



## **UM MÉTODO HÍBRIDO PARA O PROBLEMA PROBABILÍSTICO DE LOCALIZAÇÃO-ALOCAÇÃO DE MÁXIMA COBERTURA**

**Marcos Antonio Pereira**

Universidade Estadual Paulista  
Av. Dr. Ariberto Pereira da Cunha, 333 - 12516-410 - Guaratinguetá - SP  
mapereira@feg.unesp.br

**Leandro Callegari Coelho**

Université Laval  
2325 de la Terrasse - G1K 0A6 - Québec City, Canada  
leandro.coelho@cirreлт.ca

**Luiz Antônio Nogueira Lorena**

**Ligia Corrêa de Souza**

Instituto Nacional de Pesquisas Espaciais  
Av. dos Astronautas, 1758 - 12221-010 - São José dos Campos - SP  
lorena@lac.inpe.br, li.correasouza@gmail.com

### **RESUMO**

Este artigo apresenta um algoritmo híbrido para resolver o Problema Probabilístico de Localização-Alocação de Máxima Cobertura. Explorando a formulação matemática do problema, uma heurística flexível de busca em vizinhança é empregada para obter as soluções de localização, enquanto um método exato fornece a respectiva solução ótima dos subproblemas de alocação. Testes computacionais realizados com dados da literatura permitiram avaliar a eficiência do método proposto. O problema inteiro foi modelado de forma eficiente para ser resolvido de modo exato, o que possibilitou encontrar novas melhores soluções para 19 das instâncias testadas, comprovando a otimalidade para 18 delas. O método híbrido apresentou desempenho consistente, encontrando 94,5% das melhores soluções conhecidas na literatura.

**PALAVRAS CHAVE.** Localização de facilidades, sistemas congestionados, matheurística.

**Área Principal:** MH – Metaheurísticas, OC – Otimização Combinatória, PM – Programação Matemática.

### **ABSTRACT**

This paper presents a hybrid algorithm to solve the Probabilistic Maximal Covering Location-Allocation Problem. A linear programming formulation presents location variables, that are determined by a flexible neighborhood search heuristic, and allocation variables, obtained as optimal solutions of an easier subproblem. Computational experiments on a set of benchmark instances from the literature were conducted to evaluate the efficiency of the proposed method. The integer problem formulation was efficiently implemented to be solved exactly, obtaining 19 new best solutions and proving optimality for 18 of them. The hybrid method performed consistently, finding the best known solutions for 94.5% of the instances.

**KEYWORDS.** Facility location, congested systems, matheuristic.

**Main Area:** MH – Metaheuristics, OC – Combinatorial Optimization, PM – Mathematical Programming.

## 1. Introdução

A localização de facilidades desempenha um papel importante na área de Logística. O número de empresas que buscam métodos quantitativos para estimar a melhor forma de atender a demanda por produtos ou serviços cresce a cada dia. Em alguns casos, a disponibilidade de atendimento está associada à distância ou ao tempo de deslocamento dos clientes até uma facilidade existente. Nestes casos, o decisor deve determinar a melhor configuração para a instalação de facilidades de forma a atender a maior parte da demanda.

O Problema de Localização de Máxima Cobertura (MCLP, na sigla em inglês) foi proposto por Church e ReVelle (1974) e é um problema clássico de localização de facilidades que visa selecionar um determinado número de locais candidatos para a instalação de facilidades de forma a maximizar a demanda total de clientes que estejam dentro do raio de atendimento de uma facilidade instalada. No setor público, este modelo é utilizado, por exemplo, para determinar a localização de serviços de emergência, como estações de ambulância e brigadas de combate a incêndio. No setor privado, busca-se determinar, por exemplo, a localização de caixas bancários de auto-atendimento, postos de gasolina, lojas de redes de *fast-food*, antenas de telefonia celular, etc. Uma lista mais abrangente de aplicações pode ser encontrada em Hale e Moberg (2003), Galvão (2004) e Serra e Marianov (2004). Variações deste problema podem ser encontradas em Pirkul e Schilling (1991) e Berman *et al.* (2009; 2013). As propostas de solução para o MCLP incluem heurísticas gulosas (Church e ReVelle, 1974; Daskin, 1995), relaxações de programação linear (Church e ReVelle, 1974) e lagrangeana (Galvão e ReVelle, 1996), algoritmos genéticos (Arakaki, 2001), heurística lagrangeana/*surrogate* (Lorena e Pereira, 2009) e geração de colunas (Pereira *et al.*, 2007).

Em algumas aplicações, o número de clientes (e sua respectiva demanda) alocados a uma facilidade pode causar algum impacto no comportamento do sistema: dependendo da natureza do serviço, os clientes podem ter que esperar para serem atendidos. Em tais sistemas congestionados, a qualidade do serviço é medida não apenas pela proximidade a uma facilidade, mas também por algum critério de desempenho, como o número de clientes na fila ou o tempo de espera para atendimento. Assumindo que o tempo médio de atendimento seja constante no tempo, pode-se incluir restrições de capacidade das facilidades à formulação matemática do MCLP, mas isso pode incorrer em facilidades ociosas ou sobrecarregadas.

Para tratar de cenários mais realistas, Marianov e Serra (1998) propuseram um modelo que considera que a chegada dos clientes a uma facilidade pode ser modelada como um processo estocástico, com taxa baseada no valor da demanda de cada cliente. Estimando-se o número esperado de clientes na fila ou o tempo máximo de espera para atendimento, os autores definem um limite mínimo para a qualidade do serviço, resultando num modelo que é uma extensão do MCLP, conhecido como Problema Probabilístico de Localização-Alocação de Máxima Cobertura (PMCLAP ou QM-CLAM, na sigla em inglês). Devido à complexidade deste problema e ao tamanho das instâncias reais, a maioria dos métodos de resolução são baseados em heurísticas. Corrêa *et al.* (2008) propõe o emprego da heurística *Clustering Search* para detectar regiões promissoras de busca baseadas em agrupamentos de soluções e Corrêa *et al.* (2009) apresentam um método baseado em grafos de conflito e geração de colunas.

Os modelos de problemas de localização e alocação contém, pelo menos, dois tipos de variáveis de decisão: onde instalar uma facilidade (decisão de localização) e quais clientes atender pela facilidade instalada (decisão de alocação). Os métodos tradicionais de solução, como *branch-and-bound*, determinam as decisões de localização e alocação simultaneamente, alocando clientes a locais candidatos que ainda estão sendo avaliados para a instalação de uma facilidade. Entretanto, uma abordagem hierarquizada parece ser um processo mais natural num método heurístico: primeiramente determina-se a localização das facilidades e só então faz-se a alocação dos clientes às mesmas.

Este artigo apresenta um novo método iterativo híbrido que explora esta característica do problema. As decisões de localização serão tratadas pela metaheurística de busca em vizinhança

*adaptive large neighborhood search* (ALNS) e as decisões de alocação correspondentes serão obtidas como soluções ótimas de um subproblema inteiro. A metaheurística ALNS foi proposta por Ropke e Pisinger (2006a) para a resolução de uma classe de problemas de roteamento de veículos (Ropke e Pisinger, 2006b) e, desde então, tem sido adaptada para tratar outros tipos de problemas, como sequenciamento de veículos (Bartodziej *et al.*, 2009; Pepin *et al.*, 2009), roteamento de veículos com estoques (Coelho *et al.*, 2012a; 2012b) e tabela de horário de trens (Barrena *et al.*, 2013). Até esta data, sabe-se de apenas uma aplicação do ALNS a um problema com um componente de localização (Hemmelmayr *et al.*, 2012), que é significativamente diferente do problema abordado neste artigo.

No restante deste artigo será apresentada a pesquisa desenvolvida. A Seção 2 apresenta a formalização e a formulação matemática do PMCLAP. A metaheurística híbrida ALNS é descrita na Seção 3. Os resultados dos testes computacionais são apresentados na Seção 4 e as conclusões compõem a Seção 5.

## 2. Descrição do Problema e Formulação Matemática

O MCLP visa localizar  $p$  facilidades dentre  $n$  possíveis locais candidatos, de forma a maximizar a demanda atendida para um dado raio de cobertura  $S$ . Entretanto, este problema não considera a capacidade de atendimento das facilidades ou o congestionamento do sistema. Para tratar dessa limitação, Marianov e Serra (1998) introduziram o PMCLAP, uma extensão do MCLP que impõe um limite mínimo na qualidade do atendimento. A medida de qualidade do serviço de uma facilidade é calculada em função do número de clientes na fila ou do tempo de espera para atendimento.

Formalmente, o problema é definido como um grafo completo com um conjunto  $\mathcal{N}$  de  $n$  vértices. A cada vértice  $i \in \mathcal{N}$  está associada uma demanda  $d_i$  e uma distância de serviço ou raio de atendimento  $S_i$ , caso uma facilidade seja instada no vértice  $i$ . Sem perda de generalidade, pode-se considerar um raio de atendimento  $S$  para todas as facilidades. Seja  $\mathcal{N}_i$  o subconjunto dos vértices a até  $S$  unidades de distância do vértice  $i$ , ou seja, o conjunto de locais candidatos  $j$  que podem atender o cliente  $i$ . Para o PMCLAP, o parâmetro  $f_i$  representa o impacto do cliente  $i$  no congestionamento do sistema, sendo calculado como uma fração de  $d_i$ . Assume-se que os clientes chegam às facilidades de acordo com uma distribuição de Poisson com taxa  $\mu$  e o parâmetro  $\alpha$  é a probabilidade mínima de um cliente, ao chegar à facilidade designada, encontrar uma fila com  $b$  clientes ou ter que aguardar  $\tau$  minutos para ser atendido.

Para modelar o PMCLAP, define-se as variáveis de decisão binárias  $y_j$ , que assumem o valor 1 se, e somente se, uma facilidade for instalada no local candidato  $j \in \mathcal{N}$  e  $x_{ij}$ , que assumem o valor 1 se, e somente se, a demanda do cliente  $i \in \mathcal{N}$  for atendida pela facilidade instalada em  $j$ . Dessa forma, o problema pode ser formulado como:

$$\text{maximizar } \sum_{i \in \mathcal{N}} \sum_{j \in \mathcal{N}_i} d_i x_{ij} \quad (1)$$

sujeito a

$$\sum_{j \in \mathcal{N}_i} x_{ij} \leq 1 \quad i \in \mathcal{N} \quad (2)$$

$$\sum_{j \in \mathcal{N}} y_j = p \quad (3)$$

$$x_{ij} \leq y_j \quad i \in \mathcal{N} \quad j \in \mathcal{N} \quad (4)$$

$$\sum_{i \in \mathcal{N}} f_i x_{ij} \leq \mu \sqrt{b+2} \sqrt{1-\alpha} \quad j \in \mathcal{N} \quad (5)$$

ou

$$\sum_{i \in \mathcal{N}} f_i x_{ij} \leq \mu + \frac{1}{\tau} \ln(1-\alpha) \quad j \in \mathcal{N} \quad (6)$$

$$y_j, x_{ij} \in \{0, 1\} \quad i \in \mathcal{N} \quad j \in \mathcal{N}. \quad (7)$$

A função objetivo (1) maximiza a demanda total atendida. As restrições (2) garantem que cada cliente seja atendido por apenas uma facilidade. A restrição (3) define o número de facilidades a serem instaladas. As restrições (4) impõem que os clientes sejam atendidos apenas pelas facilidades instaladas. A natureza probabilística do problema é representada pelas restrições (5) e (6): as restrições (5) garantem que a facilidade  $j$  tenha, no máximo  $b$  clientes na fila, com probabilidade mínima  $\alpha$  e as restrições (6) garantem que o tempo de atendimento na facilidade  $j$  é de, no máximo,  $\tau$  minutos, com probabilidade mínima  $\alpha$ . As restrições (7) definem a natureza binária das variáveis. É óbvio que  $x_{ij} = 0$  para todo  $j \notin \mathcal{N}_i$ . O PMCLAP é *NP-hard* (Pirkull e Schilling, 1991), o que implica que este modelo pode ser resolvido de forma exata e com mínimo esforço computacional apenas para instâncias relativamente pequenas, como será apresentado na Seção 4.

Observe que, sem as restrições (5) e (6), o modelo resultante corresponde ao MCLP.

### 3. Algoritmo Híbrido de Busca em Vizinhança

Considerando separadamente as decisões de localização e de alocação, foi desenvolvido um método iterativo híbrido para maximizar o atendimento da demanda. A cada iteração, os valores das variáveis de localização são obtidas por uma heurística flexível, baseada na metaheurística ALNS, que contém um subproblema inteiro para determinar os valores ótimos das variáveis de alocação e o valor da função objetivo.

A Figura 1 mostra a representação de uma solução de localização para uma rede com  $n = 10$  locais candidatos e  $p = 3$  facilidades instaladas.

$$y: \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 0 & 1 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 \\ \hline 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 & 10 \\ \hline \end{array}$$

Figura 1: Representação da variável de localização  $y$

Em termos gerais, o ALNS destrói e repara partes de uma solução, num processo iterativo, buscando encontrar soluções melhores. Para isso, aplicam-se operadores de destruição e de reparo, que competem entre si: operadores que produziram soluções melhores no passado têm mais chance de serem utilizados. Utilizando conhecimento do problema, foram definidos operadores de destruição e reparo que atuam fechando e depois abrindo facilidades. Com as decisões de localização fixadas, define-se um subproblema inteiro para calcular o valor ótimo das decisões de alocação, a cada iteração. Tal algoritmo pode ser caracterizado como uma *matheurística* (Maniezzo *et al.*, 2009), ou seja, uma hibridização entre um algoritmo heurístico e um método exato de programação matemática.

A escolha dos operadores é baseada numa roleta, com probabilidades que dependem do desempenho anterior dos mesmos. Tal medida de desempenho também é utilizada para definir o *score*  $\pi_r$  e o peso  $\omega_r$  para cada operador  $r$ . Assim, para  $h$  operadores, o operador  $\bar{r}$  será selecionado com probabilidade  $\omega_{\bar{r}} / \sum_{r=1}^h \omega_r$ . Inicialmente, todos os pesos são fixados em 1 e todos os *scores* são fixados em 0. A cada iteração, o *score* do operador selecionado é atualizado, sendo incrementado de  $\sigma_1$  se o operador produz uma nova melhor solução, de  $\sigma_2$  se produzir uma solução melhor que a solução incumbente e de  $\sigma_3$  se a solução não é de melhoria mas ainda é aceita como nova solução corrente. A cada  $\theta$  iterações (segmento), os pesos são atualizados de acordo com os *scores* obtidos no último segmento. Seja  $o_{rs}$  o número de vezes que o operador  $r$  foi utilizado no último segmento  $s$ . Os pesos atualizados são calculados como:

$$\omega_r = \begin{cases} \omega_r & \text{se } o_{rs} = 0 \\ (1 - \eta)\omega_r + \eta\pi_r / o_{rs} & \text{se } o_{rs} \neq 0, \end{cases} \quad (8)$$

onde  $\eta \in [0, 1]$  é denominado fator de reação e controla a rapidez com que os pesos são ajustados de acordo com as mudanças de desempenho do operador. Ao final de cada segmento, os *scores* dos operadores são reinicializados em 0.

Como ocorre em outras implementações do ALNS (Coelho *et al.*, 2012b, Ropke *et al.*, 2006a; 2006b), utiliza-se um critério de aceitação de soluções baseado na heurística Simulated Annealing. Seja  $z(\cdot)$  o valor da função objetivo da solução  $\cdot$ . Dada uma solução  $s$ , uma solução vizinha  $s'$  será sempre aceita se  $z(s') > z(s)$ ; caso contrário, será aceita com probabilidade  $e^{(z(s)-z(s'))/T}$ , onde  $T > 0$  é a temperatura atual. A temperatura tem valor inicial  $T_{inicial}$ , decrescendo a cada iteração de acordo com um fator de resfriamento  $\phi$ , onde  $0 < \phi < 1$ .

As principais características do algoritmo serão descritas nas subseções seguintes.

### 3.1. Solução inicial

O algoritmo pode iniciar com uma solução vazia ou arbitrária. Se a solução inicial for vazia então utiliza-se apenas operadores de reparo na primeira iteração visando abrir  $p$  facilidades. Na solução inicial arbitrária seleciona-se ao acaso  $p$  locais candidatos para a instalação das facilidades. Vários trabalhos demonstraram que a qualidade da solução inicial não influencia o desempenho global da metaheurística ALNS (Coelho *et al.*, 2012a; 2012b; Barrena *et al.*, 2013).

### 3.2. Lista de operadores

As características do problema em questão foram cuidadosamente consideradas para definir os operadores. Dada uma solução de localização, os operadores de destruição e de reparo irão fechar ou abrir facilidades, respectivamente, visando explorar diferentes vizinhanças.

#### 3.2.1. Operadores de destruição

##### 1. Fechar arbitrariamente $\rho$ facilidades

Este operador fecha  $\rho$  facilidades, ao acaso. Aqui,  $\rho$  é um número aleatório gerado de acordo com uma distribuição semi-triangular com inclinação negativa, definida em  $[1, p]$ . Esta distribuição é útil para o refinamento de soluções, visto que causa poucas alterações na mesma quando  $\rho$  é pequeno, o que ocorre com mais frequência devido às características desta distribuição. Entretanto, quando  $\rho$  é grande, as mudanças na solução são maiores.

##### 2. Fechar a facilidade com o menor número de clientes

Este operador identifica, dentre as facilidades abertas, aquela que possui o menor número de clientes alocados e a fecha. Neste caso, considera-se o número de clientes em potencial que estão dentro do raio de atendimento  $S$  de cada facilidade aberta  $j$ . Este operador é útil para fechar facilidades com pouco potencial de atendimento, permitindo que outra facilidade com maior potencial de atendimento seja aberta.

##### 3. Fechar a facilidade com a menor demanda atendida

Este operador fecha a facilidade com o menor potencial de atendimento da demanda. É similar ao operador anterior, mas neste caso considera-se a demanda dos clientes dentro do raio de atendimento  $S$  de cada facilidade aberta  $j$ .

##### 4. Fechar uma das duas facilidades mais próximas

Este operador identifica as duas facilidades mais próximas na solução atual e fecha uma delas, ao acaso. Este operador busca espalhar as facilidades, permitindo assim que mais clientes sejam atendidos.

#### 3.2.2. Operadores de reparo

Todos os operadores de reparo calculam o número de facilidades a serem abertas, sendo executados repetidamente até que a solução produzida contenha  $p$  facilidades.

##### 1. Instalar aleatoriamente uma facilidade

Este operador seleciona, ao acaso, um local candidato para instalar uma facilidade. É particularmente útil para diversificar a busca por melhores soluções.

##### 2. Instalar uma facilidade $a$ , no mínimo, $2S$ unidades das facilidades já abertas

Este operador busca um local candidato que esteja a mais de  $2S$  unidades de distância das facilidades já instaladas, para a instalação de uma nova facilidade. Caso não haja tal local candidato, seleciona-se o local candidato mais distante das facilidades já instaladas. O propósito deste operador é buscar atender os clientes não atendidos pelas facilidades existentes.

### 3. Instalar a facilidade com o maior potencial de atendimento (clientes)

Este operador avalia, dentre os locais candidatos não utilizados, aquele que atende o maior número de clientes ainda não atendidos pelas facilidades existentes. Com isso, busca-se atender clientes não atendidos pelas facilidades existentes, permitindo a sobreposição das áreas de atendimento das facilidades, o que pode melhorar a qualidade do serviço, sendo portanto útil para a parte probabilística do problema. Na hipótese de que todos os clientes já estejam atendidos, seleciona-se um local candidato, ao acaso.

### 4. Instalar a facilidade com o maior potencial de atendimento (demanda)

Semelhante ao operador anterior, mas buscando pelo local candidato capaz de atender a maior demanda total ainda não atendida pelas facilidades existentes. Na hipótese de que todos os clientes já estejam atendidos, seleciona-se um local candidato, ao acaso.

## 3.3. Solução do subproblema

Uma vez que a heurística ALNS terminou de destruir e reparar a solução de localização deve-se determinar a solução de alocação considerando as restrições probabilísticas e calcular o valor da função objetivo. Para isto, deve-se resolver de forma exata o seguinte problema inteiro no qual as variáveis  $y_j$  são substituídas pelos valores  $\bar{y}_j$  obtidos pela heurística ALNS:

$$\text{maximizar } \sum_{i \in \mathcal{N}} \sum_{j \in \mathcal{N}} d_i x_{ij} \quad (9)$$

sujeito a

$$\sum_{j \in \mathcal{N}} x_{ij} \leq 1 \quad i \in \mathcal{N} \quad (10)$$

$$x_{ij} \leq \bar{y}_j \quad i \in \mathcal{N}_j \quad j \in \mathcal{N} \quad (11)$$

$$\sum_{i \in \mathcal{N}_j} f_i x_{ij} \leq \mu \sqrt[b+2]{1 - \alpha} \quad j \in \mathcal{N} \quad (12)$$

ou

$$\sum_{i \in \mathcal{N}_j} f_i x_{ij} \leq \mu_j + \frac{1}{\tau} \ln(1 - \alpha) \quad j \in \mathcal{N} \quad (13)$$

$$x_{ij} \in \{0, 1\} \quad i \in \mathcal{N} \quad j \in \mathcal{N}. \quad (14)$$

Note que como  $\bar{y}$  é uma solução de localização viável, a restrição sobre o número de facilidades a serem instaladas pode ser removida da formulação, sendo considerada implicitamente. Este problema é significativamente mais fácil de ser resolvido do que o problema (1)–(7). A cada iteração, é necessário apenas atualizar os limites das variáveis  $x_{ij}$  nas restrições (11), podendo-se utilizar de técnicas de reotimização uma vez que apenas uma pequena parte do problema é alterada a cada iteração.

## 3.4. Procedimento de melhoria

Foi desenvolvido um procedimento para melhoria de soluções obtidas durante o processo que é aplicado sempre que o ALNS encontra uma nova melhor solução e a cada  $\theta$  iterações. Neste procedimento, define-se um modelo de programação inteira utilizando a melhor solução de alocação conhecida, permitindo o fechamento de duas facilidades e a seleção de outros dois locais candidatos para a instalação de novas facilidades. Este procedimento pode ser considerado como uma busca em vizinhança na qual todas as combinações de fechamento de duas facilidades e abertura de duas novas facilidades são exploradas. Se o modelo produzir uma nova melhor solução, ela será utilizada

para atualizar o ALNS. Neste modelo,  $\bar{y}$  é um vetor binário que indica se a facilidade  $j$  está aberta (1) ou fechada (0) na melhor solução conhecida até o momento.

$$\text{maximizar } \sum_{i \in \mathcal{N}} \sum_{j \in \mathcal{N}} d_i x_{ij} \quad (15)$$

sujeito a

$$\sum_{j \in \mathcal{N}} y_j = p \quad (16)$$

$$\sum_{j \in \mathcal{N}} x_{ij} \leq 1 \quad i \in \mathcal{N} \quad (17)$$

$$x_{ij} \leq y_j \quad i \in \mathcal{N}_j \quad j \in \mathcal{N} \quad (18)$$

$$\sum_{i \in \mathcal{N}_j} f_i x_{ij} \leq \mu \sqrt[1-\alpha]{b+2} \quad j \in \mathcal{N} \quad (19)$$

ou

$$\sum_{i \in \mathcal{N}_j} f_i x_{ij} \leq \mu_j + \frac{1}{\tau} \ln(1-\alpha) \quad j \in \mathcal{N} \quad (20)$$

$$\sum_{j \in \mathcal{N}} \bar{y}_j y_j = p - 2 \quad (21)$$

$$y_j, x_{ij} \in \{0, 1\} \quad i \in \mathcal{N} \quad j \in \mathcal{N}. \quad (22)$$

Neste problema, (15)–(20) são iguais à (1)–(6). A restrição adicional (21) garante que  $p-2$  das facilidades instaladas permaneçam abertas. O modelo deve abrir duas facilidades fechadas de forma a atender à restrição (16). Este procedimento de busca local não foi implementado como um operador do ALNS por ser significativamente mais complexo que os demais operadores.

### 3.5. Definição de parâmetros e pseudocódigo

Os valores dos parâmetros utilizados nesta implementação do ALNS foram definidos após uma fase inicial de testes. O número máximo de iterações  $i_{max}$  depende da temperatura inicial  $T_{inicial}$  e da taxa de resfriamento  $\phi$ . Estes parâmetros foram definidos como:

$$T_{inicial} = 30000 \quad (23)$$

$$\phi = (0,01/T_{inicial})^{1/i_{max}} \quad (24)$$

Dessa forma, a taxa de resfriamento é definida em função do número desejado de iterações, ajustando de forma automática a probabilidade de aceitação de soluções piores pelo ALNS. O critério de parada é atingido quando a temperatura atingir 0,01. Nesta implementação, o número máximo de iterações  $i_{max}$  foi fixado em 1000 para as instâncias com menos de 100 clientes, 2000 para as instâncias com menos de 500 clientes e 3000 para as instâncias com mais de 500 clientes. O valor do segmento  $\theta$  foi fixado em 200 iterações e o fator de reação  $\eta$  foi fixado em 0,7, definindo assim que os novos pesos corresponderão a 70% do desempenho do último segmento e 30% do valor do peso anterior. Os *scores* foram atualizados com  $\sigma_1 = 10$ ,  $\sigma_2 = 5$  e  $\sigma_3 = 2$ . O Algoritmo 1 mostra o pseudocódigo da implementação do ALNS.



---

**Algoritmo 1 : Matheurística ALNS híbrida.**

---

```
1: Inicialização: fixe todos os pesos em 1 e todos os scores em 0.
2:  $s_{melhor} \leftarrow s \leftarrow s_{inicial}, T \leftarrow T_{inicial}$ .
3: while  $T > 0.01$  do
4:    $s' \leftarrow s$ .
5:   escolha um operador de destruição e um de reparo usando uma roleta baseada nos pesos
   atuais. Aplique os operadores à  $s'$  e atualize o número de vezes que foram utilizados.
6:   resolva o subproblema (9)–(14), obtendo  $z(s')$ .
7:   if  $z(s') > z(s)$  then
8:      $s \leftarrow s'$ .
9:     if  $z(s) > z(s_{melhor})$  then
10:       $s_{melhor} \leftarrow s$ .
11:      atualize o score dos operadores utilizados com  $\sigma_1$ .
12:      aplique o procedimento de melhoria à  $s_{melhor}$ .
13:     else
14:       atualize o score dos operadores utilizados com  $\sigma_2$ .
15:     end if
16:   else
17:     if  $s'$  é aceita pelo critério do Simulated Annealing then
18:        $s \leftarrow s'$ .
19:       atualize o score dos operadores utilizados com  $\sigma_3$ .
20:     end if
21:   end if
22:   if o número de iterações é múltiplo de  $\theta$  then
23:     atualize os pesos de todos os operadores e reinicie seus scores.
24:     aplique o procedimento de melhoria à  $s_{melhor}$ .
25:   end if
26:    $T \leftarrow \phi T$ .
27: end while
28: return  $s_{melhor}$ .
```

---



#### 4. Resultados Computacionais

O algoritmo ALNS foi implementado em C++ e os subproblemas foram resolvidos pelo *software* de otimização comercial CPLEX Concert Technology versão 12.6. Todas as execuções foram realizadas em computadores equipados com processadores Intel Xeon™ operando a 2,66 GHz. Na execução, o algoritmo ALNS utilizou menos de 1 GB de memória RAM. O modelo apresentado na Seção 2 foi implementado em CPLEX e executado em computadores com até 48 GB de memória RAM. Os computadores utilizados operavam sob o sistema operacional Scientific Linux 6.0.

Os ensaios computacionais foram realizados sobre um grande número de instâncias de teste, divididas em 3 grupos: 26 instâncias com 30 vértices, 24 instâncias com 324 vértices e 24 instâncias com 818 vértices. O número  $p$  de facilidades a serem instaladas variou de 2 a 50. O raio de atendimento  $S$  das facilidades instaladas foi fixado em 1,5 milhas para as instâncias com 30 vértices, 250 metros para as instâncias com 324 vértices e 750 metros para as instâncias com 818 vértices. Os dados das instâncias com 30 vértices foram propostas por Marianov e Serra (1998) e os das instâncias com 324 e 818 vértices foram propostas por Corrêa *et al.* (2008). Tais conjuntos de dados foram utilizados para avaliar a heurística MS proposta por Marianov e Serra (1998), o algoritmo genético construtivo AGC de Corrêa e Lorena (2006), o algoritmo de busca em agrupamentos de Corrêa *et al.* (2008) e a heurística de geração de colunas de Corrêa *et al.* (2009).

Os nomes das instâncias nas tabelas 1–3 contém os valores dos parâmetros utilizados na execução. Por exemplo, a instância 30\_2\_0\_0\_85 refere-se a um problema com 30 vértices, duas facilidades, o tipo de restrição probabilística (0 para tamanho de fila ou 1 para tempo de espera), o respectivo parâmetro de congestionamento (o número  $b$  de clientes na fila ou o tempo de espera  $\tau$  em minutos) e a probabilidade mínima  $\alpha$ , em porcentagem. A taxa de chegada  $\mu$  foi fixada em 72 para a rede com 30 vértices e em 96 para as redes com 324 e 818 vértices. O parâmetro  $f_i$  das formulações (1)–(7), (9)–(14) e (15)–(22) foi calculado como  $f d_i$ , com  $f = 0,01$  para as redes com 324 e 818 vértices. Para a rede com 30 vértices,  $f = 0,015$  (restrições de tamanho da fila) ou  $f = 0,006$  (restrições de tempo de espera).

As tabelas 1–3 apresentam, para cada instância, a melhor solução, a solução média (quando disponível) e o respectivo tempo computacional para seis métodos distintos. A melhor solução encontrada para cada instância está destacada em negrito. Na coluna CPLEX de cada tabela, a nova melhor solução obtida por um método exato aparece marcada com um asterisco. Para a heurística de geração de colunas, a coluna *Gap (%)* apresenta a diferença percentual entre a solução obtida e o limitante superior, ambos calculados pela heurística.

Na seção da heurística ALNS, cada instância foi executada 3 vezes. Na coluna *Média* pode-se comprovar a consistência do método proposto. Os valores apresentados nas colunas *Tempo (s)* também são valores médios.

Conforme apresentado na Tabela 1, a implementação do método exato provou a otimalidade para as 26 instâncias. O algoritmo ALNS atingiu a solução ótima em todas elas, demonstrando um desempenho melhor que os outros métodos da literatura, como pode ser comprovado na linha *Média* no final da tabela, sendo em média 10 vezes mais rápido que o CPLEX.

Na Tabela 2, usando a implementação do método exato, o CPLEX provou a otimalidade para 23 das 24 instâncias. o algoritmo ALNS conseguiu encontrar a solução ótima para 19 instâncias e atingiu resultados melhores que os da literatura para as outras 5 instâncias.

Na Tabela 3, o CPLEX obteve a solução ótima para todas as instâncias. O algoritmo ALNS encontrou 19 delas e apresentou desempenho melhor em uma instância que o obtido anteriormente pela melhor heurística da literatura.

#### 5. Conclusão

Este artigo apresentou um método híbrido para resolver o problema probabilístico de localização-alocação de máxima cobertura. O algoritmo é baseado numa heurística *adaptive large neighborhood search* utilizada para determinar as decisões de localização do problema. Um método



Tabela 1: Resultados computacionais para a instância com 30 vértices.

Instância	CPLEX			Heurística MS		AGC			Busca em Agrupamentos			Geração de Colunas			ALNS		
	Solução	Gap (%)	Tempo (s)	Solução	Tempo (s)	Melhor	Média	Tempo (s)	Melhor	Média	Tempo (s)	Solução	Gap (%) <sup>1</sup>	Tempo (s)	Melhor	Média	Tempo (s)
30.2.0.0.85	3700	0,000	0	3700	0,000	3700	3700	0,310	3700	3700,0	0,009	3700	0,000	0,530	3700	3700,0	12,333
30.2.0.1.85	5100	0,000	0	4630	0,000	5090	5090	0,360	5090	5090,0	0,018	5090	0,196	5,550	5100	5100,0	9,000
30.2.0.2.85	5210	0,000	0	4780	0,000	5210	5210	0,380	5210	5210,0	0,016	5210	1,321	4,770	5210	5210,0	4,667
30.2.0.2.95	4520	0,000	0	4470	0,000	4520	4513	0,300	4520	4520,0	0,015	4520	0,000	0,700	4520	4520,0	11,333
30.3.0.0.85	5390	0,000	0	5210	0,000	5390	5390	0,510	5390	5390,0	0,025	5390	0,119	28,030	5390	5390,0	5,000
30.3.0.1.85	5390	0,000	0	5210	0,000	5390	5390	0,480	5390	5390,0	0,024	5390	0,742	3,770	5390	5390,0	3,000
30.3.0.1.95	5270	0,000	6	5080	0,000	5240	5240	0,480	5240	5240,0	0,024	5240	0,763	14,750	5270	5270,0	44,667
30.3.0.2.85	5390	0,000	1	5210	0,000	5390	5390	0,470	5390	5390,0	0,023	5390	0,742	1,880	5390	5390,0	3,667
30.3.0.2.95	5390	0,000	0	5230	0,000	5390	5390	0,500	5390	5390,0	0,027	5390	0,622	11,450	5390	5390,0	3,667
30.3.1.49.90	2160	0,000	0	2160	0,000	2160	2160	0,530	2160	2160,0	0,009	2160	0,000	0,360	2160	2160,0	13,333
30.4.0.1.95	5390	0,000	0	5260	0,000	5390	5390	0,540	5390	5390,0	0,026	5390	1,391	30,880	5390	5390,0	8,333
30.4.1.42.85	4600	0,000	0	4550	0,000	4600	4600	0,610	4600	4600,0	0,022	4600	0,000	0,810	4600	4600,0	105,667
30.4.1.48.90	1920	0,000	0	1890	0,000	1920	1920	0,660	1920	1920,0	0,014	1920	0,000	0,440	1920	1920,0	17,333
30.4.1.49.90	2880	0,000	0	2870	0,000	2880	2877	0,590	2880	2880,0	0,013	2880	0,000	0,450	2880	2880,0	15,000
30.5.0.0.95	5330	0,000	13	5210	0,000	5330	5323	0,800	5330	5317,6	0,041	5330	0,375	6,910	5330	5330,0	288,667
30.5.1.40.85	3050	0,000	93	2910	0,000	3020	3001	0,740	3050	3033,2	0,021	3050	0,000	0,890	3050	3050,0	234,000
30.5.1.42.85	5390	0,000	1	5210	0,000	5390	5390	0,770	5390	5390,0	0,035	5390	0,464	34,170	5390	5390,0	15,000
30.5.1.48.90	2400	0,000	1	2280	0,000	2390	2390	0,740	2400	2398,8	0,019	2400	0,000	3,080	2400	2400,0	26,667
30.5.1.50.90	4700	0,000	1	4670	0,000	4700	4700	0,730	4700	4700,0	0,028	4700	0,000	0,830	4700	4700,0	42,667
30.6.0.0.95	5410	0,000	1	5390	0,000	5410	5392	0,840	5410	5391,0	0,037	5410	1,054	42,410	5410	5410,0	62,333
30.6.1.40.85	3610	0,605	10803	3480	0,000	3610	3610	0,910	3610	3608,8	0,031	3610	1,022	30,640	3610	3610,0	514,000
30.6.1.41.85	5330	0,188	10802	5120	0,000	5300	5274	1,000	5330	5286,4	0,038	5300	0,755	11,740	5330	5330,0	322,333
30.6.1.50.90	5390	0,000	1	5060	0,000	5390	5390	0,970	5390	5390,0	0,038	5390	0,395	48,440	5390	5390,0	31,667
30.7.1.40.85	4060	0,000	1	3860	0,000	4060	4060	1,030	4060	4060,0	0,039	4060	0,517	18,920	4060	4060,0	301,000
30.7.1.41.85	5410	0,000	1	5300	0,000	5390	5390	0,880	5390	5390,0	0,035	5350	2,159	41,840	5410	5410,0	61,333
30.8.1.41.85	5470	0,000	0	5390	0,000	5470	5470	0,950	5470	5470,0	0,032	5470	0,000	1,200	5470	5470,0	8,333
Média	4533,1	0,030	835,577	4389,6	0,000	4528,1	4525,0	0,657	4530,8	4527,1	0,025	4528,1	0,486	13,286	4533,1	4533,1	83,269

<sup>1</sup> gap da heurística

Tabela 2: Resultados computacionais para a instância com 324 vértices.

Instância	CPLEX			Heurística MS		AGC			Busca em Agrupamentos			Geração de Colunas			ALNS		
	Solução	Gap (%)	Tempo (s)	Solução	Tempo (s)	Melhor	Média	Tempo (s)	Melhor	Média	Tempo (s)	Solução	Gap (%) <sup>1</sup>	Tempo (s)	Melhor	Média	Tempo (s)
324.10.0.0.85	37180	0,000	13	37081	0,220	37145	37069,0	8,100	37173	37163,2	3,460	37180	0,000	275,110	37180	37180,0	1255,333
324.10.0.0.95	21460	0,000	9	21386	0,140	21431	21373,0	8,630	21455	21447,2	3,160	21460	0,000	65,200	21460	21460,0	865,667
324.10.0.1.85	51000	0,000	22	50750	0,200	50880	50711,0	7,690	50948	50946,3	3,410	51000	0,000	507,810	51000	51000,0	1435,000
324.10.0.1.95	35360	0,000	14	35250	0,160	35342	35304,0	7,790	35359	35354,6	3,170	35360	0,000	47,330	35360	35360,0	857,000
324.10.0.2.85	59740	0,000	22	59598	0,200	59624	59437,0	7,620	59693	59688,5	3,330	59740	0,000	604,480	59740	59740,0	987,667
324.10.0.2.95	45390	0,000	9	45300	0,200	45347	45245,0	7,810	45374	45354,6	3,100	45390	0,000	327,840	45390	45390,0	1292,000
324.10.1.40.85	27700	0,000	14	27583	0,170	27675	27602,0	8,540	27698	27692,1	3,370	27700	0,000	238,390	27700	27700,0	1406,333
324.10.1.41.85	29360	0,000	6	29288	0,140	29324	29260,0	8,270	29351	29341,9	3,520	29360	0,000	145,880	29360	29360,0	1182,667
324.10.1.42.85	30950	0,000	11	30902	0,170	30932	30895,0	8,340	30948	30943,3	3,330	30950	0,000	42,910	30950	30950,0	1034,667
324.10.1.48.90	26920	0,000	15	26855	0,140	26883	26835,0	8,350	26917	26910,6	3,500	26920	0,000	144,720	26920	26920,0	1492,667
324.10.1.49.90	28330	0,000	22	28206	0,250	28280	28221,0	8,280	28318	28310,3	3,430	28330	0,000	315,700	28330	28330,0	1747,000
324.10.1.50.90	29680	0,000	6	29638	0,220	29641	29593,0	8,260	29672	29665,5	3,360	29680	0,000	81,810	29680	29680,0	1127,333
324.20.0.0.85	74360*	0,000	198	73981	0,830	73407	73001,0	23,690	74165	74106,7	9,710	74358	0,003	2630,440	74360	74357,7	6191,667
324.20.0.0.95	42920	0,000	22	42714	0,730	42577	42318,0	24,300	42840	42804,9	9,370	42920	0,000	2425,520	42920	42919,7	3936,333
324.20.0.1.85	102000*	0,000	612	100628	1,020	99576	98353,0	24,690	101374	101177,4	9,070	101973	0,024	10801,330	101978	101974,0	7212,667
324.20.0.1.95	70720	0,000	55	70368	0,740	70471	70308,0	23,400	70656	70628,2	9,060	70720	0,000	1067,410	70720	70720,0	4417,333
324.20.0.2.85	119470*	0,008	10804	118451	0,770	116639	115235,0	23,330	118771	118613,6	8,990	119448	0,019	10801,590	119455	119447,3	6388,000
324.20.0.2.95	90780*	0,000	74	90424	0,810	89970	89355,0	24,150	90556	90521,2	9,400	90780	0,000	2369,980	90780	90780,0	6667,333
324.20.1.40.85	55400*	0,000	52	55006	0,840	54804	54414,0	23,920	55306	55226,7	9,650	55396	0,007	8457,660	55399	55398,3	5488,667
324.20.1.41.85	58720	0,000	85	58577	1,020	58009	57571,0	24,700	58604	58583,4	10,330	58720	0,000	1377,420	58720	58720,0	7417,667
324.20.1.42.85	61900	0,000	35	61637	0,880	61545	61266,0	23,810	61847	61822,6	9,740	61900	0,000	735,140	61900	61900,0	3561,333
324.20.1.48.90	53840*	0,000	49	53377	0,630	53300	52958,0	24,320	53793	53689,5	9,820	53838	0,004	4645,490	53839	53838,7	5912,667
324.20.1.49.90	56660*	0,000	167	56180	1,340	56216	55813,0	24,150	56532	56429,9	9,550	56654	0,009	10800,920	56655	56655,0	7130,667
324.20.1.50.90	59360*	0,000	56	59119	0,940	58941	58577,0	26,030	59285	59242,6	10,080	59360	0,000	1273,390	59360	59360,0	5551,333
Média	52883,3	0,000	515,500	52595,8	0,532	52415,0	52113,1	16,174	52776,5	52736,0	6,455	52880,7	0,003	2507,645	52881,5	52880,9	3523,292

\* nova melhor solução obtida por um método exato

<sup>1</sup> gap da heurística

Tabela 3: Resultados computacionais para a instância com 818 vértices.

Instância	CPLEX			Heurística MS		AGC			Busca em Agrupamentos			Geração de Colunas			ALNS		
	Solução	Gap (%)	Tempo (s)	Solução	Tempo (s)	Melhor	Média	Tempo (s)	Melhor	Média	Tempo (s)	Solução	Gap (%) <sup>1</sup>	Tempo (s)	Melhor	Média	Tempo (s)
818_10.0.0.95	<b>21460</b>	0,000	557	21429	4,940	21455	21449,3	43,650	<b>21460</b>	21459,9	11,230	<b>21460</b>	0,000	163,08	<b>21460</b>	21460,0	6818,000
818_10.0.1.95	<b>35360</b>	0,000	657	35339	13,050	35356	35346,0	50,450	<b>35360</b>	35360,0	11,540	<b>35360</b>	0,000	207,69	<b>35360</b>	35360,0	10407,000
818_10.0.2.95	<b>45390</b>	0,000	648	45375	12,090	45387	45377,4	49,370	<b>45390</b>	45390,0	12,170	<b>45390</b>	0,000	251,33	<b>45390</b>	45390,0	7400,000
818_10.1.48.90	<b>26920</b>	0,000	586	26907	11,380	26915	26901,0	48,350	<b>26920</b>	26920,0	11,320	<b>26920</b>	0,000	185,41	<b>26920</b>	26920,0	8212,000
818_10.1.49.90	<b>28330</b>	0,000	659	28309	8,630	28320	28298,0	47,780	<b>28330</b>	28330,0	12,230	<b>28330</b>	0,000	196,06	<b>28330</b>	28330,0	8052,667
818_10.1.50.90	<b>29680</b>	0,000	682	29661	18,280	29678	29673,8	47,810	<b>29680</b>	29680,0	11,330	<b>29680</b>	0,000	199,28	<b>29680</b>	29680,0	9078,333
818_20.0.0.85	<b>74360</b>	0,000	785	74313	75,050	74341	74279,4	90,040	<b>74360</b>	74359,8	66,810	<b>74360</b>	0,000	412,74	<b>74360</b>	74360,0	17183,667
818_20.0.0.95	<b>42920</b>	0,000	562	42793	25,670	42870	42817,7	76,200	<b>42920</b>	42918,9	54,840	<b>42920</b>	0,000	248,13	<b>42920</b>	42920,0	9890,333
818_20.0.1.85	<b>102000*</b>	0,000	1491	101933	76,060	101955	101898,8	89,190	<b>102000</b>	101998,9	67,360	<b>102000</b>	0,000	447,06	<b>102000</b>	102000,0	16602,000
818_20.0.1.95	<b>70720</b>	0,000	610	70644	37,030	70653	70557,1	80,420	<b>70720</b>	70719,2	62,910	<b>70720</b>	0,000	390,03	<b>70720</b>	70720,0	16880,667
818_20.0.2.85	<b>119480*</b>	0,000	1579	119397	105,480	119445	119306,4	89,180	<b>119480</b>	119477,6	74,360	<b>119480</b>	0,000	473,52	<b>119480</b>	119480,0	19074,667
818_20.0.2.95	<b>90780</b>	0,000	841	90730	75,190	90747	90672,9	84,990	<b>90780</b>	90779,6	66,800	<b>90780</b>	0,000	460,19	<b>90780</b>	90780,0	14622,667
818_20.1.40.85	<b>55400*</b>	0,000	833	55325	66,110	55341	55235,7	88,330	<b>55400</b>	55399,0	61,040	<b>55400</b>	0,000	293,62	<b>55400</b>	55400,0	15044,333
818_20.1.41.85	<b>58720*</b>	0,000	641	58637	69,630	58706	58677,6	87,620	<b>58720</b>	58719,9	57,310	<b>58720</b>	0,000	372,28	<b>58720</b>	58720,0	14384,000
818_20.1.42.85	<b>61900*</b>	0,000	929	61814	71,810	61839	61719,7	90,430	<b>61900</b>	61898,8	58,710	<b>61900</b>	0,000	380,64	<b>61900</b>	61900,0	14487,000
818_20.1.48.90	<b>53840</b>	0,000	640	53728	22,410	53814	53762,2	87,870	<b>53840</b>	53839,6	59,560	<b>53840</b>	0,000	343,08	<b>53840</b>	53840,0	13808,667
818_20.1.49.90	<b>56660</b>	0,000	948	56602	34,340	56605	56465,3	88,710	<b>56660</b>	56660,0	67,420	<b>56660</b>	0,000	324,64	<b>56660</b>	56660,0	13008,333
818_20.1.50.90	<b>59360</b>	0,000	877	59269	39,840	59336	59279,8	87,040	<b>59360</b>	59359,9	58,480	<b>59360</b>	0,000	364,84	<b>59360</b>	59360,0	14568,667
818_50.0.0.85	<b>185900*</b>	0,000	2956	185426	756,720	184428	184153,6	177,340	185880	185775,6	364,200	185898	0,001	3695,94	185637	185587,7	24094,333
818_50.0.1.85	<b>255000*</b>	0,000	6332	254509	730,200	253438	252884,6	171,860	254985	254905,0	387,370	<b>255000</b>	0,000	5072,75	254996	254987,3	23978,000
818_50.0.2.85	<b>298700*</b>	0,000	4435	298217	757,730	296763	296182,8	171,740	298582	298517,6	392,290	298490	0,070	6004,53	298692	298648,3	23729,667
818_50.1.48.90	<b>134600*</b>	0,000	785	134088	596,110	134079	133999,4	177,670	134598	134561,6	335,000	<b>134600</b>	0,000	2317,55	134597	134593,3	25037,333
818_50.1.49.90	<b>141650*</b>	0,000	1719	141281	571,170	140439	140143,4	174,960	141586	141532,8	356,800	<b>141650</b>	0,000	2713,86	<b>141650</b>	141606,7	24425,000
818_50.1.50.90	<b>148400*</b>	0,000	1946	147931	667,670	147202	147123,8	173,960	148383	148321,9	337,400	<b>148400</b>	0,000	2444,64	148397	148378,0	25031,667
Média	<b>91563,8</b>	0,000	1362,417	91402,4	201,941	91213,0	91091,9	98,957	91553,9	91536,9	124,937	91554,9	0,003	1165,120	91552,0	91545,1	15659,125

\* nova melhor solução obtida por um método exato

<sup>1</sup> gap da heurística

exato de programação matemática é utilizado para determinar a solução dos subproblemas de alocação. As melhores soluções obtidas pela metaheurística podem ser aperfeiçoadas por um procedimento flexível de melhoria. O método híbrido apresentou um desempenho consistente, encontrando 10 soluções melhores que as da literatura, sendo 4 delas ótimas. O critério de parada exclusivamente baseado em *Simulated Annealing* contribuiu para o aumento dos tempos computacionais nas instâncias maiores.

## 6. Agradecimentos

O primeiro autor agradece ao CIRRELT – Centre Interuniversitaire de Recherche sur les Réseaux d'Enterprise, la Logistique et le Transport, ao Department of Operations and Decision Systems e à Faculty of Administration Sciences da Université Laval pelo apoio financeiro.

## Referências

- Arakaki, R. G. I. e Lorena, L. A. N.**, A constructive genetic algorithm for the maximal covering location problem, in *Proceedings of the 4th Metaheuristics International Conference*, Porto, Portugal, 2001.
- Barrena, E., Ortiz, D. C., Coelho L. C. e Laporte, G.**, A fast and efficient adaptive large neighborhood search heuristic for the passenger train timetabling problem with dynamic demand, *Technical Report 64*, CIRRELT, Montréal, 2013.
- Bartodziej, P., Derigs, U., Malcherek, D. e Vogel, U.** (2009), Models and algorithms for solving combined vehicle and crew scheduling problems with rest constraints: an application to road feeder service planning in air cargo transportation, *OR Spectrum*, 31, 405-429.
- Berman, O., Drezner, Z. e Wesolowsky, G. O.** (2009), The maximal covering problem with negative weights, *Geographical Analysis*, 41, 30-42.
- Berman, O., Hajizadeh, I. e Krass, D.** (2013), The maximum covering problem with travel time uncertainty, *IIE Transactions*, 45, 81-96.
- Church, R. e ReVelle, C.** (1974), The maximal covering location problem, *Papers in Regional Science*, 32, 101-118.
- Coelho, L. C., Cordeau, J.-F. e Laporte, G.** (2012a), The inventory-routing problem with transshipment, *Computers & Operations Research*, 39, 2537-2548.
- Coelho, L. C., Cordeau, J.-F. e Laporte, G.** (2012b), Consistency in multi-vehicle inventory-routing, *ransportation Research Part C: Emerging Technologies*, 24, 270-287.

- Corrêa, F. A. e Lorena, L. A. N.**, Using the constructive genetic algorithm for solving the probabilistic maximal covering location-allocation problem, in *Proceedings of the I Workshop on Computational Intelligence*, Ribeirão Preto, Brasil, 2006.
- Corrêa, F. A., Chaves, A. A. e Lorena, L. A. N.** (2008), Hybrid heuristics for the probabilistic maximal covering location-allocation problem, *Operational Research. An International Journal*, 7, 323-344.
- Corrêa, F. A., Lorena, L. A. N. e Ribeiro, G. M.** (2009), A decomposition approach for the probabilistic maximal covering location-allocation problem, *Computers & Operations Research*, 36, 2729-2739.
- Daskin, M. S.**, *Network and Discrete Location: Models, Algorithms and Applications*, John Wiley & Sons, New York, 1995.
- Galvão, R. D.** (2004), Uncapacitated facility location problems: contributions, *Pesquisa Operacional*, 24, 7-38.
- Galvão, R. D. e ReVelle, C.** (1996), A lagrangean heuristic for the maximal covering location problem, *European Journal of Operational Research*, 88, 114-123.
- Hale, T. S. e Moberg, C. R.** (2003), Location science research: a review, *Annals of Operations Research*, 123, 21-35.
- Hemmelmayr, V. C., Cordeau, J.-F. e Crainic, T. G.** (2012), An adaptive large neighborhood search heuristic for two-echelon vehicle routing problems arising in city logistics, *Computers & Operations Research*, 39, 3215-3228.
- Lorena, L. A. N. e Pereira, M. A.** (2002), A lagrangean/surrogate heuristic for the maximal covering location problem using Hillsman's edition, *International Journal of Industrial Engineering*, 9, 57-67.
- Maniezzo, V., Stützle T. e Voß, S.**, *Matheuristics: Hybridizing Metaheuristics and Mathematical Programming*, Springer, New York, 2009.
- Marianov, V. e Serra, D.** (1998), Probabilistic maximal covering location-allocation models for congested systems, *Journal of Regional Science*, 38, 401-424.
- Pepin, A.-S., Desaulniers, G. Hertz, A. e Huisman, D.** (2009), A comparison of five heuristics for the multiple depot vehicle scheduling problem, *Journal of Scheduling*, 12, 17-30.
- Pereira, M. A., Lorena, L. A. N. e Senne, E. L. F.** (2007), A column generation approach for the maximal covering location problem, *International Transactions in Operations Research*, 14, 349-364.
- Pirkul, H. e Schilling, D. A.** (1991), The maximal covering location problem with capacities on total workload, *Management Science*, 37, 233-248.
- Ropke, S. e Pisinger, D.** (2006), An adaptive large neighborhood search heuristic for the pickup and delivery problem with time windows, *Transportation Science*, 40, 455-472.
- Ropke, S. e Pisinger, D.** (2006), A unified heuristic for a large class of vehicle routing problems with backhauls, *European Journal of Operational Research*, 171, 750-755.
- Serra, D. e Marianov, V.**, New trends in public facility location modeling, *Technical Report 755*, UFP Economics and Business, Barcelona, 2004.