentam o desvio médio obtido nas soluções, e consideram soluções iniciais já “otimizadas” por uma heurística construtiva, cujo tempo de execução não é apresentado.

Já os resultados apresentados por Alvin e Taillard (2009) foram obtidos em um PC com processador Intel Xeon de 3.2GHz com 6GB de memória RAM. Os métodos Tabu(50n), Pop(asc) e Pop(10) apresentaram, respectivamente, um tempo médio de 1466,21, 437,74 e 7,63 segundos para as instâncias de 13206 pontos com 4 posições candidatas, e 1655,90, 838,39 e 21,14 segundos as instâncias de 13206 pontos com 8 posições candidatas.

5 CONCLUSÕES

Pode-se observar neste trabalho que a aplicação da meta-heurística híbrida *Clustering Search* (CS e CS*) para resolução do Problema de Rotulação Cartográfica de Pontos (PRCP) foi eficiente, apresentando soluções idênticas às obtidas pelos melhores métodos encontrados na literatura (todas as soluções ótimas, em todos os experimentos) para as instâncias com 25, 100, 250, 500 e 750 pontos. Já para as instâncias com 1000 e 13206 pontos, os resultados obtidos pela CS e CS* foram superiores. Vale ressaltar, que a CS* superou os resultados apresentados pela CS proposta por Rabello et al. (2013) para as instâncias com 13206 pontos.

Também foi possível concluir com este trabalho que a aplicação da ECS para instâncias acima de 750 pontos não apresentou resultados satisfatórios. Todavia, a aplicação da ECS às instâncias com 25, 100, 250, e 500 pontos, além de apresentar resultados equivalentes aos obtidos pelas meta-heurísticas CS e CS*, utilizou tempos computacionais significativamente inferiores.

Com a aplicação da CS e CS*, foi possível encontrar uma melhora significativa nas soluções para as instâncias com 1000 e 13206 pontos. Isto é, com a aplicação desses métodos, pode-se obter um maior número de rótulos sem sobreposições (rótulos livres), o que resulta em um mapa com uma visualização mais clara dos pontos e seus respectivos rótulos.

Assim, a aplicação da *Clustering Search* demonstrou ser uma nova alternativa para resolução do PRCP, apresentando um bom desempenho quando comparada a métodos propostos nos principais e/ou recentes trabalhos sobre o problema.

REFERÊNCIAS BIBLIOGRÁFICAS

ALVIM, A. C. F.; TAILLARD, E. D. Popmusic for the point-feature label placement problem. *European Journal of Operational Research*, v. 192, p. 396-413, 2009.

CHAVES, A. A.; LORENA, L. A. N. Clustering search algorithm for the capacitated centered clustering problem. *Computers & Operations Research*, v. 37, p. 552-558, 2010.

CHRISTENSEN, J.; MARKS, J.; SHIEBER, S. An empirical study of algorithms for point-feature label placement. *ACM Transactions on Graphics*, v. 14, p. 203-232, 1995.

CRAVO, G. L.; RIBEIRO, G. M.; LORENA, L. A. N. A greedy randomized adaptive search procedure for the point-feature cartographic label placement. *Computers & GeoSciences*, v. 34, p. 373-386, 2008.

HAMMING, R. W. Error detecting and error correcting codes. *Bell System Technical Journal*, v. 26, p. 147-160, 1950.

HOLLAND, J. H. *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. Oxford, England: Michigan Press, 1975.

LORENA, L. A. N.; FURTADO, J. C. Constructive genetic algorithm for clustering problems. *Evolutionary Computation*, v. 9, p. 309-327, 2001.

MARKS, J.; SHIEBER, S. *The computational complexity of cartographic label placement*. Harvard: Harvard University, 1991. 28 p. (Relatório Técnico). Disponível em: <<http://www.eecs.harvard.edu/~Shieber/papers/label.ps.gz>>. Acesso em: 31 out. 2012.

MAURI, G. R.; RIBEIRO, G. M.; LORENA, L. A. N. A new mathematical model and a lagrangean decomposition for the point-feature cartographic label placement problem. *Computers & Operations Research*, v. 37, p. 2164-2172, 2010.

OLIVEIRA, A. C. M.; LORENA, L. A. N. Detecting promising areas by evolutionary clustering search. In *Advances in Artificial Intelligence SBIA 2004. Lecture Notes in Artificial Intelligence*, v. 3171, p. 385-394, 2004.

OLIVEIRA, A. C. M.; LORENA, L. A. N. Hybrid evolutionary algorithms and clustering search. *Hybrid Evolutionary Algorithms, Studies in Computational Intelligence*, v. 75, p. 77-99, 2007.

OLIVEIRA, C.; URRUTIA, S. A.; NORONHA, T. F. Heurística ILS para o problema da rotulação cartográfica de pontos. In. *Simpósio de Pesquisa Operacional e Logística da Marinha*, 12, 2009, Rio de Janeiro. Anais... SPOLM, 2009.

_____. Heurística de backtracking para o problema da rotulação cartográfica de pontos. In. *Simpósio Brasileiro de Pesquisa Operacional*, 42, 2010, Bento Gonçalves. Anais... SBPO, 2010.

RABELLO, R. L.; MAURI, G. R.; RIBEIRO, G. M.; LORENA, L. A. N. Meta-Heurística clustering search aplicada ao problema de rotulação cartográfica de pontos. In. *Simpósio Brasileiro de Pesquisa Operacional*, 45, 2013, Natal. Anais... SBPO, 2013.

RIBEIRO, G. M.; CONSTANTINO, M. F.; LORENA, L. A. N. Um estudo sobre desigualdades válidas para o problema de maximização de rótulos livres. In. *Simpósio Brasileiro de Pesquisa Operacional*, 41, 2009, Porto Seguro. Anais... SBPO, 2009.

RIBEIRO, G. M.; LAPORTE, G.; MAURI, G. R. A comparison of three metaheuristics for the workover rig routing problem. *European Journal of Operational Research*, v. 220, p. 28-36, 2012.

RIBEIRO, G. M.; LORENA, L. A. N. Column generation approach for the point-feature cartographic label placement problem. *Journal of Combinatorial Optimization*, v. 15, p. 147-164, 2008a.

_____. Lagrangean relaxation with clusters for point-feature cartographic label placement problems. *Computers & Operations Research*, v. 35, p. 2129-2140, 2008b.

RIBEIRO, G. M.; MAURI, G. R.; LORENA, L. A. N. A lagrangean decomposition for the maximum independent set problem applied to map labeling. *Operational Research: An International Journal*, v. 11, p. 229-243, 2011.

STRIJK, T.; VERWEIJ, B.; AARDAL, K. *Algorithms for maximum independent set applied to map labeling*. Universiteit Utrecht, 2000. (Relatório Técnico). Disponível em: <<http://www.cs.uu.nl/research/techreps/repo/CS-2000/2000-22.pdf>>. Acesso em: 31 de out. 2012.

TAILLARD, E.; VOSS, S. Popmusic: partial optimization metaheuristic under special intensification conditions. In: RIBEIRO, C.; HANSEN, P. (Ed.). *Essays and surveys in metaheuristics*. Berlin: Springer, 2001.

VERNER, O. V.; WAINWRIGHT, R. L.; SCHOENEFELD, D. A. Placing text labels on maps and diagrams using genetic algorithms with masking. *INFORMS Journal on Computing*, v. 9, p. 266-275, 1997.

WOLFF, A. *Automated label placement in theory and practice*. Tese (Doctoral in Mathematik und Informatik) – Freie Universität Berlin, Berlin, 1999. Disponível em: <<http://i11www.iti.uni-karlsruhe.de/~awolff/pub/w-alptp-99.pdf>>. Acesso em: 31 de out. de 2012.

YAMAMOTO, M. *Uma aplicação da busca tabu ao problema de rotulação cartográfica de pontos*. Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 1998.

YAMAMOTO, M.; CÂMARA, G.; LORENA, L. A. N. Tabu search heuristic for point-feature cartographic label placement. *GeoInformatica*, v. 6, p. 77-90, 2002.

YAMAMOTO, M.; LORENA, L. A. N. A constructive genetic approach to point-feature cartographic label placement. In: IBARAKI, T.; NONOBE, K.; YAGIURA, M. (Ed.). *Metaheuristics: progress as real problem solvers*. Berlin: Springer, 2005.

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE COMPUTAÇÃO**

RÔMULO LOUZADA RABELLO

**APLICAÇÃO DA META-HEURÍSTICA CLUSTERING
SEARCH AO PROBLEMA DE ROTULAÇÃO
CARTOGRÁFICA DE PONTOS**

ALEGRE - ES

2013