

ALGORITMO ILS PARA O PROBLEMA DE LOCALIZAÇÃO DE p -HUBS AVESSO AO RISCO COM ALOCAÇÃO MÚLTIPLA

Aldo Vieira Pinto^{1,2}, Elisangela Martins de Sá², Sérgio Ricardo de Souza²

¹ Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais
Rua Afonso Sardinha, 90, CEP: 36494-018, Ouro Branco, MG, Brasil

² Centro Federal de Educação Tecnológica de Minas Gerais
Av. Amazonas, 7675, CEP: 30510-000, Belo Horizonte, MG, Brasil
aldo.vieira@ifmg.edu.br, elisangelamartins@cefetmg.br,
sergio@cefetmg.br

RESUMO

Este artigo propõe uma formulação para o problema de localização de hubs do tipo p -mediana com múltiplas alocações sob condições de incerteza. Para lidar com as incertezas nos custos e nas demandas, é proposto um modelo com aversão ao risco, que utiliza o *Conditional Value at Risk* (CVaR). Este artigo propõe também um algoritmo baseado na metaheurística *Iterated Local Search* (ILS) para o problema. A partir de experimentos computacionais realizados utilizando cenários gerados a partir dos conjuntos de instâncias da literatura, verifica-se que a metaheurística ILS possibilita, nestes casos, obter boas soluções com pouca variabilidade e com baixo tempo computacional. Experimentos computacionais com o *solver* CPLEX, por outro lado, mostram que o problema se torna intratável, por questão de tempo computacional e disponibilidade de memória, mesmo para instâncias com poucos nós e poucos cenários.

PALAVRAS CHAVE. Localização de *hubs*. Alocação múltipla. Otimização sob incertezas. Medida CVaR de Aversão ao Risco. Algoritmo ILS.

Tópicos: MH – Metaheurísticas, OC – Otimização Combinatória.

ABSTRACT

This article proposes a formulation for the p -median hub location problem with multiple allocations under uncertainty conditions. A risk-averse model is proposed to deal with uncertainties in costs and demands, which uses Conditional Value at Risk (CVaR). This article also proposes an algorithm based on the Iterated Local Search (ILS) metaheuristic for the problem. Based on the performed computational experiments using scenarios generated from sets of instances in the literature, it can be seen that the ILS metaheuristic makes it possible, in these cases, to obtain good solutions with little variability and low computational time. On the other hand, computational experiments with the CPLEX solver show that the problem becomes intractable due to large runtime and excessive memory usage, even for instances with few nodes and few scenarios.

KEYWORDS. Hub location. Multiple-allocation. Optimization under uncertainty. CVaR Measure of Risk Aversion. ILS algorithm.

Paper topics: MH - Metaheuristics, OC- Combinatorial optimization.

1. Introdução

Ao se projetar uma rede, a instalação de conexões diretas entre cada par de origem e destino pode ser impraticável por conta de restrições orçamentárias ou operacionais. Projetar, então, a rede no formato eixo-raio pode reduzir o número de conexões, bem como o custo de transporte, por meio de economias de escala entre os *hubs*, devido à consolidação e redistribuição do fluxo pelos *hubs* [Farahani et al., 2013]. Estes nós recebem as demandas de diferentes nós de origem, que são enviadas para uma rede de nós *hubs* e, em seguida, distribuídas para os nós de destino.

O problema não capacitado de p medianas de *hubs* com alocação múltipla (UMApHMP - *Uncapacitated Multiple Allocation p-hub Median Problem*) busca localizar p *hubs* não-capacitados, com múltiplas alocações, ou seja, os nós não *hubs* podem ser alocados a mais de um *hub*, a fim de minimizar a soma dos custos de transporte para atender a todas as demandas.

Por envolver decisões estratégicas relacionadas com altos investimentos financeiros e de manutenção operacional, as incertezas nos custos ou nas demandas podem tornar as decisões baseadas na solução do problema determinístico pouco realistas. De acordo com Alem e Morabito [2015], há na literatura da pesquisa operacional várias abordagens de problemas de otimização que consideram incertezas nos dados. A Otimização Estocástica, em que os parâmetros incertos são modelados por meio de uma distribuição de probabilidade conhecida ou razoavelmente bem estimada, é uma das principais abordagens a tratar essa questão.

Com relação aos estudos que consideram a incerteza em problemas de localização de *hubs*, Marianov e Serra [2003] tratam de um problema no contexto do transporte aéreo sob efeitos de congestionamento com restrições probabilísticas. Yang [2009] apresenta um modelo de programação estocástica de dois estágios para abordar a localização de *hubs* de carga aérea e o planejamento de rotas de vôo sob variações sazonais de demanda. Já Contreras et al. [2011] consideram problemas com incertezas na demanda e custos de transporte, com objetivo de otimização de valor de esperado.

Para o caso de modelos estocásticos de localização de *hubs*, a maioria dos estudos existentes na literatura é neutra frente ao risco, ou seja, o objetivo é minimizar o custo total esperado. Estes modelos que otimizam o custo em média podem levar a resultados indesejáveis, como altos custos de transporte ou longos tempos de viagem, de maneira tal que a qualidade das soluções pode não ser satisfatória. Em modelos avessos ao risco, por outro lado, agrega-se medidas de variabilidade à função objetivo, permitindo um controle do grau de aversão ao se alterar os parâmetros das funções de medida de risco. Modelos avessos ao risco têm sido amplamente utilizados em várias áreas, incluindo logística humanitária [Ozbay et al., 2019] e otimização de portfólio financeiro [Paç e Pinar, 2014].

Kargar e Mahmutogullari [2022] abordam modelos neutros e avessos ao risco para o problema UMaPHMP, com uma estrutura da rede cujas alocações se dá por meio de caminhos que permitem nós não-*hubs* como nós intermediários e em quantidade arbitrária. Uma vez que o problema se torna computacionalmente intratável à medida que o número de cenários aumenta, os autores propõem um algoritmo de agrupamento baseado em árvore de cenários para resolvê-lo. Essa técnica tem sido empregada em outras variantes de problemas de localização de *hubs*, integrada com a decomposição de Benders, como em Ghaffarinasab et al. [2023].

O presente artigo propõe uma formulação para o problema de localização de *hubs* sob condições avessas ao risco mediante o *Conditional Value at Risk* (CVaR), baseado em Kargar e Mahmutogullari [2022], que será denotado por UMaPHMP-CVaR, bem como propõe um algoritmo baseado na meta-heurística *Iterated Local Search* (ILS) [Stützle, 1998] para a sua solução.

Este trabalho está organizado da seguinte maneira. A Seção 2 apresenta o problema objeto de interesse. A Seção 3 detalha o algoritmo proposto. Os experimentos computacionais são apresentados na Seção 4. A Seção 5 aponta as considerações finais e propostas de trabalhos futuros.

2. Formulação do Problema

Considere $G = (N, E)$ um grafo, em que N é o conjunto de nós e E é o conjunto de arestas. O UMAPHMP-CVaR supõe que os custos e os fluxos de demanda são incertos. Além disso, a decisão de localização dos hubs é tomada em um primeiro estágio, com base apenas nas informações disponíveis no momento em que a decisão é tomada (hipótese de não-antecipatividade), enquanto as decisões de roteamento de fluxo de demanda são tomadas em um segundo estágio, quando os dados incertos se tornam conhecidos. Além disso, a aversão ao risco devido a incertezas é modelada usando o CVaR.

O CVaR é uma medida de risco de uma variável aleatória no nível β , com $0 \leq \beta < 1$, dada pelo valor esperado condicional dessa variável aleatória a $100(1 - \beta)\%$ dos cenários mais pessimistas. Por esta razão o CVaR é conhecido na literatura como uma medida avessa ao risco. Demonstra-se em Rockafellar e Uryasev [2002] que, para uma variável aleatória X :

$$\text{CVaR}_\beta(X) = \inf_{\eta \in \mathbb{R}} \left\{ \eta + \frac{1}{1 - \beta} \mathbb{E}[(X - \eta)_+] \right\}$$

em que a função não linear $(\cdot)_+$ é definida como $(t)_+ = \max\{0, t\}$. Mostra-se, em Shapiro et al. [2009], que o CVaR é uma função convexa definida em X . Além disso, apesar da presença de funções não lineares, um modelo usando esta medida de risco é facilmente linearizável.

O problema UMAPHMP-CVaR busca selecionar p nós no conjunto de nós N para se tornarem *hubs*, de forma a minimizar o CVaR do custo total de transporte, assumindo que não são permitidas conexões diretas entre nós não hubs e que pode haver no máximo dois hubs em cada caminho. A formulação e a notação utilizadas neste trabalho são baseadas na formulação proposta por Kargar e Mahmutogullari [2022], com a adição de algumas restrições, que utilizam como base as formulações propostas por Ernst e Krishnamoorthy [1998] e Alumur et al. [2012] para o caso determinístico.

Assume-se que é dado um espaço de probabilidade Ω , com probabilidade π^ω para o cenário $\omega \in \Omega$. O parâmetro c_{ij}^ω é o custo por unidade roteada na aresta $(i, j) \in E$ e w_{ij}^ω é o fluxo a ser enviado do nó $i \in N$ para o nó $j \in N$ no cenário $\omega \in \Omega$. Além disso, seja $\alpha \in (0, 1)$ o fator de desconto constante no transporte realizado nas conexões entre *hubs*. Supondo que k e l são nós *hubs* e i e j são nós não *hubs*, o custo de transporte de uma unidade de fluxo através da rota $i \rightarrow k \rightarrow l \rightarrow j$ no cenário $\omega \in \Omega$ é calculado como $c_{ik}^\omega + \alpha c_{kl}^\omega + c_{lj}^\omega$. O modelo também usa O_i^ω para representar o fluxo total originado no nó $i \in N$, ou seja, $O_i^\omega = \sum_{j \in N} w_{ij}^\omega$.

A formulação utiliza as variáveis de decisão H_k binárias, de modo que $H_k = 1$ se o nó $k \in N$ é um hub e $H_k = 0$, caso contrário; as variáveis Z_{ik}^ω , que representam o fluxo enviado do nó $i \in N$ para o hub $k \in N$ no cenário ω ; as variáveis Y_{ikl}^ω , que representam o fluxo originado no nó $i \in N$ e roteado através da conexão entre os hubs $k, l \in N$ no cenário ω ; e a variável X_{ilj}^ω , que representa o fluxo originado no nó $i \in N$ e enviado do hub $l \in N$ para o nó $j \in N$ no cenário ω .

Dado um nível de risco $0 \leq \beta < 1$, a formulação para o problema é dada, então, por:

$$\min \quad \eta + \frac{1}{1 - \beta} \sum_{\omega \in \Omega} \pi^\omega (C^\omega - \eta)_+ \quad (1)$$

$$\text{s. a} \quad C^\omega = \sum_{i \in N} \sum_{k \in N} c_{ik}^\omega Z_{ik}^\omega + \sum_{i \in N} \sum_{k \in N} \sum_{l \in N} \alpha c_{kl}^\omega Y_{ikl}^\omega + \sum_{i \in N} \sum_{l \in N} \sum_{j \in N} c_{lj}^\omega X_{ilj}^\omega, \quad \forall \omega \in \Omega \quad (2)$$

$$\sum_{k \in N} H_k = p \quad (3)$$

$$\sum_{k \in N} Z_{ik}^\omega = O_i^\omega, \quad \forall i \in N, \omega \in \Omega \quad (4)$$

$$\sum_{l \in N} X_{ilj}^{\omega} = w_{ij}^{\omega}, \quad \forall i, j \in N, \omega \in \Omega \quad (5)$$

$$\sum_{\substack{l \in N \\ l \neq k}} Y_{ikl}^{\omega} + \sum_{j \in N} X_{ikj}^{\omega} = \sum_{\substack{l \in N \\ l \neq k}} Y_{ilk}^{\omega} + Z_{ik}^{\omega}, \quad \forall i, k \in N, \omega \in \Omega \quad (6)$$

$$Z_{ik}^{\omega} \leq O_i^{\omega} H_k, \quad \forall i, k \in N, \omega \in \Omega \quad (7)$$

$$X_{ilj}^{\omega} \leq w_{ij}^{\omega} H_l, \quad \forall i, j, l \in N, \omega \in \Omega \quad (8)$$

$$\sum_{l \in N} Y_{ikl}^{\omega} \leq Z_{ik}^{\omega}, \quad \forall i, k \in N, \omega \in \Omega \quad (9)$$

$$Z_{ik}^{\omega}, Y_{ikl}^{\omega}, X_{ilj}^{\omega} \geq 0, \quad \forall i, j, k, l \in N, \omega \in \Omega \quad (10)$$

$$H_k \in \{0, 1\}, \quad \forall k \in N. \quad (11)$$

$$\eta \in \mathbb{R} \quad (12)$$

A função objetivo (1) minimiza o CVaR no nível β da variável aleatória discreta dada pelo custo total de transporte, isto é, minimiza a média dos $100(1 - \beta)\%$ maiores custos. As restrições (2) calculam, para cada cenário $\omega \in \Omega$, o custo do transporte como a soma do custo de transporte dos nós de origem até o primeiro *hub*, dentre *hubs* e do último *hub* ao nó de destino. A restrição (3) garante que o número de *hubs* ativados seja p . As restrições de conservação de fluxo (4), (5) e (6) garantem que o fluxo seja roteado adequadamente para cada par origem-destino. As restrições (7) e (8) garantem que o fluxo seja roteado através de *hubs* instalados. As restrições (9) garantem que os nós intermediários de cada caminho mínimo são *hubs* ativados e que cada rota passa por no máximo dois *hubs* intermediários. As restrições (10) a (12) estabelecem o domínio das variáveis de decisão.

Para linearizar a função objetivo, considere as variáveis auxiliares V^{ω} para representar $(C^{\omega} - \eta)_{+}$, para $\omega \in \Omega$. A formulação linearizada para o UMApHMP-CVaR é, portanto:

$$\begin{aligned}
 \min \quad & \eta + \frac{1}{1 - \beta} \sum_{\omega \in \Omega} \pi^{\omega} V^{\omega} \\
 \text{s. a} \quad & V^{\omega} \geq C^{\omega} - \eta, \quad \forall \omega \in \Omega \\
 & V^{\omega} \geq 0, \quad \forall \omega \in \Omega \\
 & (3) - (12).
 \end{aligned}$$

3. Descrição do Algoritmo Proposto

Esta seção descreve em detalhes o algoritmo proposto para solucionar o UMApHMP-CVaR, a partir da proposição apresentada para o caso determinístico introduzida em Pinto et al. [2023].

3.1. Representação da Solução e Avaliação da Função Objetivo

Uma solução para o UMApHMP-CVaR é representada por um vetor s de inteiros, tendo dimensão n , que é o número de nós da rede. As primeiras p posições indicam os *hubs* ativados e as demais posições os *hubs* inativos. Por exemplo, para $n = 7$ e $p = 3$, o vetor solução $s = [2, 4, 5, 7, 6, 1, 3]$ indica que os *hubs* 2, 4 e 5 estão ativados.

Este trabalho utiliza a versão do algoritmo de Floyd-Warshall descrita em de Carvalho [2017], para o cálculo do caminho mínimo para cada cenário. Este algoritmo garante apenas caminhos mínimos com até dois *hubs*, em que estes hubs são nós intermediários.

Assim, dada uma solução *hubs* s , para cada cenário $\omega \in \Omega$, o algoritmo recebe uma matriz chamada custo^{ω} , em que o custo do arco (i, i) no cenário ω é zero; para $i \neq j$, o custo no cenário ω entre $s[i]$ e $s[j]$ é $c_{s[i]s[j]}^{\omega}$, se $1 \leq i \leq p$ ou $1 \leq j \leq p$, enquanto que os demais arcos recebem

um valor correspondente a infinito. A saída é a matriz de custos mínimos CM^ω referente ao cenário ω . O pseudocódigo do algoritmo é apresentado no Algoritmo 1. O laço das linhas (1)-(10) calcula a matriz d , que representa o menor caminho de um *hub* até todos os nós, utilizando um *hub* como nó intermediário. Já no laço das linhas (11)-(20) é calculado e armazenado na matriz CM^ω o menor custo entre cada par de nós, avaliando a passagem por cada *hub*, tendo já sido calculado o menor caminho deste *hub* ao nó destino. Como, em geral, $p < n$, conclui-se que esse algoritmo é de complexidade $O(n^2p)$.

Algoritmo 1 Algoritmo de Caminho Mínimo

Entrada: $s, n, p, \omega, custo^\omega$

```

1: para  $k = 1, \dots, p$  faça
2:   para  $l = 1, \dots, n$  faça
3:      $d_{s[k],s[l]} = \infty$ 
4:     para  $m = 1, \dots, p$  faça
5:       se  $d_{s[k],s[l]} > \alpha * custo_{s[k],s[m]}^\omega + custo_{s[m],s[l]}^\omega$  então
6:          $d_{s[k],s[l]} = \alpha * custo_{s[k],s[m]}^\omega + custo_{s[m],s[l]}^\omega$ 
7:       fim se
8:     fim para
9:   fim para
10: fim para
11: para  $i = 1, \dots, n$  faça
12:   para  $j = 1, \dots, n$  faça
13:      $CM_{s[i],s[j]}^\omega = \infty$ 
14:     para  $k = 1, \dots, p$  faça
15:       se  $CM_{s[i],s[j]}^\omega > custo_{s[i],s[k]}^\omega + d_{s[k],s[j]}$  então
16:          $CM_{s[i],s[j]}^\omega \leftarrow custo_{s[i],s[k]}^\omega + d_{s[k],s[j]}$ 
17:       fim se
18:     fim para
19:   fim para
20: fim para
Saída:  $CM^\omega$ 

```

O custo total $C^\omega(s)$ associado à solução s no cenário $\omega \in \Omega$ é dado por

$$C^\omega(s) = \sum_{i,j=1}^n CM_{s[i],s[j]}^\omega \cdot w_{s[i],s[j]}^\omega.$$

O CVaR no nível β é, então, calculado, usando o procedimento proposto por Rockafellar e Uryasev [2002]. Os custos de todos os cenários são ordenados, de forma que $C^1 < C^2 < \dots < C^{|\Omega|}$, em que a probabilidade de C^k é igual a p_k . Seja k_β o único índice tal que $\sum_{k=1}^{k_\beta} p_k \geq \beta >$

$\sum_{k=1}^{k_\beta-1} p_k$. Então $CVaR_\beta(C)$ é dado por:

$$CVaR_\beta(C) = \frac{1}{1-\beta} \left(\left(\sum_{k=1}^{k_\beta} p_k - \beta \right) C^{k_\beta} + \sum_{k=k_\beta+1}^{|\Omega|} p_k C^k \right).$$

3.2. Construção da Solução Inicial

Será utilizado um procedimento de Construção Gulosa, enumerando-se os *hubs* em ordem crescente segundo os valores da função de avaliação $g(t) = \sum_{\omega \in \Omega} \sum_{j \in N} c_{tj}^{\omega} \cdot w_{tj}^{\omega}$. Esta função possibilita classificar os *hubs* melhor posicionados em relação a todos os demais, considerando a soma dos custos de transporte, sem considerar economia de escala, para todas as demandas originadas no nó em todos os cenários. Os p nós com menores valores são os *hubs* escolhidos.

3.3. Estrutura de Vizinhança e Busca Local

O procedimento de busca local proposto usa a troca sistemática de vizinhança, aplicando o movimento de troca de *hub*, que faz a troca de um nó *hub* com um nó não-*hub*. A Figura 1 apresenta um exemplo. Uma solução vizinha de $s = [2, 4, 5, 7, 6, 1, 3]$ é dada por $s' = [2, 6, 5, 7, 4, 1, 3]$, na qual o nó 4 deixa de ser *hub* e o nó 6 passa a ser *hub*.




Figura 1: Solução s e solução vizinha s' de s [Pinto et al., 2023].

A busca local recebe uma solução s e inteiros i e j , com $1 \leq i \leq p < j \leq n$, e realiza a troca dos nós nas posições i e j usando a função *movimento-troca-hub-naohub*(i, j, s). A busca local é realizada em toda a vizinhança da solução corrente s , via estratégia de descida baseada no critério de Melhor Vizinho, em que, uma vez identificada a melhor solução vizinha da solução corrente s , esta solução vizinha passa a ser a nova solução corrente, caso seja melhor que a solução corrente existente. Repete-se o procedimento de exploração da vizinhança a partir da nova solução, até que o melhor vizinho não seja melhor que a solução corrente. Assim, o método é encerrado quando um ótimo local é obtido.

3.4. Metaheurística Iterated Local Search (ILS)

A metaheurística *Iterated Local Search* (ILS) reúne intensificação com a exploração da região corrente através de busca local e diversificação com perturbações na solução ótima local corrente [Stützle, 1998; Lourenço et al., 2002].

Uma implementação do ILS para a solução do problema UMAPHMP-CVaR é apresentado no Algoritmo 2. Neste algoritmo, uma solução inicial s_0 é gerada (linha 1), sendo refinada com a estratégia de busca local do Melhor Vizinho (linha 2). No laço principal de repetição do algoritmo (linhas 4-14), que para após *IterMax* iterações sem melhora, efetua-se uma perturbação na solução corrente (na linha 6) e uma busca local na solução perturbada (linha 7), obtendo-se s'' . Caso a solução s'' tenha melhorado o valor de função de avaliação, ela passa a ser a solução corrente (linha 9), atualiza-se, então, a *MelhorIter* e o nível de perturbação retorna para 1. Não havendo melhora, aumenta-se em 1 unidade o nível de perturbação (linha 12). Este valor foi limitado a 70% de p para evitar um reinício aleatório da solução.

A perturbação de nível igual a k para o UMAPHMP-CVaR é baseada no procedimento de perturbação descrito em Pinto et al. [2023], que consiste na troca aleatória de k nós *hub* por k nós não *hub*. Como exemplo deste procedimento, considere a solução $s = [2, 4, 5, 7, 6, 1, 3]$, para $n = 7$ e $p = 3$. Uma perturbação de nível $k = 2$ de s pode gerar $s'' = [3, 6, 5, 7, 4, 1, 2]$.

Algoritmo 2 ILS - Iterated Local Search

Entrada: $f(\cdot), \mathcal{N}(\cdot), IterMax, s$

```

1:  $s_0 \leftarrow SolucaoInicial$ 
2:  $s \leftarrow BuscaLocal(s_0, f(\cdot), \mathcal{N}(\cdot))$ 
3:  $iter \leftarrow 0, MelhorIter \leftarrow iter, nível \leftarrow 1$ 
4: enquanto  $iter - MelhorIter < IterMax$  e  $nível < 0,7 \cdot p$  faça
5:    $iter \leftarrow iter + 1$ 
6:    $s' \leftarrow perturbacao(s, nível)$ 
7:    $s'' \leftarrow BuscaLocal(s')$ 
8:   se  $f(s'') < f(s)$  então
9:      $s \leftarrow s''$ 
10:     $MelhorIter \leftarrow iter, nível \leftarrow 1$ 
11:  senão
12:     $nível \leftarrow nível + 1$ 
13:  fim se
14: fim enquanto

Saída:  $s$ 

```

O procedimento de perturbação desmembra o vetor-solução s de tamanho n em dois vetores: (i) s_h , com as p primeiras posições; e (ii) s_{nh} , com as $n - p$ últimas posições. Em seguida, s_h e s_{nh} são embaralhados. Então, as k primeiras posições de s_h são trocadas pelas k primeiras posições de s_{nh} . Por fim, constrói-se a solução perturbada s' com as p primeiras posições de s_h e com as $n - p$ últimas vindas do vetor s_{nh} .

4. Experimentos Computacionais

Esta seção apresenta os resultados dos experimentos computacionais realizados e está organizada como segue. A Subseção 4.1 descreve os conjuntos de instâncias utilizados nos experimentos realizados. A Subseção 4.2 detalha o procedimento utilizado para a configuração dos parâmetros do algoritmo. A Subseção 4.3 mostra as tabelas com os resultados dos experimentos.

4.1. Instâncias da Literatura

Este trabalho utiliza os conjuntos de instâncias CAB (*Civil Aeronautics Board*), introduzido em O'Kelly [1987] e TR (*Turkish network*), retirados de Tan e Kara [2007] e Alumur et al. [2009] e cujas planilhas estão disponíveis em <http://ie.bilkent.edu.tr/~bkara/Turkish%20network.xls> para os experimentos computacionais. Os valores do fator de desconto utilizados para as instâncias CAB são $\alpha = 0,4$ e $\alpha = 0,8$. Para as instâncias TR, $\alpha = 0,9$ é o valor fornecido empiricamente por uma empresa de entrega de cargas que também utiliza o transporte rodoviário. Os demais parâmetros são baseados em Kargar e Mahmutoğulları [2022]. Para o nível de risco do CVaR, utiliza-se os fatores $\beta = 0,8$ e $\beta = 0,9$. Para a geração de cenários, dois níveis de variação para os custos e fluxos entre cada par de nós foram considerados. O nível *Low* gera valores de custo multiplicando valores gerados de forma aleatória no intervalo $[0,9; 1,1]$, com distribuição uniforme pelos valores nominais $\hat{c}_{ij}$. O nível *High* utiliza os intervalos $[0,5; 1,5]$. O mesmo procedimento gera as demandas para cada cenário. Foram geradas instâncias com 10, 25, 50 e 100 cenários. Os cenários em cada instância são equiprováveis.

Denota-se por CAB-High- m - p - α - β e TR-High- m - p - α - β as instâncias com m cenários gerados com nível de variação *High*, com p hubs a serem ativados, fator de desconto α e nível de risco β para o conjunto CAB e TR com 25 e 81 nós, respectivamente. Notação análoga vale para as instâncias geradas com variação *Low*.

Tabela 1: Resultados para as instâncias CAB com 25 nós e 10 cenários e 30 execuções do algoritmo ILS.

Instâncias	CPLEX			ILS		
	Valor Ótimo	Tempo (s)	hubs Ativados	gap(%)		Tempo(s)
				médio	maior	
CAB-High-10-3-0,4-0,8*	7142721699,8704	33646,6406	2, 12, 21	0,00	0,00	0,1723
CAB-High-10-3-0,4-0,9	7157152825,8273	32748,7188	2, 12, 21	0,00	0,00	0,1693
CAB-High-10-3-0,8-0,8	8021651732,0918	28282,0938	2, 12, 21	0,00	0,00	0,1891
CAB-High-10-3-0,8-0,9	8054040177,4383	31711,5156	2, 12, 21	0,00	0,00	0,1821
CAB-High-10-5-0,4-0,8	5679846408,6503	35067,7813	4, 7, 12, 14, 17	0,00	0,00	0,7010
CAB-High-10-5-0,4-0,9*	5694957552,2388	39725,7813	4, 7, 12, 14, 17	0,44	0,88	0,6147
CAB-High-10-5-0,8-0,8	6869468238,4973	37110,0625	2, 4, 12, 17, 21	0,00	0,00	0,6861
CAB-High-10-5-0,8-0,9	6900159728,0342	60080,8906	2, 4, 12, 17, 21	0,00	0,00	0,7682
CAB-Low-10-3-0,4-0,8	7429884685,4193	8484,5313	4, 12, 17	0,00	0,00	0,1833
CAB-Low-10-3-0,4-0,9	7452266363,0214	13768,3906	4, 12, 17	0,00	0,00	0,1741
CAB-Low-10-3-0,8-0,8*	8769382644,4520	14171,7500	12, 17, 21	0,00	0,00	0,1859
CAB-Low-10-3-0,8-0,9	8798042981,7231	15799,4375	12, 17, 21	0,00	0,00	0,1972
CAB-Low-10-5-0,4-0,8	5834877296,0666	2537,5469	4, 7, 12, 14, 17	0,00	0,00	0,6333
CAB-Low-10-5-0,4-0,9	5846189222,0822	3401,2188	4, 7, 12, 14, 17	0,00	0,00	0,6297
CAB-Low-10-5-0,8-0,8	7853346275,5738	11495,5781	1, 4, 7, 12, 17	0,00	0,00	0,6751
CAB-Low-10-5-0,8-0,9*	7862042184,7247	24269,8125	1, 4, 7, 12, 17	0,00	0,00	0,7188
Médias	—	24518,86	—	0,03	0,06	0,4300

O algoritmo ILS proposto foi implementado na linguagem C++ e, para a resolução do modelo matemático, foi utilizado o solver CPLEX 22.1.1, configurado com uma *thread* e demais configurações padrão, por meio da biblioteca *Concert Technology* usando a linguagem C++. As execuções se deram em um computador Intel(R) Core(TM) i7-11390HU, 3.40 GHz, com 16 GB de RAM e sistema operacional Windows 11.

4.2. Configurações dos Parâmetros do Algoritmo ILS aplicado ao UMApHMP-CVaR

A calibração do parâmetro *IterMax* a ser utilizado na execução do algoritmo implementado foi feita por meio do software IRACE (*Iterated Racing for Automatic Algorithm Configuration*, [López-Ibáñez et al., 2016]), com *budget* de número máximo de 5000 execuções e demais configurações *default*. Do conjunto de 96 instâncias, 20% delas foram selecionadas para o treinamento, com distribuição uniforme no conjunto de nós (CAB e TR), no número de cenários, tipos de perturbação - *High* e *Low*, nos valores de p , α e β . Elas são identificadas com o símbolo (*) junto ao nome da instância nas tabelas de resultados da próxima subseção. No arquivo de parâmetros, o intervalo de inteiros indicado para tal parâmetro foi $IterMax \in (1, 15)$. Após a execução, o IRACE retornou, como melhor configuração, $IterMax = 9$.

4.3. Resultados dos Experimentos

Para as instâncias com 10 cenários, todas as instâncias do tipo CAB foram resolvidas por meio do CPLEX e do ILS. Os resultados estão na Tabela 1, que apresenta os valores ótimos de função objetivo (FO) obtidos por meio do CPLEX, o tempo de execução do *solver* e os *hubs* ativados na solução ótima, bem como os tempos médios e *gaps* médios e maiores *gaps* encontrados nas 30 execuções do algoritmo ILS. Para o cálculo do *gap*, em valores percentuais, tem-se:

$$gap\ médio(\%) = \frac{\text{Valor médio} - \text{Valor da melhor solução encontrada}}{\text{Valor da melhor solução encontrada}} \times 100,$$

em que “Valor da melhor solução encontrada” é o valor de FO da solução ótima, quando fornecida pelo *solver*, ou da melhor solução encontrada pela heurística e, para calcular o *maior gap*, utiliza-se o Maior Valor Encontrado de função objetivo em vez do Valor Médio.

Nas 30 execuções do algoritmo ILS com as instâncias CAB para 10 cenários, apenas na instância CAB-High-10-5-0,4-0,9 o valor ótimo não foi atingido para algumas execuções. Porém,

este resultado apresenta poucos ótimos locais que não eram soluções ótimas e, além disso, relativamente próximos ao ótimo global. Os tempos médios de execução do CPLEX e da heurística foram de 24518,86 segundos e 0,43 segundos, respectivamente. O tempo do CPLEX é de aproximadamente 57 mil vezes o tempo da heurística.

Para as instâncias CAB com 25 cenários, testes preliminares mostraram que o CPLEX, com um tempo limite de 36 horas, não chega a encontrar a solução ótima, apresentando *gap* de otimalidade em torno de 7%. Da mesma forma, para as instâncias TR com 10 cenários, testes preliminares mostraram que um tempo limite de 24 horas no CPLEX não produz sequer uma solução viável. Para 25 cenários, o CPLEX tem uma parada prematura por falta de memória. Assim, para estas instâncias, optou-se por apresentar apenas os resultados encontrados pela metaheurística ILS. As Tabelas 2 e 3 mostra os valores da melhor solução encontrada nas 30 execuções e os *hubs* nela ativados, bem como os tempos médios encontrados nas 30 execuções do algoritmo ILS para as instâncias CAB e para as instâncias TR, respectivamente. Os *gaps* foram calculados tendo como referência a melhor solução encontrada pela heurística.

Os resultados mostram que o tempo de resolução destas instâncias é baixo, mesmo para instância com 81 nós e 100 cenários. O maior valor de tempo médio encontrado foi para a instância TR-High-100-10-0,9-0,9, que foi igual a 2437,5513 segundos. Além disso, a heurística apresenta uma grande estabilidade, já que os *gaps* médios e maior são iguais a zero na maioria dos casos e, nos casos em que estes *gaps* são estritamente positivos, eles são muito próximos de zero.

Foi realizada uma análise estatística a fim de avaliar se há diferença nas distribuições dos tempos de execução e dos *gaps* nas 30 execuções do ILS em relação ao nível de incerteza (variação) nos dados e ao nível de risco β . Foi considerado um nível de significância de 5%. O teste de Normalidade de Shapiro-Wilk [Montgomery, 2009] rejeitou a normalidade dos tempos e dos *gaps*. Assim, aplicou-se o teste de Wilcoxon [Montgomery, 2009]. O resultado do teste mostra que não há evidências suficientes para concluir que há diferença entre as medianas dos tempo de execução dos dois níveis de variação. O teste de Wilcoxon não pareado para o conjunto dos *gaps médios* indica diferença significativa no conjunto dos *gaps*. Isto indica que uma maior amplitude na variação dos dados acarreta uma maior variabilidade nos ótimos locais encontrados pela heurística.

Considerando agora os grupos das instâncias com nível de risco $\beta = 0,8$ e $\beta = 0,9$, o Teste de Wilcoxon aponta que não há evidências suficientes para concluir que a diferença entre as medianas dos tempo de execução e dos *gaps* nos dois grupos. Isto sugere que o fator de risco β não impacta no tempo de execução, nem na qualidade das soluções apresentadas.

Todos os códigos e as instâncias utilizadas nos experimentos deste trabalho estão disponíveis no repositório <https://github.com/AldoVieiraPinto/SBPO2024/>.

5. Considerações Finais

Este artigo apresentou uma formulação do problema UMApHMP sob incertezas com aversão ao risco por meio da medida CVaR.

Os resultados dos experimentos computacionais da aplicação da metaheurística ILS ao problema UMApHMP-CVaR com instâncias dos conjuntos CAB e TR e da implementação do modelo no CPLEX mostram que essa metaheurística apresentou um bom desempenho em relação à obtenção da solução ótima ou de soluções com valor de função objetivo bem próximo do valor ótimo, com tempo computacional muito inferior ao do solver CPLEX, nos casos em que o número de nós é pequeno e há poucos cenários. Quando considera-se instâncias com maior número de nós ou um maior número de cenários, o CPLEX apresenta tempo computacional muito grande ou término de execução por falta memória. Assim, a heurística ILS possibilita, nestes casos, obter soluções com pouca variabilidade em tempo computacional viável.

Tabela 2: Resultados para as instâncias CAB com 25 nós e 25, 50 e 100 cenários e 30 execuções do algoritmo ILS.

Instâncias	Melhor Solução encontrada		ILS		Tempo(s)
	Valor de Função Objetivo	hubs Ativados	gap(%)		
			médio	maior	
CAB-High-25-3-0,4-0,8	7364999032,1838	4, 12, 18	0,00	0,00	0,5021
CAB-High-25-3-0,4-0,9	7425341381,5543	4, 12, 18	0,00	0,00	0,5417
CAB-High-25-3-0,8-0,8	8429707526,5227	4, 19, 25	0,35	0,44	0,4366
CAB-High-25-3-0,8-0,9 *	8459471809,7622	4, 19, 25	0,45	0,54	0,4634
CAB-High-25-5-0,4-0,8	5741488030,0913	4, 7, 12, 14, 17	0,00	0,00	1,9715
CAB-High-25-5-0,4-0,9	5788887933,9308	4, 7, 12, 14, 17	0,00	0,00	1,9786
CAB-High-25-5-0,8-0,8 *	7009318083,1933	4, 7, 12, 17, 20	0,00	0,00	1,9952
CAB-High-25-5-0,8-0,9	7043644255,7197	4, 7, 12, 17, 20	0,00	0,00	2,0736
CAB-Low-25-3-0,4-0,8	7412638526,7188	4, 12, 17	0,00	0,00	0,4918
CAB-Low-25-3-0,4-0,9 *	7426147875,4452	4, 12, 17	0,00	0,00	0,5141
CAB-Low-25-3-0,8-0,8	8766992155,9516	12, 17, 21	0,01	0,07	0,5120
CAB-Low-25-3-0,8-0,9	8780815692,6111	4, 12, 17	0,00	0,00	0,5363
CAB-Low-25-5-0,4-0,8 *	5820266764,8663	4, 7, 12, 14, 17	0,00	0,00	1,7716
CAB-Low-25-5-0,4-0,9	5831253481,5233	4, 7, 12, 14, 17	0,00	0,00	1,7690
CAB-Low-25-5-0,8-0,8	7795761671,0368	4, 7, 12, 17, 24	0,00	0,00	2,0010
CAB-Low-25-5-0,8-0,9	7815454273,1330	4, 7, 12, 17, 24	0,00	0,00	2,0213
CAB-High-50-3-0,4-0,8	7344848237,1391	4, 12, 17	0,00	0,00	0,9429
CAB-High-50-3-0,4-0,9	7460490996,5075	4, 12, 17	0,00	0,00	0,9827
CAB-High-50-3-0,8-0,8 *	8433391899,2629	5, 12, 17	0,03	0,31	0,9486
CAB-High-50-3-0,8-0,9	8544757318,1525	5, 12, 17	0,45	0,54	0,8855
CAB-High-50-5-0,4-0,8	5718387615,2861	4, 7, 12, 14, 17	0,00	0,00	3,5240
CAB-High-50-5-0,4-0,9	5818041887,2294	4, 7, 12, 14, 17	0,00	0,00	3,6873
CAB-High-50-5-0,8-0,8	7164035749,0535	4, 5, 10, 12, 17	0,03	0,31	3,5277
CAB-High-50-5-0,8-0,9 *	7216509910,6530	4, 5, 12, 13, 17	0,00	0,00	3,4299
CAB-Low-50-3-0,4-0,8 *	7408293624,8819	4, 12, 17	0,00	0,00	0,8911
CAB-Low-50-3-0,4-0,9	7427088884,9087	4, 12, 17	0,00	0,00	0,9129
CAB-Low-50-3-0,8-0,8	8764615760,3191	4, 12, 17	0,00	0,00	1,0947
CAB-Low-50-3-0,8-0,9	8777569547,5397	4, 12, 17	0,00	0,00	1,1167
CAB-Low-50-5-0,4-0,8	5822498325,3671	4, 7, 12, 14, 17	0,00	0,00	3,3036
CAB-Low-50-5-0,4-0,9 *	5833379691,1637	4, 7, 12, 14, 17	0,00	0,00	3,2615
CAB-Low-50-5-0,8-0,8	7823323678,5269	1, 4, 7, 12, 17	0,00	0,00	3,5975
CAB-Low-50-5-0,8-0,9	7843041193,4410	4, 7, 12, 14, 17	0,00	0,00	3,7588
CAB-High-100-3-0,4-0,8	7467610212,7822	4, 12, 18	0,00	0,00	1,9884
CAB-High-100-3-0,4-0,9 *	7601512800,0350	4, 12, 18	0,05	0,12	1,9302
CAB-High-100-3-0,8-0,8	8539116452,9026	4, 12, 18	0,00	0,00	2,2245
CAB-High-100-3-0,8-0,9	8659944827,5700	4, 12, 18	0,00	0,00	2,7786
CAB-High-100-5-0,4-0,8 *	5806822051,0368	4, 7, 12, 14, 17	0,00	0,00	7,2382
CAB-High-100-5-0,4-0,9	5917820157,6955	4, 7, 12, 14, 17	0,00	0,00	6,5363
CAB-High-100-5-0,8-0,8	7177644451,2339	2, 4, 12, 13, 17	0,00	0,00	7,1011
CAB-High-100-5-0,8-0,9	7269701721,9312	2, 4, 12, 13, 17	0,00	0,00	8,4475
CAB-Low-100-3-0,4-0,8	7435856726,8723	4, 12, 17	0,00	0,00	1,8040
CAB-Low-100-3-0,4-0,9	7462752324,1028	4, 12, 17	0,00	0,00	1,9306
CAB-Low-100-3-0,8-0,8	8800978138,0687	4, 12, 17	0,00	0,00	2,2083
CAB-Low-100-3-0,8-0,9 *	8833373099,9504	4, 12, 17	0,00	0,00	2,0293
CAB-Low-100-5-0,4-0,8	5846149910,5646	4, 7, 12, 14, 17	0,00	0,00	6,6140
CAB-Low-100-5-0,4-0,9	5868681703,7721	4, 7, 12, 14, 17	0,00	0,00	6,6651
CAB-Low-100-5-0,8-0,8 *	7846804262,5392	4, 7, 12, 17, 24	0,00	0,00	7,2240
CAB-Low-100-5-0,8-0,9	7868209649,7360	4, 7, 12, 17, 24	0,00	0,00	7,3320
Médias	—	—	0,0187	0,0308	2,6977

Para trabalhos posteriores, sugere-se investigar com mais profundidade o desempenho do método em instâncias de maior dimensão, bem como buscar outras alternativas de construção inicial e ainda outras variantes do ILS, como o *Smart* ILS. Além disso, sugere-se verificar o desempenho da heurística para outras medidas avessas ao risco, como o *Mean-CVaR* ou medidas neutras ao risco, como o valor esperado.

Tabela 3: Resultados para as instâncias TR com 81 nós e 10, 25, 50 e 100 cenários e 30 execuções do algoritmo ILS.

Instâncias	Melhor Solução encontrada		ILS	
	Valor de Função Objetivo	hubs Ativados	gap(%) médio maior	Tempo(s)
TR-High-10-6-0,9-0,8	42756753010,8267	3, 23, 41, 50, 71, 80	0,0247 0,0824	57,3101
TR-High-10-6-0,9-0,9	42790768682,1028	3, 23, 41, 50, 71, 80	0,1328 0,8690	61,0841
TR-High-10-10-0,9-0,8	38122937362,9351	1, 3, 12, 27, 35, 38, 41, 52, 54, 71	0,0418 0,4179	259,4213
TR-High-10-10-0,9-0,9 *	38224760775,8398	1, 3, 12, 27, 35, 38, 41, 52, 54, 71	0,1058 0,9608	265,8248
TR-Low-10-6-0,9-0,8 *	50473829690,6649	1, 6, 21, 34, 60, 64	0,00 0,00	56,5364
TR-Low-10-6-0,9-0,9	50503082495,1490	1, 6, 21, 34, 60, 64	0,0120 0,0299	52,6274
TR-Low-10-10-0,9-0,8	47833297278,5627	1, 3, 6, 21, 25, 34, 38, 45, 54, 55	0,00 0,00	222,2833
TR-Low-10-10-0,9-0,9	47833688092,6350	1, 3, 6, 21, 25, 34, 38, 45, 54, 55	0,00 0,00	225,0140
TR-High-25-6-0,9-0,8	43334395821,2413	1, 3, 6, 21, 41, 58	0,00 0,00	137,1533
TR-High-25-6-0,9-0,9	43721240829,9588	3, 6, 21, 41, 58, 68	0,00 0,00	160,7389
TR-High-25-10-0,9-0,8	38663909155,6310	3, 6, 21, 34, 41, 45, 54, 58, 68, 80	0,0123 0,0760	602,4594
TR-High-25-10-0,9-0,9 *	38727418903,1851	3, 6, 21, 34, 41, 45, 54, 58, 68, 80	0,0332 0,2727	604,8594
TR-Low-25-6-0,9-0,8	50466737465,9871	1, 6, 21, 35, 41, 60	0,00 0,00	152,7393
TR-Low-25-6-0,9-0,9 *	50487429200,4976	1, 6, 21, 35, 41, 60	0,00 0,00	148,9618
TR-Low-25-10-0,9-0,8	47918575870,7784	1, 3, 6, 21, 25, 34, 35, 38, 41, 52	0,00 0,00	594,6453
TR-Low-25-10-0,9-0,9	47930098640,9519	1, 3, 6, 21, 25, 34, 35, 38, 41, 52	0,00 0,00	581,7376
TR-High-50-6-0,9-0,8	43611648656,9693	1, 3, 6, 21, 41, 71	0,00 0,00	341,2284
TR-High-50-6-0,9-0,9 *	43851239545,2178	1, 3, 6, 21, 41, 71	0,00 0,00	326,1991
TR-High-50-10-0,9-0,8	38660803741,2439	1, 3, 6, 12, 27, 41, 45, 54, 60, 71	0,00 0,00	1231,1099
TR-High-50-10-0,9-0,9	38814971581,4429	1, 3, 6, 12, 27, 28, 41, 45, 54, 71	0,00 0,00	1164,2330
TR-Low-50-6-0,9-0,8	50426208750,5236	1, 6, 21, 41, 45, 60	0,00 0,00	257,9643
TR-Low-50-6-0,9-0,9	50491059283,1653	1, 6, 21, 41, 45, 60	0,00 0,00	263,9948
TR-Low-50-10-0,9-0,8 *	47934045143,1780	1, 3, 6, 21, 25, 34, 35, 38, 41, 52	0,0096 0,1441	1122,5188
TR-Low-50-10-0,9-0,9	47988733867,1522	1, 3, 6, 21, 25, 34, 35, 38, 41, 52	0,00 0,00	1104,2473
TR-High-100-6-0,9-0,8 *	43602880533,8333	1, 3, 6, 21, 41, 60	0,0183 0,1375	601,3585
TR-High-100-6-0,9-0,9	43951316054,7818	1, 3, 21, 38, 41, 71	0,0442 0,2082	574,7417
TR-High-100-10-0,9-0,8	38780558016,0968	1, 3, 6, 21, 41, 45, 46, 54, 60, 71	0,00 0,00	2373,2094
TR-High-100-10-0,9-0,9	39069173992,6133	1, 3, 6, 21, 41, 45, 46, 52, 54, 71	0,00 0,00	2437,5513
TR-Low-100-6-0,9-0,8	50568739900,5727	1, 6, 21, 41, 45, 60	0,00 0,00	573,3325
TR-Low-100-6-0,9-0,9	50646739362,7879	1, 6, 21, 41, 45, 58	0,00 0,00	562,1144
TR-Low-100-10-0,9-0,8	48018868552,5908	1, 3, 6, 21, 25, 34, 35, 38, 41, 55	0,0041 0,0071	2330,3952
TR-Low-100-10-0,9-0,9 *	48068297211,5641	1, 3, 6, 21, 25, 34, 38, 41, 45, 55	0,00 0,00	2389,2448
Médias	—	—	0,0137 0,1002	682,4012

Agradecimentos

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq, processo 409785/2023-7), à Fundação de Apoio à Pesquisa do Estado de Minas Gerais (FAPEMIG, processo APQ-00417-21), ao Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG) e ao Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais (IFMG) pelo apoio ao desenvolvimento deste trabalho.

Referências

- Alem, D. e Morabito, R. (2015). Planejamento da produção sob incerteza: programação estocástica versus otimização robusta. *Gestão & Produção*, 22:539–551.
- Alumur, S. A., Kara, B. Y., e Karasan, O. E. (2009). The design of single allocation incomplete hub networks. *Transportation Research Part B: Methodological*, 43:936–951.
- Alumur, S., Nickel, S., e da Gama, F. S. (2012). Hub location under uncertainty. *Transportation Research Part B: Methodological*, 46:529–543.
- Contreras, I., Cordeau, J.-F., e Laporte, G. (2011). Stochastic uncapacitated hub location. *European Journal of Operational Research*, 212(3):518–528.
- de Carvalho, R. (2017). *Heurísticas Paralelas aplicadas a problemas de alocação de concentradores*. Tese de doutorado, Universidade Federal de Minas Gerais.

- Ernst, A. e Krishnamoorthy, M. (1998). Exact and heuristic algorithms for the uncapacitated multiple allocation p-hub median problem. *European Journal Operational Research*, 104:100–112.
- Farahani, R. Z., Hekmatfar, M., Arabani, A. B., e Nikbakhsh, E. (2013). Hub location problems: A review of models, classification, solution techniques, and applications. *Computers & Industrial Engineering*, 64:1096–1109.
- Ghaffarinasab, N., Çavuş, Ö., e Kara, B. Y. (2023). A mean-cvar approach to the risk-averse single allocation hub location problem with flow-dependent economies of scale. *Transportation Research Part B: Methodological*, 167:32–53.
- Kargar, K. e Mahmutogullari, A. (2022). Risk-averse hub location: Formulation and solution approach. *Computers & Operations Research*, 1443.
- López-Ibáñez, M., Dubois-Lacoste, J., Cáceres, L. P., Birattari, M., e Stützle, T. (2016). The IRACE package: Iterated racing for automatic algorithm configuration. *Operations Research Perspectives*, 3:43–58.
- Lourenço, H., Martin, O., e Stützle, T. (2002). Iterated local search. In Glover, F. e Kochenberger, G., editors, *Handbook of Metaheuristics*, p. 43–58. International Series in Operations Research & Management Science.
- Marianov, V. e Serra, D. (2003). Location models for airline hubs behaving as m/d/c queues. *Computers & Operations Research*, 30(7):983–1003.
- Montgomery, D. C. (2009). *Design and Analysis of Experiments*. John Wiley & Sons, 7 th edition.
- O’Kelly, M. (1987). A quadratic integer program for the location of interacting hub facilities. *European Journal of Operational Research*, 32:393–404.
- Ozbay, E., Çavuş, Ö., e Kara, B. (2019). Shelter site location under multi-hazard scenarios. *Computers & Operations Research*, 106:102–118.
- Paç, A. B. e Pınar, M. Ç. (2014). Robust portfolio choice with cvar and var under distribution and mean return ambiguity. *Transactions in Operations Research*, 22(3):875–891.
- Pinto, A. V., Martins de Sá, E., e de Souza, S. R. (2023). Metaheurística *Smart* ils aplicada ao problema de localização de p concentradores com alocação múltiplas. *Anais do LV Simpósio Brasileiro de Pesquisa Operacional*, 55.
- Rockafellar, T. e Uryasev, S. (2002). Conditional value-at-risk for general loss distributions. *Journal of Banking & Finance*, 26(7):1443–1471.
- Shapiro, A., Dentcheva, D., e Ruszczyński, A. (2009). *Lectures on Stochastic Programming*. Society for Industrial and Applied Mathematics. URL <https://epubs.siam.org/doi/abs/10.1137/1.9780898718751>.
- Stützle, T. (1998). *Local Search Algorithms for Combinatorial Problems: Analysis, Improvements, and New Applications*. Phd thesis, Darmstadt University of Technology.
- Tan, P. Z. e Kara, B. Y. (2007). A hub covering model for cargo delivery systems. *Networks: An International Journal*, 49(1):28–39.
- Yang, T.-H. (2009). Stochastic air freight hub location and flight routes planning. *Applied Mathematical Modelling*, 33(12):4424–4430.