



Universidade Federal
de Ouro Preto

**Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Departamento de Computação e Sistemas**

**Aplicações de Técnicas
Meta-heurísticas na Otimização de
Rotas para Coleta de Resíduos Sólidos**

Hudson Vitor Oliveira Silva

**TRABALHO DE
CONCLUSÃO DE CURSO**

**ORIENTAÇÃO:
Samuel Souza Brito**

**Julho, 2026
João Monlevade—MG**

Hudson Vitor Oliveira Silva

**Aplicações de Técnicas Meta-heurísticas na
Otimização de Rotas para Coleta de Resíduos
Sólidos**

Orientador: Samuel Souza Brito

Monografia apresentada ao curso de Engenharia de Computação do Instituto de Ciências Exatas e Aplicadas, da Universidade Federal de Ouro Preto, como requisito parcial para aprovação na Disciplina “Trabalho de Conclusão de Curso II”.

Universidade Federal de Ouro Preto

João Monlevade

Julho de 2026

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

S586a Silva, Hudson Vitor Oliveira.

Aplicações de técnicas meta-heurísticas na otimização de rotas para coleta de resíduos sólidos. [manuscrito] / Hudson Vitor Oliveira Silva. Hudson Vitor Oliveira Silva. - 2026.

61 f.

Orientador: Prof. Dr. Samuel Souza Brito.

Monografia (Bacharelado). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia de Computação .

1. Gestão integrada de resíduos sólidos - Rotas. 2. GRASP (Sistema operacional de computador). 3. Metaheurísticas. 4. Otimização matemática - Rotas. 5. Problema de roteamento de veículos - Coleta de lixo. 6. Recozimento simulado (Matemática). I. Silva, Hudson Vitor Oliveira. II. Brito, Samuel Souza. III. Universidade Federal de Ouro Preto. IV. Título.

CDU 519.85:628.4

Bibliotecário(a) Responsável: Flavia Reis - CRB6/2431



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE OURO PRETO
REITORIA
INSTITUTO DE CIÊNCIAS EXATAS E APLICADAS
DEPARTAMENTO DE COMPUTAÇÃO E SISTEMAS



FOLHA DE APROVAÇÃO

Hudson Vitor Oliveira Silva

Aplicações de Técnicas Meta-heurísticas na Otimização de Rotas para Coleta de Resíduos Sólidos

Monografia apresentada ao Curso de Engenharia de Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Engenharia de Computação

Aprovada em 30 de julho de 2026

Membros da banca

Dr. Samuel Souza Brito - Orientador - Universidade Federal de Ouro Preto
Dr. Matheus Nohra Haddad - Avaliador - Universidade Federal de Ouro Preto
Dr. Roberto Gomes Ribeiro - Avaliador - Universidade Federal de Ouro Preto

Samuel Souza Brito, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 19/08/2026.



Documento assinado eletronicamente por **Samuel Souza Brito, PROFESSOR DE MAGISTERIO SUPERIOR**, em 19/08/2026, às 14:15, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1168873** e o código CRC **2D67480A**.

Dedico este trabalho à minha família e aos meus amigos, pelo apoio, incentivo e presença constantes ao longo de toda a caminhada.

Agradecimentos

Agradeço, em primeiro lugar, à minha família, pelo apoio incondicional, pela paciência e por acreditar em mim mesmo nos momentos mais difíceis. Em especial, aos meus pais, Adriana Miranda Oliveira Silva e Wellington Vitor Silva, pelo incentivo diário, pela dedicação e por sempre terem sido minha base. À minha irmã, Júlia Miranda Oliveira Silva, pelo carinho, companheirismo e apoio ao longo de toda essa caminhada.

Aos meus amigos, deixo meu agradecimento pela parceria, pelas conversas e pelo encorajamento durante todo o processo. Cada palavra de apoio, cada troca de ideias e cada momento de descontração contribuíram para que essa etapa fosse mais leve e possível.

Agradeço também ao meu orientador, Samuel Souza Brito, pela disponibilidade, pela orientação cuidadosa e pelas contribuições técnicas que direcionaram este estudo. Sua condução ao longo do desenvolvimento do trabalho foi essencial para a organização das etapas e para a qualidade do resultado final.

Por fim, agradeço a todos que, direta ou indiretamente, contribuíram para que este trabalho se concretizasse, seja com apoio, sugestões ou compreensão durante o período de dedicação a esta etapa.

Resumo

O presente trabalho aborda o problema de planejamento de rotas para coleta de resíduos sólidos domiciliares em João Monlevade–MG, formulando-o como um Problema de Roteamento em Arcos Capacitados (PRAC/CARP). Para isso, a malha viária é representada como um grafo, obtido a partir de recursos geoespaciais, e organizada em instâncias de análise compatíveis com a estrutura adotada no estudo utilizado como referência. A demanda de coleta é incorporada ao modelo por meio de uma estratégia de atribuição ao longo da rede, viabilizando a execução dos métodos propostos. A solução do problema é conduzida por meio do GRASP (*Greedy Randomized Adaptive Search Procedure*) como estratégia construtiva, associado a procedimentos de busca local, incluindo trocas entre trechos de coleta e a meta-heurística *Simulated Annealing*. Os resultados obtidos permitiram comparar as abordagens em termos de distância total percorrida e tempo de processamento, indicando que a configuração proposta alcançou redução de até 2,89% na distância total em relação ao estudo de referência, sendo até 20.582,13 vezes mais rápida no tempo de execução.

Palavras-chave: PRAC. CARP. coleta de resíduos sólidos. otimização de rotas. meta-heurísticas. GRASP. *Simulated Annealing*.

Abstract

This work addresses the problem of planning routes for household solid waste collection in João Monlevade–MG, formulating it as a Capacitated Arc Routing Problem (CARP). To this end, the road network is represented as a graph, obtained from geospatial resources, and organized into analysis instances compatible with the structure adopted in the reference study. Collection demand is incorporated into the model through an assignment strategy along the network, enabling the execution of the proposed methods. The solution is conducted using GRASP (*Greedy Randomized Adaptive Search Procedure*) as a constructive strategy, associated with local improvement procedures, including swaps between collection segments and the *Simulated Annealing* metaheuristic. The obtained results allowed the comparison of the approaches in terms of total traveled distance and processing time, indicating that the proposed configuration achieved a reduction of up to 2.89% in total distance compared to the reference study, in addition to being up to 20,582.13 times faster in terms of execution time.

Keywords: CARP. household solid waste collection. route optimization. metaheuristics. GRASP. *Simulated Annealing*.

Lista de ilustrações

Figura 1 – Exemplo de grafo não direcionado.	16
Figura 2 – Exemplo de grafo dirigido (dígrafo).	17
Figura 3 – Exemplo de grafo ponderado.	17
Figura 4 – Representação esquemática do Problema de Roteamento em Arcos Capacitados.	19
Figura 5 – Divisão de regiões para coleta em João Monlevade–MG.	25
Figura 6 – Distribuição espacial dos vértices do grafo viário e setorização em sete instâncias.	26
Figura 7 – Exemplo de solução gerada pelo GRASP para a instância gp1, gerando apenas uma rota representada em verde no mapa.	36
Figura 8 – Distância total nas melhores configurações por método de busca local utilizando Floyd-Warshall.	40
Figura 9 – Tempo de execução nas melhores configurações por método de busca local utilizando Floyd-Warshall.	40
Figura 10 – Comparação de tempo de execução (Dijkstra vs FW) – Configurações de melhor tempo.	42
Figura 11 – Comparação de tempo de execução (Dijkstra vs FW) – Configurações de melhor qualidade.	42

Lista de tabelas

Tabela 1 – Divisão dos bairros por grupo, conforme setorização adotada no estudo de referência.	27
Tabela 2 – Parâmetros avaliados na calibração dos algoritmos.	38
Tabela 3 – Melhores configurações obtidas por busca local na calibração com Floyd–Warshall.	39
Tabela 4 – Resultados agregados com Dijkstra versus Floyd–Warshall.	41
Tabela 5 – Resultados das heurísticas aplicadas ao mapa completo unificado para as configurações de melhor tempo.	43
Tabela 6 – Resultados das heurísticas aplicadas ao mapa completo unificado para as configurações de melhor qualidade.	43
Tabela 7 – Comparação entre a abordagem proposta e o estudo de referência no mapa simplificado.	44
Tabela 8 – Resultados consolidados de todos os experimentos executados.	51

Lista de abreviaturas e siglas

CARP	<i>Capacitated Arc Routing Problem</i>
gp	Grupo
GRASP	<i>Greedy Randomized Adaptive Search Procedure</i>
MG	Minas Gerais
ODbL	<i>Open Database License</i> (licença do OpenStreetMap)
OSM	<i>OpenStreetMap</i>
OSMnx	<i>OpenStreetMap NetworkX</i> (biblioteca para análise de redes urbanas)
PNRS	Política Nacional de Resíduos Sólidos
PR	Problema de Roteirização
PRAC	Problema de Roteamento em Arcos Capacitados
PRV	Problema de Roteirização de Veículos
RCL	<i>Restricted Candidate List</i>
SA	<i>Simulated Annealing</i>
UFOP	Universidade Federal de Ouro Preto

Sumário

1	INTRODUÇÃO	13
1.1	Problema	13
1.2	Objetivos	14
1.3	Justificativa	14
1.4	Estrutura do trabalho	15
2	REVISÃO DE LITERATURA	16
2.1	Conceitos básicos de grafos	16
2.2	Problemas de roteamento em redes	17
2.3	Problema de Roteamento em Arcos Capacitados	18
2.4	Abordagens de solução	20
2.5	Trabalhos relacionados	21
3	DESENVOLVIMENTO	24
3.1	Preparação das instâncias	24
3.1.1	Obtenção da malha viária	24
3.1.2	Setorização e geração das instâncias	25
3.1.3	Atribuição de demandas aos trechos da rede	27
3.2	Métodos de solução	29
3.2.1	Estrutura da solução	29
3.2.2	Abordagem construtiva baseada em GRASP	29
3.2.3	GRASP construtivo com conexão por caminhos mínimos	30
3.2.4	Estratégias para obtenção dos caminhos mínimos	31
3.2.5	Busca local baseada em trocas	32
3.2.6	<i>Simulated Annealing</i>	34
3.2.7	Visualização das rotas geradas	35
4	EXPERIMENTOS E RESULTADOS	37
4.1	Ambiente computacional	37
4.2	Calibração dos parâmetros	37
4.3	Dijkstra versus Floyd–Warshall	40
4.4	Resultados na malha viária unificada	42
4.5	Comparação com o estudo de referência	44
4.6	Síntese	45
5	CONCLUSÃO	46

REFERÊNCIAS	48
APÊNDICES	50
APÊNDICE A – TABELA CONSOLIDADA DOS EXPERIMENTOS	51

1 Introdução

A coleta de resíduos sólidos domiciliares é um serviço essencial nas cidades e envolve custos operacionais relevantes, especialmente nas atividades de coleta e transporte. No Brasil, a Política Nacional de Resíduos Sólidos (Lei nº 12.305/2010) reforça a responsabilidade dos municípios na gestão e destinação adequada dos resíduos urbanos, o que torna a busca por maior eficiência um aspecto importante para a administração pública.

Nesse contexto, técnicas de otimização aplicadas ao planejamento de rotas surgem como uma alternativa para reduzir deslocamentos desnecessários e contribuir para o melhor uso de recursos. Este trabalho tem como referência o estudo de [Carvalho \(2017\)](#), desenvolvido para o município de João Monlevade–MG, que também abordou a otimização das rotas de coleta de resíduos sólidos domiciliares. A partir dessa base, o presente trabalho analisa o problema sob a perspectiva do Problema de Roteamento em Arcos Capacitados (PRAC/CARP), buscando avaliar o potencial de melhorias operacionais por meio da construção de instâncias, aplicação de métodos heurísticos e meta-heurísticos e comparação quantitativa dos resultados obtidos.

1.1 Problema

O planejamento de rotas para a coleta de resíduos sólidos domiciliares envolve decisões operacionais que impactam diretamente o percurso percorrido pelos veículos e o esforço necessário para atender uma região. Em um cenário ideal, o atendimento ocorreria com mínima repetição de trechos e sem deslocamentos desnecessários; entretanto, limitações práticas, como restrições operacionais e a própria configuração da malha urbana, tornam esse objetivo difícil de ser atingido de forma perfeita.

Diante disso, o problema pode ser entendido como um problema de otimização de roteamento, no qual se busca reduzir o custo total do serviço (por exemplo, a distância percorrida), garantindo que o atendimento seja realizado de forma completa e respeitando restrições relevantes. No caso da coleta domiciliar, em particular, a demanda está ligada ao atendimento de trechos da rede viária, o que motiva sua formulação em modelos de roteamento compatíveis com esse tipo de estrutura.

1.2 Objetivos

O objetivo geral deste trabalho é utilizar estratégias de otimização para o planejamento de rotas de coleta de resíduos sólidos domiciliares em João Monlevade–MG, buscando reduzir a distância total percorrida e respeitar restrições operacionais, como a capacidade dos veículos. Para isso, o cenário é estruturado a partir de uma representação em grafo da malha viária, de modo a permitir a aplicação e a avaliação comparativa de métodos de solução.

Como objetivos específicos, destacam-se:

- estruturar uma representação da malha viária do município a partir de recursos geoespaciais, utilizando dados do *OpenStreetMap* com apoio da biblioteca *OSMnx* da linguagem de programação Python;
- organizar o cenário em instâncias de análise compatíveis com a setorização por bairros adotada no trabalho de [Carvalho \(2017\)](#), permitindo comparações sob condições semelhantes;
- avaliar a capacidade de escala dos métodos propostos ao planejar rotas otimizadas diretamente para o grafo completo unificado do município, sem a utilização de subdivisões territoriais em setores de coleta;
- incorporar a demanda de coleta ao longo da rede por meio de uma estratégia de atribuição aos trechos viários, de modo a viabilizar experimentos sistemáticos;
- implementar algoritmos heurísticos e meta-heurísticas para construção de soluções de roteamento, considerando tanto trechos atendidos (coleta) quanto deslocamentos necessários;
- aplicar procedimentos de busca local sobre as soluções geradas, avaliando o impacto dessas etapas no custo final das rotas;
- comparar os resultados obtidos em termos de custo total e tempo de execução, considerando diferentes parametrizações e estabelecendo uma comparação com o trabalho de [Carvalho \(2017\)](#).

1.3 Justificativa

A ausência de planejamento ou o planejamento limitado das rotas de coleta tende a gerar aumento de custos operacionais, uma vez que trajetos maiores implicam maior consumo de combustível, maior tempo de operação e maior utilização dos veículos. Assim, a aplicação de técnicas de otimização se justifica como uma alternativa para apoiar decisões mais eficientes na execução do serviço.

Além do aspecto econômico, a redução de percursos desnecessários pode gerar efeitos indiretos associados à operação, como diminuição do tempo de serviço e menor esforço acumulado ao longo das rotas. Também é importante destacar que a discussão e aplicação de métodos de roteamento extrapolam o contexto específico da coleta de resíduos, sendo relevantes em atividades similares, como varrição, entregas e outras operações urbanas que dependem de deslocamentos sistemáticos em rede.

1.4 Estrutura do trabalho

O trabalho está organizado da seguinte forma. No Capítulo 2 é apresentada a fundamentação teórica necessária, incluindo conceitos relacionados ao problema de roteamento e às técnicas utilizadas. No Capítulo 3 é descrita a metodologia adotada, bem como a forma de construção das instâncias e as abordagens consideradas. No Capítulo 4 são apresentados os experimentos realizados e os resultados obtidos. Por fim, no Capítulo 5 são discutidas as conclusões do estudo e possíveis direções para trabalhos futuros.

2 Revisão de Literatura

Este capítulo apresenta os principais conceitos teóricos necessários para o desenvolvimento do trabalho. Inicialmente, são abordados conceitos básicos de grafos, utilizados para representar a malha viária e os trechos de coleta. Em seguida, são discutidos problemas de roteamento em redes, com ênfase no Problema de Roteamento em Arcos Capacitados (PRAC/CARP), além de abordagens heurísticas e meta-heurísticas empregadas na solução desse tipo de problema. Por fim, são apresentados trabalhos relacionados que servem de base para a formulação e comparação dos resultados obtidos neste estudo.

2.1 Conceitos básicos de grafos

A teoria dos grafos fornece a base formal para representar redes e relações entre elementos. Um grafo pode ser definido como $G = (V, E)$, em que V é o conjunto de vértices (nós) e E é o conjunto de arestas (ligações) (NETTO, 2012). A Figura 1 apresenta um exemplo de grafo não direcionado, no qual as ligações entre os vértices não possuem sentido definido.




Figura 1 – Exemplo de grafo não direcionado.

Em aplicações urbanas, como malhas viárias, os vértices podem representar interseções e pontos relevantes da rede, enquanto as arestas representam trechos de via. Quando há orientação, utiliza-se um grafo dirigido (dígrafo), no qual cada ligação possui um sentido; caso contrário, utiliza-se um grafo não direcionado (LUCCHESI, 2006). A Figura 2 ilustra um exemplo de grafo dirigido, em que as setas indicam o sentido permitido de deslocamento entre os vértices.




Figura 2 – Exemplo de grafo dirigido (dígrafo).

Em muitos problemas práticos, as arestas são associadas a um custo, formando um grafo ponderado. No contexto de roteamento, esse custo pode representar distância, tempo ou esforço operacional (NETTO, 2012). A Figura 3 apresenta um exemplo de grafo ponderado, no qual os valores associados às ligações representam os custos de deslocamento. A noção de caminho entre dois vértices e o cálculo de caminhos mínimos são conceitos centrais para conectar deslocamentos na rede e avaliar o custo total de uma rota (DIJKSTRA, 1959).




Figura 3 – Exemplo de grafo ponderado.

2.2 Problemas de roteamento em redes

Problemas de roteamento constituem uma classe de problemas de otimização combinatória voltada à definição de percursos eficientes em grafos. Entre os modelos clássicos, destacam-se o Problema do Caixeiro Viajante e o Problema do Carteiro Chinês, frequentemente utilizados como referência para variações aplicadas a serviços urbanos (LAPORTE, 1991).

A literatura também distingue problemas em que a demanda está associada aos vértices (pontos) e problemas em que a demanda está associada às arestas/arcos (trechos). Essa distinção é relevante, pois aplicações como varrição, coleta de resíduos e inspeções em vias são naturalmente descritas por demandas distribuídas ao longo da rede, motivando o uso de modelos de roteamento em arcos (GOLDBARG; GOLDBARG; LUNA, 2015).

2.3 Problema de Roteamento em Arcos Capacitados

Quando o atendimento ocorre em trechos da rede e há restrições operacionais, como capacidade limitada de veículos, obtém-se o Problema de Roteamento em Arcos Capacitados (PRAC), conhecido na literatura como *Capacitated Arc Routing Problem* (GOLDEN; WONG, 1981). De forma geral, considera-se um conjunto de arcos requeridos, com demanda positiva a ser atendida, e um custo associado a cada deslocamento. O objetivo é construir um conjunto de rotas que atenda todos os arcos requeridos, respeitando restrições, em especial a capacidade do veículo, e minimizando o custo total.

Para formalizar o PRAC clássico da literatura, seja $G = (V, E)$ um grafo não direcionado que representa a rede viária, em que $V = \{1, 2, \dots, n\}$ é o conjunto de vértices e o vértice 1 representa o depósito central. Seja $E_R \subseteq E$ o conjunto de arcos requeridos que possuem demanda de coleta $q_{ij} > 0$ para cada $(i, j) \in E_R$. O custo de percorrer a aresta (i, j) é dado por $c_{ij} > 0$. Considera-se uma frota de K veículos homogêneos de capacidade W . As variáveis de decisão propostas por Golden e Wong (1981) são definidas por:

- $x_{ij}^p \geq 0$: número de vezes que o veículo $p \in \{1, \dots, K\}$ percorre a aresta $(i, j) \in E$ em deslocamento (sem realizar serviço de coleta, também denominado *deadheading*);
- $y_{ij}^p \in \{0, 1\}$: igual a 1 se o veículo $p \in \{1, \dots, K\}$ realiza o serviço de coleta na aresta $(i, j) \in E_R$, e 0 caso contrário.

O modelo matemático é formulado como se segue:

$$\text{Minimizar } \sum_{p=1}^K \sum_{(i,j) \in E} c_{ij} (x_{ij}^p + y_{ij}^p) \quad (2.1)$$

sujeito a:

$$\sum_{p=1}^K (y_{ij}^p + y_{ji}^p) = 1 \quad \forall (i, j) \in E_R \quad (2.2)$$

$$\sum_{j=1}^n (x_{ij}^p + y_{ij}^p) - \sum_{j=1}^n (x_{ji}^p + y_{ji}^p) = 0 \quad \forall i \in V, p = 1, \dots, K \quad (2.3)$$

$$\sum_{(i,j) \in E_R} q_{ij} y_{ij}^p \leq W \quad \forall p = 1, \dots, K \quad (2.4)$$

$$x_{ij}^p \geq 0, \quad y_{ij}^p \in \{0, 1\} \quad \forall (i, j) \in E, p = 1, \dots, K \quad (2.5)$$

A função objetivo (2.1) busca minimizar o custo total de deslocamento de toda a frota, somando os custos das arestas percorridas em coleta (y_{ij}^p) e em deslocamento vazio (x_{ij}^p). A restrição (2.3) representa a conservação de fluxo para cada vértice e veículo: a

quantidade de vezes que o veículo p entra em um vértice deve ser igual à de vezes que ele sai. Na formulação clássica, essa restrição de fluxo garante que qualquer rota iniciada no depósito retorne obrigatoriamente a ele. Dessa forma, o custo de retorno ao depósito ao final da coleta (quando a capacidade limite W é atingida) é incorporado automaticamente na função objetivo através das variáveis de deslocamento vazio x_{ij}^p . Por fim, a restrição (2.4) assegura que a capacidade de carga W de cada veículo não seja violada.

A Figura 4 apresenta uma representação esquemática do PRAC. Nessa representação, alguns arcos da rede possuem demanda de atendimento, enquanto outros podem ser utilizados apenas como deslocamento para conectar os trechos requeridos. Assim, a solução deve definir rotas que cubram todos os arcos com demanda, sem ultrapassar a capacidade do veículo. Como exemplo, as setas coloridas na Figura 4 ilustram uma solução viável composta por duas rotas de coleta distintas (indicadas em azul e verde). A rota representada em azul atende a um subconjunto de trechos requeridos na parte superior e direita do grafo (com demandas de 8, 7, 6, 10 e 5), enquanto a rota verde atende aos demais trechos de coleta da parte inferior (com demandas de 6, 6 e 8). Ambas as rotas utilizam trechos sem demanda (arestas cinzas, com $q = 0$) para realizar deslocamentos intermediários e fechar o circuito de retorno, garantindo que a soma das demandas atendidas por cada veículo não exceda a capacidade limite.




Figura 4 – Representação esquemática do Problema de Roteamento em Arcos Capacitados.

A formulação do PRAC é amplamente utilizada para representar cenários reais de serviços urbanos. No caso da coleta de resíduos sólidos domiciliares, por exemplo, os trechos de rua podem ser entendidos como unidades de atendimento, e a capacidade do veículo impõe limites ao quanto pode ser coletado antes de encerrar ou reiniciar a operação (CARVALHO, 2017).

Além disso, o PRAC é considerado um problema de difícil resolução computacional.

Segundo [Golden e Wong \(1981\)](#), o problema pertence à classe dos problemas NP-difíceis, o que significa que não são conhecidos algoritmos eficientes, em tempo polinomial, capazes de resolver todas as instâncias de forma exata. Dessa forma, à medida que o tamanho da rede aumenta, a busca por soluções ótimas tende a se tornar computacionalmente custosa, justificando o uso de métodos heurísticos e meta-heurísticos para obter boas soluções em tempo viável.

2.4 Abordagens de solução

Problemas de roteamento, especialmente em instâncias realistas, tendem a apresentar elevada complexidade combinatória. Por esse motivo, diferentes estratégias de solução são discutidas na literatura, variando entre métodos exatos, heurísticas e meta-heurísticas.

Os métodos exatos, como formulações de Programação Inteira, buscam encontrar soluções ótimas para o problema, isto é, soluções que minimizam a função objetivo respeitando todas as restrições definidas no modelo. Embora sejam importantes por fornecerem garantias de otimalidade, esses métodos podem se tornar computacionalmente custosos em instâncias grandes, devido ao crescimento do número de combinações possíveis ([LAPORTE, 1991](#)). No trabalho de [Carvalho \(2017\)](#), por exemplo, a abordagem exata foi aplicada ao problema de coleta de resíduos em João Monlevade–MG, porém apresentou elevado tempo de processamento para a instância considerada.

As heurísticas, por sua vez, são métodos desenvolvidos para encontrar boas soluções em tempo computacional viável, sem necessariamente garantir que a solução obtida seja ótima. Em geral, essas estratégias utilizam regras práticas de construção ou escolha, buscando reduzir o esforço de enumeração das possibilidades. Dessa forma, tornam-se adequadas para problemas de grande porte ou para situações em que o tempo de resposta é um fator relevante ([GOLDBARG; GOLDBARG; LUNA, 2015](#)).

As meta-heurísticas correspondem a estratégias mais gerais de busca, capazes de orientar a exploração do espaço de soluções de forma mais flexível. Diferentemente de uma heurística específica, uma meta-heurística pode ser adaptada para diferentes problemas de otimização, combinando mecanismos como aleatoriedade controlada, busca local, aceitação probabilística de soluções e refinamento iterativo ([GOLDBARG; GOLDBARG; LUNA, 2015](#)).

Entre as meta-heurísticas aplicadas a problemas de roteamento, destacam-se o GRASP e o *Simulated Annealing*. O GRASP, sigla para *Greedy Randomized Adaptive Search Procedure*, é uma meta-heurística composta, em geral, por uma fase construtiva e uma fase de busca local. Na fase construtiva, a solução é formada progressivamente por meio de escolhas parcialmente gulosas e parcialmente aleatórias, geralmente controladas por uma lista restrita de candidatos. Em seguida, procedimentos de busca local podem ser

aplicados para refinar a solução obtida (FEO; RESENDE, 1995).

O *Simulated Annealing*, por sua vez, é uma meta-heurística inspirada no processo físico de recozimento de metais. No contexto de otimização, o método permite aceitar, ocasionalmente, soluções piores durante a busca, com o objetivo de escapar de mínimos locais. Essa aceitação é controlada por uma temperatura, que diminui progressivamente ao longo da execução, tornando o método mais seletivo nas etapas finais (KIRKPATRICK; GELATT; VECCHI, 1983).

Neste trabalho, essas abordagens são utilizadas de forma complementar: o GRASP é empregado na construção inicial das rotas, enquanto estratégias de busca local, incluindo trocas entre trechos de coleta e *Simulated Annealing*, são aplicadas para buscar reduções no custo total das soluções.

2.5 Trabalhos relacionados

A otimização de rotas de coleta de resíduos sólidos urbanos tem sido estudada a partir de diferentes formulações de problemas de roteamento e localização. De modo geral, esses trabalhos buscam reduzir distâncias percorridas, custos operacionais e tempo de execução, considerando características práticas do serviço, como localização de pontos de coleta, capacidade dos veículos, atendimento de vias e estrutura da malha urbana. A seguir, são apresentados trabalhos relacionados em ordem cronológica, destacando o problema tratado, a abordagem utilizada e os principais resultados obtidos.

Barão (2008) estudou a aplicação de problemas de localização e roteamento na otimização da coleta de resíduos sólidos urbanos no município de Passo Fundo-RS. O trabalho teve como foco a coleta seletiva e buscou definir a localização eficiente de postos de entrega voluntária de materiais recicláveis, bem como uma rota para coleta desses resíduos e destinação ao aterro sanitário municipal. Para isso, foram utilizados o problema das p -medianas, para localização dos pontos de coleta, e o Problema do Caixeiro Viajante, para determinação da rota de coleta. Os modelos foram implementados no software Lingo, e os resultados indicaram uma metodologia reprodutível, aplicável tanto à inserção de novos pontos de coleta quanto a outras áreas urbanas.

Batista e Scarpin (2015) trataram o Problema de Roteamento em Arcos Capacitado e Periódico (PCARP) em um contexto real de inspeção e manutenção ferroviária. Embora o estudo não esteja diretamente voltado à coleta de resíduos, ele é relevante por explorar uma variação do roteamento em arcos capacitado, em que os trechos da rede possuem demandas periódicas a serem atendidas ao longo de um horizonte de tempo. O problema foi modelado por meio de programação linear binária, considerando veículos com capacidade de atendimento e periodicidades distintas para os arcos. Os autores obtiveram uma solução satisfatória para o cenário estudado, com atendimento das demandas por meio

de movimentação sincronizada dos veículos. Esse trabalho reforça a aplicabilidade dos problemas de roteamento em arcos em serviços que exigem atendimento de trechos de uma rede, característica também presente na coleta de resíduos.

Vecchi (2016) desenvolveu um estudo voltado diretamente à otimização de rotas dos caminhões de coleta de resíduos sólidos urbanos. O trabalho propôs duas abordagens principais. A primeira utilizou um modelo de Programação Linear Inteira Mista associado ao Problema de Roteamento de Veículos (PRV), tratando a coleta como um problema de roteamento em nós. A segunda abordagem foi sequencial e composta por três fases: agrupamento dos arcos por meio de um modelo adaptado do problema das p -medianas, aplicação de um modelo para o Problema de Roteamento em Arcos Capacitados (CARP) e obtenção dos roteiros por meio de um algoritmo adaptado de Hierholzer. As abordagens foram aplicadas a dados reais de uma cidade brasileira de médio porte. Os resultados indicaram redução aproximada de 32% na distância total percorrida na abordagem baseada em PRV, além de reduções de 1,5% para coleta indiferenciada e 7,5% para coleta seletiva na abordagem sequencial. O estudo também avaliou ganhos ambientais, considerando a redução de emissões de poluentes associada às rotas otimizadas.

Oliveira, Silva e Silva (2017) apresentaram um estudo de caso sobre a otimização da rota de coleta de resíduos sólidos domiciliares em Santo Antônio de Leverger-MT. O objetivo foi minimizar a distância total percorrida pelo veículo coletor em uma área do perímetro urbano do município. Para isso, os autores utilizaram o Problema do Carteiro Chinês Não Direcionado (PCCND), com etapas de reconhecimento da área de estudo, mapeamento da rede, cadastramento dos vértices, coleta de dados geográficos e aplicação do modelo. A implementação foi realizada com apoio do Excel, VBA e OpenSolver. Como resultado, a rota otimizada apresentou distância de 20.172,36 m, enquanto a rota atual possuía 27.212,04 m, correspondendo a uma redução de aproximadamente 25% na distância total percorrida. Esse trabalho evidencia a utilidade de modelos de roteamento em arcos em contextos municipais e mostra ganhos expressivos mesmo em estudos de menor porte.

Carvalho (2017) desenvolveu o estudo utilizado como principal referência neste trabalho, aplicado ao planejamento de rotas de coleta de resíduos sólidos domiciliares em João Monlevade-MG. O autor modelou o problema a partir da representação da região estudada como um grafo não direcionado, considerando as vias como de mão dupla, e aplicou tanto uma abordagem exata quanto uma abordagem heurística construtiva para obter soluções aproximadas. O estudo também apresentou a divisão do município em regiões de coleta, utilizada neste trabalho como base para a geração das instâncias gp1 a gp7. Além disso, Carvalho (2017) estimou a demanda de resíduos por logradouro a partir da extensão das ruas, do número médio de pessoas por domicílio e da quantidade média de lixo produzida por habitante por dia. Dessa forma, o presente trabalho se baseia diretamente nessa pesquisa, preservando a setorização territorial para fins de comparação, mas propõe

avanços na construção automatizada da malha viária, na atribuição proporcional de demandas, no uso de GRASP combinado a caminhos mínimos pré-processados por Floyd–Warshall e na aplicação de procedimentos de busca local, incluindo *Simulated Annealing*.

De forma geral, os trabalhos analisados indicam que a coleta de resíduos sólidos urbanos pode ser modelada por diferentes problemas de otimização, como PRV, PCC, PCCND, PRAC/CARP e variações periódicas de roteamento em arcos. Observa-se também que, em aplicações reais, métodos exatos podem apresentar limitações computacionais conforme o tamanho das instâncias aumenta, o que motiva o uso de heurísticas e meta-heurísticas. Nesse contexto, o presente trabalho se aproxima especialmente de [Carvalho \(2017\)](#), por tratar o mesmo município e utilizar sua setorização como referência, mas diferencia-se ao automatizar a obtenção da rede viária, empregar caminhos mínimos pré-processados e avaliar diferentes estratégias de melhoria sobre soluções construídas por GRASP.

3 Desenvolvimento

Este capítulo descreve os procedimentos adotados para estruturar as instâncias do problema e as abordagens utilizadas para obtenção de soluções. Inicialmente, apresenta-se a obtenção da malha viária e a setorização em instâncias compatíveis com o estudo de referência. Em seguida, descreve-se a estratégia utilizada para atribuir demanda aos trechos da rede. Por fim, são detalhados os métodos heurísticos e meta-heurísticos empregados, incluindo a etapa construtiva e os procedimentos de busca local.

3.1 Preparação das instâncias

Esta seção apresenta as etapas utilizadas para transformar a malha viária de João Monlevade–MG em instâncias adequadas à aplicação dos métodos de roteamento. Inicialmente, descreve-se a obtenção da rede viária a partir de dados geoespaciais. Em seguida, apresenta-se a setorização adotada para manter comparabilidade com o trabalho de [Carvalho \(2017\)](#). Por fim, detalha-se a estratégia utilizada para atribuir demanda aos trechos da rede, permitindo a formulação do problema como um Problema de Roteamento em Arcos Capacitados.

3.1.1 Obtenção da malha viária

A malha viária do município de João Monlevade–MG foi obtida a partir de dados disponibilizados pelo *OpenStreetMap* ([OpenStreetMap contributors, 2024](#)), disponível para consulta em ([SILVA, 2026](#)). A extração e estruturação da rede em forma de grafo foram realizadas com apoio da biblioteca *OSMnx*, disponível na linguagem de programação Python e voltada à obtenção, modelagem e análise de redes urbanas a partir de dados geoespaciais ([BOEING, 2025](#)).

Nessa representação, os vértices correspondem principalmente a interseções e extremidades de ruas, enquanto as arestas representam trechos viários que conectam esses vértices. A cada aresta é associado um custo, considerado neste trabalho como o comprimento do trecho.

Os dados do *OpenStreetMap*, utilizados por meio da biblioteca *OSMnx*, disponibilizam informações sobre a estrutura da via, incluindo atributos relacionados ao sentido de circulação quando disponíveis. Entretanto, neste trabalho, para fins de deslocamento, a malha viária foi modelada como um grafo não direcionado, permitindo que os caminhos mínimos fossem calculados considerando os trechos como percorráveis nos dois sentidos. Essa escolha mantém compatibilidade com o estudo de [Carvalho \(2017\)](#), que também

considerou as vias como de mão dupla. Na implementação, os trechos percorridos são diferenciados entre coleta e deslocamento, de modo que apenas os trechos com demanda positiva são contabilizados como atendimento.

Essa etapa representa um diferencial em relação ao trabalho de [Carvalho \(2017\)](#), no qual a construção da instância foi realizada manualmente, com marcação de pontos nos cruzamentos e finais de ruas por meio do Google Maps e posterior medição das distâncias entre pontos adjacentes no Google Earth. No presente trabalho, a obtenção da malha é automatizada a partir de dados geoespaciais, reduzindo o esforço manual de construção da rede e facilitando a atualização ou replicação do processo.

3.1.2 Setorização e geração das instâncias

Com o objetivo de manter comparabilidade com o estudo utilizado como referência ([CARVALHO, 2017](#)) e de viabilizar experimentos por regiões, a rede viária foi particionada em sete instâncias, denotadas por gp1 a gp7. Essa divisão foi definida a partir da setorização de coleta apresentada por [Carvalho \(2017\)](#), a qual foi originalmente estabelecida pela empresa responsável pela coleta de resíduos sólidos do município, organizando o município de João Monlevade-MG em regiões associadas aos bairros atendidos pelo serviço de coleta.

A Figura 5 apresenta a divisão de regiões de coleta utilizada no estudo de referência. Essa setorização serviu como base para a geração das instâncias deste trabalho, preservando a coerência do recorte territorial e permitindo que os resultados obtidos fossem comparados com o cenário anteriormente estudado.




Figura 5 – Divisão de regiões para coleta em João Monlevade-MG.

Fonte: Adaptado de [Carvalho \(2017\)](#).

A partir dessa divisão, os vértices extraídos da malha viária foram associados aos grupos conforme o bairro ao qual pertencem. Em seguida, as arestas foram filtradas de modo que cada instância mantivesse apenas os trechos cujos vértices de origem e destino pertencem ao mesmo grupo. Assim, foram geradas sete instâncias independentes, correspondentes aos grupos **gp1** a **gp7**. Adicionalmente, além das sete instâncias setorizadas, foi mantida uma representação contendo o grafo unificado de todo o município (sem subdivisão territorial), denominada **mapa completo**, para fins de avaliação da escalabilidade dos algoritmos sob um cenário de planejamento de rotas integrado e global.

A Figura 6 ilustra a distribuição espacial dos vértices do grafo gerado neste trabalho e a separação por grupos. A Tabela 1 apresenta a composição de cada grupo em termos de bairros associados.




Figura 6 – Distribuição espacial dos vértices do grafo viário e setorialização em sete instâncias.

Tabela 1 – Divisão dos bairros por grupo, conforme setorização adotada no estudo de referência.

Grupo	Bairros
gp1	Ponte Funda; Nova Cachoeirinha; Recanto Paraíso; Vale da Serra; Rosário; Vale do Sol; Mangabeiras; José Elói; São João; São Benedito; Castelo; Ipiranga; Industrial; Campo Alegre; Boa Vista; Cidade Nova; JK.
gp2	Nova Aclimação; Paineiras; Sion; Campos Elísios; Terminal Rodoviário; Poso Marfim; Posto 5 Estrelas; Chácara Burian; Tanquinho; Tanquinho II; Centro Industrial; Tiete; Pedreira; Santa Cruz; Amazonas; Jacui; Serra do Egito.
gp3	Novo Horizonte; Aclimação; República; Lourdes; Alvorada; Nossa Senhora da Conceição; Nova Esperança.
gp4	Lucília; São José; Promorar; São Geraldo; Satélite; José de Alencar; Loanda; Miramar; Ernestina Graciana; Alto do Loanda; Serra.
gp5	Santo Hipólito; Teresópolis; Cruzeiro Celeste; Petrópolis; Nova Monlevade; Novo Cruzeiro; Santa Cecília; Estrela Dalva; Primeiro de Maio; Monte Sagrado; Corumbiara de Vanessa; ABM; Palmares; Jardim Vitória; Vera Cruz; Feixos.
gp6	João Cândido Dias; Laranjeiras; Metalúrgico; Belmonte; Bau; Vila Tanque; Areia Preta.
gp7	Carneirinhos; Avenida Getúlio Vargas; Avenida Wilson Alvarenga; Pinheiros; Santa Bárbara; São Jorge; Monte Santo; Entorno da Prefeitura.

3.1.3 Atribuição de demandas aos trechos da rede

Para viabilizar a formulação do problema como PRAC, cada aresta deve possuir, além do custo associado ao comprimento, uma demanda de coleta. Como não se dispõe, neste trabalho, de dados empíricos de geração de resíduos por rua ou por bairro, adotou-se uma estratégia de atribuição proporcional ao comprimento dos trechos viários, baseada em uma estimativa agregada de geração diária total de resíduos do município.

Para estimar essa geração diária total, utilizou-se a população de João Monlevade–MG informada pelo IBGE no Censo Demográfico de 2022, correspondente a 80.187 habitantes ([Instituto Brasileiro de Geografia e Estatística, 2022](#)). Para a taxa de geração per capita, adotou-se o valor de 0,84 kg/hab.dia, com base no indicador de massa média per capita de resíduos sólidos domiciliares coletados apresentado pelo SINISA, ano de referência 2024 ([Brasil. Ministério das Cidades, 2025](#)).

A estratégia adotada parte da hipótese de que a demanda de coleta pode ser distribuída linearmente ao longo da malha viária considerada. Dessa forma, trechos mais longos recebem uma parcela proporcionalmente maior da demanda, enquanto trechos menores recebem uma parcela menor. Essa abordagem é uma aproximação utilizada para construir instâncias completas do problema, permitindo a execução e comparação dos métodos propostos.

Sejam:

- H a população considerada do município (habitantes);
- r a taxa de geração per capita de resíduos (kg/hab/dia);
- R a geração diária total estimada do município (kg/dia);
- E_g o conjunto de arestas da instância (grupo) $g \in \{gp1, \dots, gp7\}$;
- ℓ_e o comprimento da aresta $e \in E_g$ (m);
- L o comprimento total da rede considerada, somando todas as instâncias (m);
- δ a densidade linear média de resíduos na rede (kg/m/dia);
- q_e a demanda atribuída à aresta e (kg/dia).

A geração diária total de resíduos do município é estimada por:

$$R = H \cdot r. \quad (3.1)$$

Substituindo os valores adotados neste trabalho, tem-se:

$$R = 80.187 \cdot 0,84 = 67.357,08 \text{ kg/dia}. \quad (3.2)$$

Em seguida, calcula-se o comprimento total da rede considerada, somando os comprimentos das arestas de todas as instâncias:

$$L = \sum_{g \in \{gp1, \dots, gp7\}} \sum_{e \in E_g} \ell_e. \quad (3.3)$$

Com base nesse comprimento total, define-se uma densidade linear média única para toda a rede:

$$\delta = \frac{R}{L}. \quad (3.4)$$

Por fim, a demanda atribuída a cada aresta $e \in E_g$ é dada por:

$$q_e = \ell_e \cdot \delta. \quad (3.5)$$

Essa estratégia garante que a geração diária total estimada para o município seja distribuída proporcionalmente entre todos os trechos da rede, independentemente do grupo ao qual pertencem. Assim, a soma das demandas atribuídas às arestas de todas as instâncias preserva a estimativa agregada inicial:

$$\sum_{g \in \{gp1, \dots, gp7\}} \sum_{e \in E_g} q_e = R. \quad (3.6)$$

Dessa forma, cada grupo mantém uma parcela da demanda total proporcional à extensão de sua própria rede viária. Com isso, evitam-se duplicações da geração total entre as instâncias e obtêm-se arquivos de entrada com custo e demanda associados às arestas, adequados para a aplicação dos algoritmos de roteamento.

3.2 Métodos de solução

A obtenção das soluções é conduzida por uma abordagem baseada em GRASP (*Greedy Randomized Adaptive Search Procedure*), utilizada na etapa construtiva das rotas, combinada com procedimentos de busca local. Após a construção inicial, são aplicadas estratégias baseadas em trocas entre trechos de coleta e, em algumas configurações, a meta-heurística *Simulated Annealing*, com o objetivo de reduzir o custo total das rotas. Em ambos os casos, as soluções são descritas como um conjunto de rotas, sendo cada rota uma sequência de trechos da malha viária. Cada trecho é classificado como *coleta*, quando corresponde a um arco requerido, ou *deslocamento*, quando representa apenas movimentação do veículo na rede para conectar trechos de coleta.

3.2.1 Estrutura da solução

A solução é composta por um conjunto de rotas $\mathcal{S} = \{R_1, R_2, \dots, R_m\}$, em que cada rota R_k é uma sequência de triplas (u, v, t) , sendo u e v vértices do grafo e $t \in \{\text{coleta}, \text{deslocamento}\}$. A carga total de uma rota é determinada pela soma das demandas associadas aos trechos marcados como *coleta*, respeitando a capacidade máxima do veículo.

A função objetivo da abordagem heurística proposta neste trabalho consiste em minimizar o custo total de deslocamento de todas as rotas geradas, sendo o custo de uma rota R_k definido pela soma das distâncias de seus trechos constitutivos:

$$C(R_k) = \sum_{(u,v,t) \in R_k} c_{uv} \quad (3.7)$$

em que c_{uv} é o comprimento do trecho entre os vértices u e v . Cabe ressaltar que, diferentemente da formulação clássica do PRAC apresentada no Capítulo 2 (a qual exige o início e o fim obrigatórios em um depósito central fixo), o algoritmo heurístico deste trabalho gera rotas abertas focadas na cobertura contínua dos arcos requeridos. Assim, cada rota R_k inicia-se no primeiro arco selecionado para coleta e encerra-se no último arco atendido antes que a capacidade W seja atingida, sem que seja adicionado um deslocamento final de retorno a um depósito físico.

3.2.2 Abordagem construtiva baseada em GRASP

A etapa construtiva adota uma estratégia inspirada no GRASP, combinando escolhas gulosas com aleatoriedade controlada por um parâmetro α (FEO; RESENDE,

1995). Em cada iteração, as rotas são construídas selecionando arcos requeridos viáveis, priorizando a continuidade do atendimento sempre que possível e inserindo deslocamentos na rede quando necessário para conectar trechos de coleta.

3.2.3 GRASP construtivo com conexão por caminhos mínimos

A etapa construtiva do algoritmo é baseada no GRASP, utilizando uma Lista Restrita de Candidatos (RCL) controlada pelo parâmetro α . A solução é construída iterativamente a partir do conjunto de arcos requeridos, isto é, trechos da rede que possuem demanda de coleta associada. Em cada rota, o algoritmo seleciona arcos viáveis respeitando a capacidade do veículo. Quando não existe arco requerido viável saindo diretamente do vértice atual, é necessário conectar a posição atual do veículo ao início de outro arco requerido ainda não atendido. Essa conexão é feita por meio de um caminho mínimo na rede, inserido na rota como deslocamento.

Neste trabalho, a obtenção desses caminhos mínimos foi avaliada de duas formas. Na primeira, os caminhos são calculados sob demanda por meio do algoritmo de Dijkstra, a partir do vértice atual, sempre que uma conexão é necessária. Na segunda, utiliza-se o algoritmo de Floyd–Warshall em uma etapa de pré-processamento, gerando matrizes de distância e de reconstrução de caminhos. Assim, durante a construção e a melhoria das rotas, os caminhos mínimos podem ser recuperados diretamente dessas estruturas, reduzindo o custo das consultas repetidas.

O Algoritmo 1 apresenta a estrutura geral do GRASP construtivo utilizado. A operação CAMINHOMINIMO representa a obtenção do menor caminho entre dois vértices, podendo ser implementada tanto por Dijkstra quanto por consulta às matrizes pré-processadas de Floyd–Warshall.

Algoritmo 1: Fase construtiva do GRASP com conexão por caminhos mínimos

Entrada: Grafo G ; arcos requeridos $\mathcal{R}$ com demanda $q(\cdot)$; capacidade W ;
parâmetro α

Saída: Conjunto de rotas $\mathcal{S}$

```

1  $\mathcal{S} \leftarrow \emptyset$ ;
2  $\mathcal{R}_{rem} \leftarrow \mathcal{R}$ ;
3 while  $\mathcal{R}_{rem} \neq \emptyset$  do
4    $route \leftarrow \emptyset$ ;
5    $load \leftarrow 0$ ;
6   Selecionar um arco inicial viável de  $\mathcal{R}_{rem}$  por meio da RCL( $\alpha$ );
7   Adicionar o arco selecionado a  $route$  como coleta;
8   Atualizar  $load$  e remover o arco de  $\mathcal{R}_{rem}$ ;
9    $atual \leftarrow destino(arco)$ ;
10  while verdadeiro do
11     $VZ \leftarrow \{(atual \rightarrow v) \in \mathcal{R}_{rem} \mid load + q(atual \rightarrow v) \leq W\}$ ;
12    if  $VZ \neq \emptyset$  then
13      Selecionar um arco de  $VZ$  por meio da RCL( $\alpha$ );
14      Adicionar o arco selecionado a  $route$  como coleta;
15      Atualizar  $load$ ,  $atual$  e  $\mathcal{R}_{rem}$ ;
16    else
17      Selecionar  $r^* \in \mathcal{R}_{rem}$  viável que minimize a distância entre  $atual$  e
         $origem(r^*)$ ;
18      if não existe  $r^*$  viável then
19        parar;
20       $P \leftarrow \text{CAMINHOMINIMO}(G, atual, origem(r^*))$ ;
21      if  $P$  não existe then
22        parar;
23      Inserir as arestas de  $P$  em  $route$  como deslocamento;
24      Inserir  $r^*$  em  $route$  como coleta;
25      Atualizar  $load$ ,  $atual$  e remover  $r^*$  de  $\mathcal{R}_{rem}$ ;
26  Adicionar  $(route, load)$  em  $\mathcal{S}$ ;
27 return  $\mathcal{S}$ ;

```

3.2.4 Estratégias para obtenção dos caminhos mínimos

A principal diferença entre as duas versões implementadas está na forma de executar a operação CAMINHOMINIMO, utilizada sempre que é necessário conectar o vértice atual ao início de outro arco requerido ainda não atendido.

Na versão baseada em Dijkstra, o caminho mínimo é calculado sob demanda. Assim, sempre que o algoritmo precisa escolher um próximo arco requerido não adjacente ao vértice atual, executa-se Dijkstra a partir do vértice corrente para obter as distâncias até os demais vértices da rede. Em seguida, seleciona-se o arco requerido viável cujo vértice de origem esteja mais próximo. O caminho encontrado é reconstruído e inserido na rota como deslocamento. Essa abordagem evita o pré-processamento inicial, mas apresenta complexidade de tempo de $\mathcal{O}(|E| + |V| \log |V|)$ utilizando uma fila de prioridades baseada em *heap* binário (em que $|V|$ representa o número de vértices e $|E|$ o número de arestas do grafo). Como esse custo é incorrido a cada necessidade de conexão, a abordagem pode se tornar custosa quando há muitas consultas a caminhos mínimos, especialmente durante os procedimentos de busca local.

Na versão baseada em Floyd–Warshall, os menores caminhos entre todos os pares de vértices são calculados previamente. Esse pré-processamento gera uma matriz de distâncias, utilizada para consultar rapidamente o custo entre dois vértices, e uma matriz de reconstrução de caminhos, utilizada para recuperar a sequência de vértices do menor caminho. Dessa forma, durante a construção das rotas e nas etapas de busca local, a conexão entre trechos de coleta pode ser obtida por consulta direta às matrizes, sem executar novamente um algoritmo de caminho mínimo a cada reconexão.

Embora o pré-processamento por Floyd–Warshall tenha complexidade de tempo de $\mathcal{O}(|V|^3)$ e complexidade de espaço de $\mathcal{O}(|V|^2)$, ele é executado apenas uma única vez na etapa de inicialização. Posteriormente, qualquer consulta de menor caminho ou distância entre dois vértices arbitrários é resolvida em tempo constante, ou seja, $\mathcal{O}(1)$. Assim, a disponibilidade prévia dos menores caminhos reduz o custo computacional das consultas repetidas e constitui um diferencial da abordagem proposta em relação à execução baseada apenas em Dijkstra sob demanda.

3.2.5 Busca local baseada em trocas

As estratégias de busca local adotadas neste trabalho incluem operadores do tipo *swap*, aplicados sobre a ordem de atendimento dos arcos de coleta dentro de uma rota. Considere uma rota R representada como uma sequência de trechos (u, v, t) , em que $t \in \{\text{coleta}, \text{deslocamento}\}$. Para a aplicação do *swap*, extraí-se inicialmente apenas a subsequência correspondente aos trechos de coleta, formando a lista

$$L = [(u_1, v_1), (u_2, v_2), \dots, (u_n, v_n)],$$

na qual cada par (u_k, v_k) representa um arco requerido atendido.

O operador consiste em selecionar duas posições distintas i e j dessa lista e permutá-las, gerando uma nova ordem

$$L' = \text{swap}(L, i, j).$$

A partir de L' , reconstrói-se uma rota conectada, inserindo trechos de deslocamento sempre que necessário para garantir conectividade entre o final de uma coleta e o início da coleta seguinte. Quando não há ligação direta entre os vértices envolvidos, os deslocamentos são obtidos por caminhos mínimos na rede: utilizando Dijkstra na primeira abordagem e estruturas pré-processadas de Floyd–Warshall na segunda. Por fim, calcula-se o custo da rota reconstruída e decide-se sobre sua aceitação conforme o critério da estratégia de busca local empregada. Em termos práticos, o *swap* busca reduzir o custo total reorganizando a ordem de atendimento dos arcos requeridos, enquanto a viabilidade do percurso é preservada por meio da inserção explícita de deslocamentos.

Embora o operador de vizinhança (troca de duas coletas) seja o mesmo, foram consideradas diferentes estratégias para percorrer a vizinhança e decidir a atualização da rota, produzindo compromissos distintos entre esforço computacional e qualidade da solução:

- **Melhor melhoria (Best Improvement).** Avalia sistematicamente todas as trocas possíveis entre pares (i, j) com $i < j$. Para cada permuta, reconstrói-se a rota conectada e computa-se o custo correspondente. Ao final, seleciona-se a melhor alternativa dentre as avaliadas, isto é, aquela que produz a maior redução de custo. Caso nenhuma troca produza melhoria, a rota permanece inalterada.
- **Descida randômica (Random Descent).** Realiza um número máximo de tentativas de troca, escolhendo pares (i, j) de forma aleatória. Sempre que uma permuta resulta em redução do custo da rota, essa nova rota é aceita e o procedimento é encerrado. Caso nenhuma melhoria seja encontrada dentro do limite de tentativas, mantém-se a rota original.
- **Primeira melhoria (First Improvement).** Percorre os pares (i, j) de forma determinística e ordenada. Assim que uma troca gera redução de custo, a nova rota é aceita e o procedimento é encerrado. Caso nenhuma permuta produza melhoria, a rota permanece inalterada.

Essas variações utilizam a mesma vizinhança definida por trocas, mas diferem na forma de busca por melhorias e no momento de interrupção, permitindo comparar o impacto da estratégia de busca local na qualidade final das rotas e no tempo de processamento.

Em termos de complexidade computacional, o espaço de busca local por meio de trocas possui tamanho de ordem $\mathcal{O}(K^2)$ em relação à quantidade de segmentos de coleta K na rota (com $K \leq |R|$, em que R é o conjunto de arestas requeridas). Para cada vizinho gerado, a rota é reconstruída. Utilizando o pré-processamento de Floyd–Warshall, a reconstrução é realizada em tempo $\mathcal{O}(K)$, resultando em complexidade de tempo de $\mathcal{O}(K^3)$ por varredura completa da vizinhança nas estratégias determinísticas

(*Best Improvement* e *First Improvement*). Na abordagem com Dijkstra sob demanda, a necessidade de reexecutar múltiplos cálculos de caminhos mínimos sob demanda eleva essa complexidade para $\mathcal{O}(K^2 \cdot (|E| + |V| \log |V|))$, o que justifica o elevado esforço computacional observado nos testes práticos.

3.2.6 *Simulated Annealing*

O *Simulated Annealing* (SA) é uma meta-heurística inspirada no processo físico de recozimento de metais, no qual um material aquecido é resfriado gradualmente para atingir um estado de menor energia. No contexto de otimização, essa analogia é utilizada para reduzir a tendência de métodos puramente gulosos ficarem presos em mínimos locais. Diferentemente de estratégias de busca local que aceitam apenas movimentos que reduzem o custo, o SA permite, de forma controlada, a aceitação ocasional de soluções piores, favorecendo a exploração do espaço de busca (KIRKPATRICK; GELATT; VECCHI, 1983).

Neste trabalho, o SA é aplicado como etapa de refinamento sobre uma rota construída previamente. A vizinhança é definida por operações de troca (*swap*) na ordem dos arcos de coleta, seguida da reconstrução de conectividade da rota. O custo da rota é avaliado pela função $C(\cdot)$, que representa a distância total percorrida (incluindo trechos de deslocamento e atendimento). A cada iteração, um vizinho r' é gerado e avaliado em relação à solução corrente r_{cur} por meio da variação

$$\Delta = C(r') - C(r_{cur}).$$

Movimentos com $\Delta < 0$ (melhoria) são sempre aceitos. Para $\Delta > 0$, o movimento pode ser aceito com probabilidade

$$p = e^{-\Delta/T},$$

em que T é a temperatura atual. Assim, quanto maior a temperatura, maior a chance de aceitar piores, permitindo escapar de regiões de busca desfavoráveis; à medida que T diminui, o algoritmo torna-se progressivamente mais seletivo, aproximando-se de uma busca local tradicional.

O processo de resfriamento é controlado por uma temperatura inicial T_0 , uma temperatura mínima T_{min} e um fator $\beta \in (0, 1)$, de modo que, ao final de cada estágio, a temperatura é atualizada por $T \leftarrow \beta \cdot T$. Em cada temperatura, são realizadas I tentativas de geração de vizinhos. Ao longo da execução, além da solução corrente, mantém-se também a melhor solução encontrada *bestRoute*, de modo que o retorno do algoritmo corresponde à melhor rota observada durante todo o processo, e não necessariamente à última solução corrente. O número total de soluções candidatas geradas e avaliadas pelo algoritmo é proporcional ao produto do número de estágios de resfriamento N_{temp} pela quantidade de iterações por temperatura I , denotado por $N_{temp} \cdot I$. Como cada vizinho gerado exige a

reconstrução da rota, a complexidade computacional de tempo do Simulated Annealing é dada por $\mathcal{O}(N_{temp} \cdot I \cdot K)$ utilizando Floyd–Warshall, e de $\mathcal{O}(N_{temp} \cdot I \cdot (|E| + |V| \log |V|))$ utilizando Dijkstra.

Após a geração de cada vizinho, a rota é reconstruída por meio da inserção de caminhos mínimos entre trechos de coleta que não estejam diretamente conectados. Dessa forma, mesmo quando a troca altera a ordem de atendimento dos arcos requeridos, a solução resultante é mantida conectada pela etapa de reconstrução. O Algoritmo 2 apresenta o procedimento utilizado.

Algoritmo 2: Simulated Annealing para melhoria de rota

Entrada: Rota inicial $route$; T_0 , T_{min} ; fator β ; iterações I

Saída: Melhor rota $bestRoute$

```

1  $route_{cur} \leftarrow route$ ;  $bestRoute \leftarrow route$ ;
2  $C_{cur} \leftarrow C(route_{cur})$ ;  $C_{best} \leftarrow C(bestRoute)$ ;
3  $T \leftarrow T_0$ ;
4 while  $T > T_{min}$  do
5   for  $k \leftarrow 1$  to  $I$  do
6     Gerar uma nova ordem de coletas  $L'$  por meio de swap;
7     Reconstruir  $route'$  conectando as coletas de  $L'$  por caminhos mínimos;
8      $\Delta \leftarrow C(route') - C_{cur}$ ;
9     if  $\Delta < 0$  ou  $rand(0, 1) < e^{-\Delta/T}$  then
10       $route_{cur} \leftarrow route'$ ;  $C_{cur} \leftarrow C(route')$ ;
11      if  $C_{cur} < C_{best}$  then
12         $bestRoute \leftarrow route_{cur}$ ;  $C_{best} \leftarrow C_{cur}$ ;
13    $T \leftarrow \beta \cdot T$ ;
14 return  $bestRoute$ ;
```

3.2.7 Visualização das rotas geradas

A Figura 7 apresenta um exemplo de solução obtida para a instância gp1, ilustrando a distribuição espacial das rotas geradas pelo algoritmo. Como se pode observar na imagem, para esse grupo foi necessária apenas 1 rota de atendimento, a qual está representada na cor verde. Esse tipo de visualização auxilia na interpretação qualitativa das soluções, evidenciando a cobertura dos trechos atendidos e os deslocamentos necessários na malha viária.

Além de apoiar a análise dos resultados, a geração de mapas das rotas constitui um diferencial deste trabalho em relação ao estudo de Carvalho (2017). Enquanto no trabalho de referência os resultados são apresentados principalmente por meio de valores numéricos e representação simplificada da cobertura, neste trabalho as rotas obtidas podem

ser visualizadas graficamente sobre a malha urbana, permitindo observar a distribuição espacial dos trajetos, os trechos de coleta e os deslocamentos realizados pelos veículos.




Figura 7 – Exemplo de solução gerada pelo GRASP para a instância gp1, gerando apenas uma rota representada em verde no mapa.

4 Experimentos e Resultados

Este capítulo apresenta os experimentos realizados e discute os resultados obtidos. As análises consideram as instâncias definidas para o município de João Monlevade–MG e utilizam como principais métricas a distância total percorrida pelas rotas e o tempo de execução necessário para obtenção das soluções. Os experimentos são apresentados em ordem cronológica: inicialmente descreve-se o ambiente computacional; em seguida, realiza-se a calibração dos parâmetros utilizando Floyd–Warshall como estratégia de conexão por caminhos mínimos; posteriormente, avalia-se o impacto do uso de Dijkstra como alternativa para essa conexão; por fim, compara-se a abordagem proposta com o estudo de referência de [Carvalho \(2017\)](#).

4.1 Ambiente computacional

Os experimentos foram executados em um computador equipado com processador Intel(R) Core(TM) i7-4790 CPU @ 3.60GHz, 16 GB de memória RAM, utilizando o sistema operacional Debian 13 (*trixie*). Esses dados são apresentados para contextualizar os tempos de execução reportados ao longo do capítulo, uma vez que o desempenho dos algoritmos depende diretamente das características do ambiente computacional. Cabe ressaltar que os testes deste trabalho e os do estudo de referência de [Carvalho \(2017\)](#) foram executados no mesmo computador, o que possibilita uma comparação direta dos tempos de execução.

4.2 Calibração dos parâmetros

A primeira etapa experimental teve como objetivo avaliar, escolher e calibrar as diferentes combinações de parâmetros do GRASP e das estratégias de busca local. Foram testados diferentes valores do parâmetro α , responsável por controlar o equilíbrio entre escolha gulosa e aleatoriedade na Lista Restrita de Candidatos (RCL), bem como diferentes quantidades de iterações do processo construtivo. Na etapa de busca local, foram avaliadas quatro estratégias: melhor melhoria, primeira melhoria, descida randômica e *Simulated Annealing* (SA).

Os parâmetros e respectivos valores testados na calibração são apresentados de forma estruturada na Tabela 2.

Tabela 2 – Parâmetros avaliados na calibração dos algoritmos.

Algoritmo / Etapa	Parâmetro	Valores testados
GRASP (Construtivo)	α (Equilíbrio gulosidade/aleatoriedade)	{0.1, 0.5, 0.8}
	Iterações do GRASP	{1, 3, 5}
Busca Local	Tipo de busca local	{melhor melhoria, primeira melhoria, descida randômica, Simulated Annealing}
Descida Randômica (Busca Local)	Número máx. de tentativas de <i>swap</i> (I_{swap})	{50, 100, 200}
Simulated Annealing (Busca Local)	Temperatura inicial (T_0)	{100, 500, 1000}
	Fator de resfriamento (β)	{0.4, 0.8, 0.95}
	Temperatura mínima (T_{min})	{0.001} (fixo)
	Iterações por temperatura (I)	{10, 100, 500}

Essa combinação de parâmetros resultou em um total de 288 configurações testadas, sendo 9 usando o método melhor melhoria, 9 usando primeira melhoria, 27 usando descida randômica e 243 usando o *Simulated Annealing*.

Nesta etapa, utilizou-se Floyd–Warshall como estratégia de conexão por caminhos mínimos. Essa escolha foi adotada porque, em testes preliminares, observou-se que o uso de caminhos mínimos pré-processados reduzia o custo computacional das consultas repetidas realizadas durante a construção e a reconstrução das rotas. Como as buscas locais exigem várias reconstruções de conectividade, o pré-processamento por Floyd–Warshall mostrou-se adequado para a varredura sistemática das configurações.

Para analisar detalhadamente o desempenho das estratégias de busca local, os resultados foram avaliados sob duas perspectivas para cada método: a configuração de melhor qualidade (menor distância total acumulada das instâncias) e a configuração mais rápida (menor tempo de processamento total). Esses resultados consolidados e os respectivos parâmetros calibrados são apresentados na Tabela 3. Nessa tabela, cada linha detalha as configurações de busca local e do GRASP calibradas (α , iterações, número de *swaps* ou parâmetros do SA), acompanhadas dos respectivos somatórios de distância e tempo de execução obtidos. As configurações de teste são identificadas pelo código único na coluna “Exp.”, que serve como referência para a Tabela 8 do Apêndice A, que contém o resultado detalhado de todos os experimentos.

Tabela 3 – Melhores configurações obtidas por busca local na calibração com Floyd–Warshall.

Busca local	Objetivo	Exp.	α	Parâmetros	Dist. (km)	Tempo (s)
melhor melhoria	melhor qualidade	EXP0041	0.8	GRASP: 5 iter.	878,46	15634,36
	melhor tempo	EXP0001	0.1	GRASP: 1 iter.	912,64	3073,50
primeira melhoria	melhor qualidade	EXP0027	0.5	GRASP: 5 iter.	889,30	6785,83
	melhor tempo	EXP0032	0.8	GRASP: 1 iter.	926,78	351,69
descida randômica	melhor qualidade	EXP0039	0.8	$I_{swap} = 100$, GRASP: 3 iter.	888,91	2,80
	melhor tempo	EXP0018	0.5	$I_{swap} = 50$, GRASP: 1 iter.	907,65	0,74
Simulated Annealing	melhor qualidade	EXP0139	0.5	$T_0 = 100$, $\beta = 0.8$, $I = 10$, GRASP: 5 iter.	883,79	17,96
	melhor tempo	EXP0082	0.5	$T_0 = 100$, $\beta = 0.4$, $I = 10$, GRASP: 1 iter.	920,54	1,24

A análise comparativa evidencia o clássico compromisso (*trade-off*) entre tempo computacional e qualidade da solução. Embora o método de melhor melhoria operando com a configuração de melhor qualidade (EXP0041) tenha encontrado a menor distância física absoluta (878,46 km), seu custo computacional de mais de 4 horas pode inviabilizar sua aplicação prática em tempo real. Em contrapartida, a melhor configuração do *Simulated Annealing* (EXP0139) encontrou uma solução muito próxima (distância apenas 0,61% maior) em meros 17,96 s, consolidando-se como a alternativa mais eficiente e viável para o planejamento operacional de rotas.

A Figura 8 apresenta a comparação das distâncias totais obtidas pelas melhores configurações de cada método. A Figura 9 detalha a comparação dos respectivos tempos de execução, com as barras de tempos muito curtos mantidas fora de escala para permitir sua visualização gráfica, enquanto os rótulos de dados exibem os valores reais.




Figura 8 – Distância total nas melhores configurações por método de busca local utilizando Floyd-Warshall.




Figura 9 – Tempo de execução nas melhores configurações por método de busca local utilizando Floyd-Warshall.

4.3 Dijkstra versus Floyd-Warshall

A segunda etapa experimental teve como objetivo avaliar o impacto da estratégia de conexão por caminhos mínimos. Para isso, além dos testes principais com Floyd-Warshall,

foram realizadas execuções complementares utilizando Dijkstra sob demanda.

Tabela 4 – Resultados agregados com Dijkstra versus Floyd–Warshall.

Busca local	α	Iter. G.	Parâmetros	Dijkstra		Floyd–Warshall	
				Dist. (km)	Tempo (s)	Dist. (km)	Tempo (s)
SA (tempo)	0.5	1	$T_0 = 100.0, \beta = 0.4,$ $I = 10, T_{min} = 0.001$	910,00	20,11	920,54	1,24
SA (qualidade)	0.5	5	$T_0 = 100.0, \beta = 0.8,$ $I = 10, T_{min} = 0.001$	888,19	378,73	883,79	17,96
melhor melh. (tempo)	0.1	1		905,97	80149,03	912,64	3073,50
melhor melh. (qualidade)	0.8	5		873,85	413789,35	878,46	15634,36
prim. melh. (tempo)	0.8	1		906,93	28152,09	926,78	351,69
prim. melh. (qualidade)	0.5	5		894,71	205362,87	889,30	6785,83
descida rand. (tempo)	0.5	1	$I_{swap} = 50$	908,80	7,74	907,65	0,74
descida rand. (qualidade)	0.8	3	$I_{swap} = 100$	884,95	44,20	888,91	2,80

Essa comparação foi realizada utilizando as configurações de melhor tempo (mais rápidas) e de melhor qualidade de solução obtidas na calibração. Os resultados da Tabela 4 evidenciam que, no contexto de Dijkstra, estratégias que demandam múltiplas reconstruções de rota podem elevar substancialmente o tempo total de execução. Esse comportamento é observado de forma extrema na configuração de melhor qualidade do método melhor melhoria, cujo tempo total de processamento com Dijkstra chegou a 413.789,35 s (aproximadamente 115 horas ou 4,8 dias).

A comparação com os resultados obtidos com Floyd–Warshall reforça a gigantesca vantagem do pré-processamento. Enquanto a melhor configuração do *Simulated Annealing* executada com Dijkstra registrou 378,73 s, a mesma com Floyd–Warshall levou apenas 17,96 s (uma aceleração de 21 vezes). Essa diferença ocorre porque o Dijkstra exige o cálculo de caminhos mínimos sob demanda a cada reconexão de trechos de coleta, enquanto o Floyd–Warshall pré-calcula todas as distâncias de uma só vez, permitindo consultas imediatas em $O(1)$.

Embora o pré-processamento por Floyd–Warshall tenha um custo inicial, ele provou ser extremamente baixo na prática: a execução levou apenas 0,48 segundos para processar todas as instâncias setorizadas da cidade de forma somada, e somente 24,39 segundos para a malha viária completa unificada de João Monlevade–MG (grafo de 2428 nós). Cabe ressaltar que o tempo gasto nesse pré-processamento não foi incluído no tempo das execuções relatado nos resultados. Diante dos milhares de consultas repetidas que ocorrem nos algoritmos de busca local, esse pequeno custo de inicialização se paga amplamente, eliminando gargalos de tempo de execução.

As Figuras 10 e 11 ilustram graficamente a comparação dos tempos de execução para as configurações de melhor tempo e melhor qualidade, respectivamente, com as barras de tempos muito baixos desenhadas fora de escala para viabilizar sua visualização gráfica.




Figura 10 – Comparação de tempo de execução (Dijkstra vs FW) – Configurações de melhor tempo.




Figura 11 – Comparação de tempo de execução (Dijkstra vs FW) – Configurações de melhor qualidade.

4.4 Resultados na malha viária unificada

Uma das contribuições deste trabalho consiste em avaliar a capacidade de escala dos algoritmos desenvolvidos quando aplicados à malha viária unificada do município

(mapa completo), isto é, sem a divisão física em grupos ou setores de coleta. Essa análise permite verificar a viabilidade operacional de rotear toda a cidade de maneira integrada.

Nesta etapa, a malha viária completa possui a totalidade das arestas com demandas de coleta correspondentes à geração diária estimada do município (67.357,08 kg). Foram executadas as oito configurações de teste utilizando Floyd–Warshall como método de caminhos mínimos pré-processados na memória.

A Tabela 5 apresenta os resultados obtidos utilizando as configurações de **melhor tempo** (mais rápidas) de cada método, cujos parâmetros estão definidos na Tabela 4.

Tabela 5 – Resultados das heurísticas aplicadas ao mapa completo unificado para as configurações de melhor tempo.

Busca local	α	Iter. G.	Parâmetros	Distância (km)	Tempo (s)
Simulated Annealing	0.5	1	$T_0 = 100.0$, $\beta = 0.4$, $I = 10$, $T_{min} = 0.001$	1031,02	2,57
melhor melhoria	0.1	1		1021,59	7212,48
primeira melhoria	0.8	1		1021,71	6840,52
descida randômica	0.5	1	$I_{swap} = 50$	1010,20	1,83

Tabela 6 – Resultados das heurísticas aplicadas ao mapa completo unificado para as configurações de melhor qualidade.

Busca local	α	Iter. G.	Parâmetros	Distância (km)	Tempo (s)
Simulated Annealing	0.5	5	$T_0 = 100.0$, $\beta = 0.8$, $I = 10$, $T_{min} = 0.001$	1007,44	25,71
melhor melhoria	0.8	5		1001,06	35073,43
primeira melhoria	0.5	5		1006,63	22052,26
descida randômica	0.8	3	$I_{swap} = 100$	1027,35	6,18

Os resultados indicam que a menor distância total percorrida na malha integrada foi obtida pela configuração de melhor qualidade do método melhor melhoria (Tabela 6), registrando 1001,06 km. Contudo, essa busca exaustiva demandou 35.073,43 s (cerca de 9,70 horas) de tempo computacional, o que reforça a inviabilidade de métodos determinísticos completos em grafos de grande porte.

Em contrapartida, a configuração de melhor qualidade do *Simulated Annealing* alcançou excelente desempenho físico: registrou a distância total de 1007,44 km (uma diferença de apenas 0,63% em relação à melhor solução) em um tempo computacional de apenas 25,71 s. Além disso, a configuração de melhor tempo da descida randômica (Tabela 5) obteve a distância de 1010,20 km em 1,83 s.

Essa análise demonstra que as abordagens heurísticas baseadas em *Simulated Annealing* e descida randômica possuem alta capacidade de escala. Elas permitem planejar a coleta de resíduos sólidos para todo o município de forma integrada em menos de 30 segundos, apresentando soluções de excelente qualidade física e viabilidade prática.

4.5 Comparação com o estudo de referência

A quarta etapa experimental consistiu em comparar a abordagem proposta com o estudo de referência de [Carvalho \(2017\)](#). Para isso, as os oito configurações de teste calibradas (duas para cada método de busca local, sendo uma de melhor tempo e outra de melhor qualidade de solução) foram executadas sobre o mesmo grafo utilizado no estudo de referência, viabilizando uma análise comparativa de desempenho.

Os testes foram realizados utilizando as mesmas os os oito configurações cujos parâmetros encontram-se consolidados na Tabela 3. A Tabela 7 apresenta os resultados da abordagem proposta comparados com os dados originais de [Carvalho \(2017\)](#).

Tabela 7 – Comparação entre a abordagem proposta e o estudo de referência no mapa simplificado.

Abordagem	Dist. (km)	Tempo (s)	Redução (%)	Aceleração
Estudo de referência (CARVALHO, 2017)	205,81	4939,71	-	-
Simulated Annealing (melhor tempo)	207,32	0,39	-0,73%	12665,92x
Simulated Annealing (melhor qualidade)	202,81	5,28	1,46%	935,55x
melhor melhoria (melhor tempo)	204,21	173,17	0,78%	28,53x
melhor melhoria (melhor qualidade)	201,38	869,13	2,15%	5,68x
primeira melhoria (melhor tempo)	203,01	43,09	1,36%	114,64x
primeira melhoria (melhor qualidade)	202,39	199,20	1,66%	24,80x
descida randômica (melhor tempo)	211,68	0,24	-2,85%	20582,13x
descida randômica (melhor qualidade)	199,86	0,90	2,89%	5488,57x

A análise comparativa revela que seis das os oito configurações propostas superaram o resultado de distância total do estudo de referência (205,81 km). O destaque principal foi a configuração de descida randômica (melhor qualidade), que reduziu a distância total para 199,86 km, o que representa um ganho de 2,89% de redução de custos de deslocamento rodando em apenas 0,90 s (cerca de 5488 vezes mais rápido que o trabalho anterior). O *Simulated Annealing* de melhor qualidade obteve uma redução de 1,46% na distância total percorrida com tempo de execução de apenas 5,28 s.

As únicas configurações que não superaram a distância do estudo de referência foram as de melhor tempo do Simulated Annealing e da descida randômica. No entanto, essas opções priorizaram de forma extrema a velocidade de processamento, concluindo em 0,39 s e 0,24 s (acelerações de mais de 12.000 e 20.000 vezes, respectivamente), evidenciando a grande adaptabilidade dos algoritmos a diferentes necessidades da operação.

Em relação ao tempo computacional, a diferença é altamente expressiva. Enquanto o estudo de referência necessitou de 4939,71 s (aproximadamente 1,37 horas) para obter suas rotas no grafo simplificado, todas as abordagens propostas que superaram a qualidade física do percurso concluíram os testes em intervalos de tempo drasticamente inferiores (com destaque para a descida randômica com menos de 1 segundo). Esse comportamento atesta a eficiência do pré-processamento por Floyd–Warshall em conjunto com as buscas

locais aplicadas.

4.6 Síntese

Os experimentos indicaram que a calibração dos parâmetros tem impacto direto na qualidade das soluções e no tempo de execução dos algoritmos. A configuração utilizando GRASP, caminhos mínimos pré-processados por Floyd-Warshall e *Simulated Annealing* apresentou a melhor eficiência global para a setorização da cidade. Por sua vez, a estratégia de busca local baseada na descida randômica mostrou-se uma alternativa de altíssima velocidade e excelente qualidade física, superando inclusive o Simulated Annealing no grafo simplificado da comparação.

A comparação entre Dijkstra e Floyd-Warshall evidenciou que a pré-computação dos menores caminhos reduz o impacto do gargalo computacional das buscas locais, proporcionando acelerações significativas. Por fim, o confronto com o estudo de referência mostrou que a metodologia proposta obteve percursos mais curtos em tempos computacionais inferiores, indicando a viabilidade e a aplicabilidade prática das meta-heurísticas desenvolvidas para o cenário avaliado.

5 Conclusão

Este trabalho abordou o planejamento de rotas para a coleta de resíduos sólidos domiciliares em João Monlevade–MG, formulando o problema no contexto do Problema de Roteamento em Arcos Capacitados (PRAC). A partir da representação da malha viária como um grafo e da construção de instâncias compatíveis com a setorização utilizada no estudo de referência, foram desenvolvidas e avaliadas abordagens heurísticas e meta-heurísticas para obtenção de soluções viáveis, considerando como critérios principais a distância total percorrida e o tempo de execução.

No processo de desenvolvimento, foram implementadas duas estratégias para conexão por caminhos mínimos durante a construção e a reconstrução das rotas: uma baseada em cálculos sob demanda (Algoritmo de Dijkstra) e outra baseada em estruturas pré-processadas (Algoritmo de Floyd-Warshall). Os resultados mostraram que o pré-processamento é determinante para viabilizar a exploração sistemática de configurações, especialmente quando são aplicadas buscas locais que demandam reconstruções recorrentes de conectividade. Em particular, os testes complementares com Dijkstra evidenciaram um crescimento acentuado no tempo de execução conforme a intensidade da busca aumentou (decorrente do elevado volume de chamadas e reexecuções sob demanda do algoritmo de caminhos mínimos), com a configuração de melhor melhoria intensiva ultrapassando 115 horas de processamento no Dijkstra, em contraste com cerca de 4,3 horas no Floyd-Warshall.

Quanto aos procedimentos de refinamento de soluções, os experimentos indicaram que a meta-heurística *Simulated Annealing* apresentou um excelente custo-benefício, obtendo uma distância total de 883,79 km em apenas 17,96 s sobre a divisão setorial das instâncias. Diferentemente dos métodos clássicos de busca local (como melhor melhoria e primeira melhoria), que realizam buscas estritamente de descida e tendem a ficar presos em mínimos locais por aceitarem apenas movimentos de redução de custo, o *Simulated Annealing* emprega uma estratégia de aceitação probabilística de soluções de custo mais elevado sob controle de um parâmetro de temperatura. Esse mecanismo de perturbação permite que a busca escape de ótimos locais e explore o espaço de busca de forma mais ampla antes de convergir. Embora a busca local exaustiva por melhor melhoria tenha alcançado a menor distância absoluta, o seu tempo de execução de 15634,36 s evidencia o elevado trade-off computacional. O *Simulated Annealing* posiciona-se, portanto, como uma alternativa muito mais equilibrada para operações práticas, aproximando-se da melhor distância física com uma fração ínfima do tempo computacional.

Além disso, ao aplicar a abordagem proposta sobre a mesma base de grafo utilizada

no estudo de referência, as heurísticas alcançaram resultados superiores tanto em distância quanto em tempo de execução. A configuração proposta baseada em *Simulated Annealing* obteve uma solução com distância de 202,81 km em 5,28 s, representando uma redução de 1,46% na distância percorrida e uma velocidade de execução 935,55 vezes superior em relação aos 205,81 km e 4939,71 s de referência. Alternativamente, a estratégia rápida de descida randômica obteve o melhor resultado em distância do trabalho, atingindo 199,86 km em apenas 0,90 s. Adicionalmente, os experimentos de roteamento global aplicados ao grafo completo unificado do município (sem subdivisão territorial) demonstraram que a abordagem proposta possui boa escalabilidade computacional. O algoritmo *Simulated Annealing* foi capaz de planejar rotas otimizadas de 1007,44 km para a malha viária integrada de toda a cidade em apenas 25,71 s, sinalizando o potencial e a aplicabilidade de modelagens globais em redes urbanas dessa escala.

De maneira geral, conclui-se que a abordagem proposta é capaz de gerar soluções viáveis, rápidas e comparáveis para o cenário estudado, oferecendo uma base sólida para análise de desempenho e escolha de parametrizações conforme a restrição operacional predominante.

Não obstante, o modelo proposto adota algumas hipóteses simplificadoras e apresenta limitações que devem ser consideradas. Primeiramente, a malha viária foi modelada como um grafo não direcionado (hipótese de mão dupla em todas as vias), desconsiderando a sinalização real de sentido das vias. Em segundo lugar, a demanda de resíduos foi distribuída de forma proporcional à extensão das ruas devido à falta de dados empíricos de geração por logradouro. Adicionalmente, as rotas foram geradas de forma aberta, sem restringir a partida e o retorno a um depósito físico fixo de garagem. Por fim, a etapa de refinamento limitou-se a trocas de atendimento dentro de uma mesma rota (intra-rota), não explorando transferências de trechos entre rotas diferentes.

Diante dessas limitações, sugere-se como trabalhos futuros: (i) estender o modelo para um grafo direcionado ou misto, incorporando restrições reais de tráfego, sentido de vias, tempos de parada e janelas de serviço; (ii) investigar métodos alternativos de estimativa de demanda a partir de dados reais de pesagem por rua ou bairro; (iii) adaptar os algoritmos para incluir a obrigatoriedade de retorno a um depósito central fixo, permitindo analisar o custo logístico de deslocamento completo da frota; e (iv) desenvolver operadores de vizinhança inter-rotas que permitam trocar trechos de atendimento entre diferentes veículos, ampliando a capacidade de otimização local.

Referências

- BARÃO, F. R. *Problemas de localização e roteamento aplicados na otimização da coleta de resíduos sólidos urbanos no município de Passo Fundo-RS*. Dissertação (Dissertação de Mestrado) — Universidade de Passo Fundo, Passo Fundo, RS, 2008. Citado na página 21.
- BATISTA, G. V.; SCARPIN, C. T. Problema de roteamento em arcos capacitado e periódico aplicado a um contexto real. *Revista Produção Online*, Florianópolis, SC, v. 15, n. 3, p. 1080–1098, 2015. Citado na página 21.
- BOEING, G. Modeling and analyzing urban networks and amenities with osmnx. *Geographical Analysis*, 2025. Published online ahead of print. Citado na página 24.
- Brasil. Ministério das Cidades. *SINISA 2025: Relatório de Resíduos Sólidos, ano de referência 2024*. 2025. <https://www.gov.br/cidades/pt-br/aceso-a-informacao/acoes-e-programas/saneamento/sinisa/resultados-sinisa/copy_of_RELATORIO_SINISA_RESIDUOS_SOLIDOS_2025.pdf>. Indicador de massa média per capita de resíduos sólidos domiciliares coletados. Acesso em: 14 maio 2026. Citado na página 27.
- CARVALHO, H. F. d. *Otimização das Rotas de Coleta de Resíduos Sólidos Domiciliares: um estudo de caso em João Monlevade-MG*. Dissertação (Trabalho de Conclusão de Curso) — Universidade Federal de Ouro Preto, João Monlevade, MG, 2017. Citado 11 vezes nas páginas 13, 14, 19, 20, 22, 23, 24, 25, 35, 37 e 44.
- DIJKSTRA, E. W. A note on two problems in connexion with graphs. *Numerische Mathematik*, v. 1, p. 269–271, 1959. Citado na página 17.
- FEO, T. A.; RESENDE, M. G. C. Greedy randomized adaptive search procedures. *Journal of Global Optimization*, v. 6, n. 2, p. 109–133, 1995. Citado 2 vezes nas páginas 21 e 30.
- GOLDBARG, E.; GOLDBARG, M.; LUNA, H. *Otimização Combinatória e Meta-heurísticas: Algoritmos e Aplicação*. Rio de Janeiro: Elsevier, 2015. Citado 2 vezes nas páginas 17 e 20.
- GOLDEN, B. L.; WONG, R. T. Capacitated arc routing problems. *Networks*, v. 11, n. 3, p. 305–315, 1981. Citado 2 vezes nas páginas 18 e 20.
- Instituto Brasileiro de Geografia e Estatística. *João Monlevade (MG) | Cidades e Estados*. 2022. <<https://www.ibge.gov.br/cidades-e-estados/mg/joao-monlevade.html>>. População no último censo: 80.187 pessoas. Acesso em: 14 maio 2026. Citado na página 27.
- KIRKPATRICK, S.; GELATT, C. D.; VECCHI, M. P. Optimization by simulated annealing. *Science*, v. 220, n. 4598, p. 671–680, 1983. Citado 2 vezes nas páginas 21 e 34.
- LAPORTE, G. The vehicle routing problem: An overview of exact and approximate algorithms. *European Journal of Operational Research*, v. 59, n. 3, p. 345–358, 1991. Citado 2 vezes nas páginas 17 e 20.
- LUCCHESI, C. L. *Introdução à Teoria dos Grafos*. Rio de Janeiro: IMPA, 2006. Citado na página 16.

NETTO, P. O. B. *Grafos: Teoria, Modelos, Algoritmos*. São Paulo: Editora Blucher, 2012. Citado 2 vezes nas páginas 16 e 17.

OLIVEIRA, P. E. G. d.; SILVA, S. C. B. d.; SILVA, W. T. P. d. Otimização para rota de coleta de resíduos sólidos domiciliares: estudo de caso em santo antônio de leverger/mt. In: *Congresso ABES/AESABESP 2017*. São Paulo: [s.n.], 2017. Trabalho I-310. Citado na página 22.

OpenStreetMap contributors. *OpenStreetMap [Data set]*. 2024. <<https://www.openstreetmap.org>>. Available under the Open Data Commons Open Database License (ODbL). Citado na página 24.

SILVA, H. V. O. *Grafo Viário de João Monlevade*. 2026. Disponível em: <<https://github.com/hudsonsilvaUfop/grafos-viario-jm>>. Acesso em: 10 ago. 2026. Citado na página 24.

VECCHI, T. P. B. *Otimização de rotas dos caminhões de coleta de resíduos sólidos urbanos*. Tese (Tese de Doutorado) — Universidade Estadual de Maringá, Maringá, PR, 2016. Citado na página 22.

Apêndices

APÊNDICE A – Tabela Consolidada dos Experimentos

Este apêndice apresenta a Tabela 8, que consolida os resultados de todos os experimentos computacionais executados neste trabalho. Cada linha da tabela detalha as configurações de teste e o respectivo desempenho obtido. A coluna “Exp.” indica o identificador único de cada experimento. “Cenário” descreve a malha viária e a estratégia de caminho mínimo empregadas. “Busca local” especifica o método de refinamento utilizado. Os parâmetros α e “Iter. G.” detalham a calibração da fase construtiva do GRASP, enquanto as configurações adicionais específicas da busca local (como o número de *swaps* ou parâmetros do Simulated Annealing) são descritas em “Parâmetros”. Por fim, as colunas “Dist. (km)” e “Tempo (s)” indicam o somatório das distâncias e dos tempos de execução para todas as instâncias correspondentes.

Tabela 8 – Resultados consolidados de todos os experimentos executados.

Exp.	Cenário	Busca local	α	Iter. G.	Parâmetros	Dist. (km)	Tempo (s)
EXP0001	Setorizado (FW)	melhor lhoria	me- 0.1	1	-	912,64	3073,50
EXP0006	Setorizado (FW)	melhor lhoria	me- 0.1	3	$I_{swap} = 200$	901,65	9165,67
EXP0011	Setorizado (FW)	melhor lhoria	me- 0.1	5	$I_{swap} = 200$	902,25	15278,77
EXP0016	Setorizado (FW)	melhor lhoria	me- 0.5	1	$I_{swap} = 200$	917,53	3115,09
EXP0021	Setorizado (FW)	melhor lhoria	me- 0.5	3	$I_{swap} = 200$	880,15	9238,19
EXP0026	Setorizado (FW)	melhor lhoria	me- 0.5	5	$I_{swap} = 200$	888,96	15645,96
EXP0031	Setorizado (FW)	melhor lhoria	me- 0.8	1	$I_{swap} = 200$	912,36	3115,99
EXP0036	Setorizado (FW)	melhor lhoria	me- 0.8	3	$I_{swap} = 200$	903,19	9358,47
EXP0041	Setorizado (FW)	melhor lhoria	me- 0.8	5	$I_{swap} = 200$	878,46	15634,36
EXP0002	Setorizado (FW)	primeira lhoria	me- 0.1	1	-	922,36	1000,70
EXP0007	Setorizado (FW)	primeira lhoria	me- 0.1	3	$I_{swap} = 200$	907,47	3117,70
EXP0012	Setorizado (FW)	primeira lhoria	me- 0.1	5	$I_{swap} = 200$	899,51	6333,00
EXP0017	Setorizado (FW)	primeira lhoria	me- 0.5	1	$I_{swap} = 200$	909,92	955,60
EXP0022	Setorizado (FW)	primeira lhoria	me- 0.5	3	$I_{swap} = 200$	904,10	4189,34

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter. G.	Parâmetros	Dist. (km)	Tempo (s)
EXP0027	Setorizado (FW)	primeira me-lhoria	0.5	5	$I_{swap} = 200$	889,30	6785,83
EXP0032	Setorizado (FW)	primeira me-lhoria	0.8	1	$I_{swap} = 200$	926,78	351,69
EXP0037	Setorizado (FW)	primeira me-lhoria	0.8	3	$I_{swap} = 200$	907,69	3855,18
EXP0042	Setorizado (FW)	primeira me-lhoria	0.8	5	$I_{swap} = 200$	899,37	7513,34
EXP0003	Setorizado (FW)	descida ran-dômica	0.1	1	$I_{swap} = 50$	917,12	0,77
EXP0004	Setorizado (FW)	descida ran-dômica	0.1	1	$I_{swap} = 100$	910,83	1,07
EXP0005	Setorizado (FW)	descida ran-dômica	0.1	1	$I_{swap} = 200$	915,85	1,68
EXP0008	Setorizado (FW)	descida ran-dômica	0.1	3	$I_{swap} = 50$	909,82	1,78
EXP0009	Setorizado (FW)	descida ran-dômica	0.1	3	$I_{swap} = 100$	908,37	2,67
EXP0010	Setorizado (FW)	descida ran-dômica	0.1	3	$I_{swap} = 200$	902,15	4,58
EXP0013	Setorizado (FW)	descida ran-dômica	0.1	5	$I_{swap} = 50$	907,17	2,74
EXP0014	Setorizado (FW)	descida ran-dômica	0.1	5	$I_{swap} = 100$	907,94	4,38
EXP0015	Setorizado (FW)	descida ran-dômica	0.1	5	$I_{swap} = 200$	900,39	7,39
EXP0018	Setorizado (FW)	descida ran-dômica	0.5	1	$I_{swap} = 50$	907,65	0,74
EXP0019	Setorizado (FW)	descida ran-dômica	0.5	1	$I_{swap} = 100$	926,35	1,06
EXP0020	Setorizado (FW)	descida ran-dômica	0.5	1	$I_{swap} = 200$	917,56	1,69
EXP0023	Setorizado (FW)	descida ran-dômica	0.5	3	$I_{swap} = 50$	901,89	1,72
EXP0024	Setorizado (FW)	descida ran-dômica	0.5	3	$I_{swap} = 100$	902,05	2,71
EXP0025	Setorizado (FW)	descida ran-dômica	0.5	3	$I_{swap} = 200$	906,06	4,66
EXP0028	Setorizado (FW)	descida ran-dômica	0.5	5	$I_{swap} = 50$	899,23	2,81
EXP0029	Setorizado (FW)	descida ran-dômica	0.5	5	$I_{swap} = 100$	889,97	4,40
EXP0030	Setorizado (FW)	descida ran-dômica	0.5	5	$I_{swap} = 200$	895,74	7,61
EXP0033	Setorizado (FW)	descida ran-dômica	0.8	1	$I_{swap} = 50$	920,06	0,75
EXP0034	Setorizado (FW)	descida ran-dômica	0.8	1	$I_{swap} = 100$	920,04	1,06
EXP0035	Setorizado (FW)	descida ran-dômica	0.8	1	$I_{swap} = 200$	906,14	1,73
EXP0038	Setorizado (FW)	descida ran-dômica	0.8	3	$I_{swap} = 50$	891,01	1,84
EXP0039	Setorizado (FW)	descida ran-dômica	0.8	3	$I_{swap} = 100$	888,91	2,80

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter.	G. Parâmetros	Dist. (km)	Tempo (s)
EXP0040	Setorizado (FW)	descida ran- dômica	0.8	3	$I_{swap} = 200$	901,38	4,54
EXP0043	Setorizado (FW)	descida ran- dômica	0.8	5	$I_{swap} = 50$	894,54	2,86
EXP0044	Setorizado (FW)	descida ran- dômica	0.8	5	$I_{swap} = 100$	897,84	4,42
EXP0045	Setorizado (FW)	descida ran- dômica	0.8	5	$I_{swap} = 200$	889,19	7,61
EXP0001	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 100, \beta = 0.4,$ $I = 10$	914,58	1,30
EXP0002	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 100, \beta = 0.4,$ $I = 100$	913,30	9,07
EXP0003	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 100, \beta = 0.4,$ $I = 500$	917,31	44,71
EXP0004	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 100, \beta = 0.8,$ $I = 10$	917,69	3,88
EXP0005	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 100, \beta = 0.8,$ $I = 100$	913,62	35,21
EXP0006	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 100, \beta = 0.8,$ $I = 500$	916,78	172,93
EXP0007	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 100, \beta = 0.95,$ $I = 10$	913,71	15,26
EXP0008	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 100, \beta = 0.95,$ $I = 100$	916,58	150,95
EXP0009	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 100, \beta = 0.95,$ $I = 500$	912,41	753,29
EXP0010	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 500, \beta = 0.4,$ $I = 10$	910,72	1,36
EXP0011	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 500, \beta = 0.4,$ $I = 100$	912,41	10,10
EXP0012	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 500, \beta = 0.4,$ $I = 500$	912,33	56,35
EXP0013	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 500, \beta = 0.8,$ $I = 10$	922,59	4,22
EXP0014	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 500, \beta = 0.8,$ $I = 100$	914,84	40,83
EXP0015	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 500, \beta = 0.8,$ $I = 500$	906,76	253,50
EXP0016	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 500, \beta = 0.95,$ $I = 10$	918,30	17,44
EXP0017	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 500, \beta = 0.95,$ $I = 100$	917,90	204,57
EXP0018	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 500, \beta = 0.95,$ $I = 500$	909,31	1467,99
EXP0019	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 1000, \beta = 0.4,$ $I = 10$	911,76	1,46
EXP0020	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 1000, \beta = 0.4,$ $I = 100$	913,93	11,50
EXP0021	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 1000, \beta = 0.4,$ $I = 500$	915,43	81,98
EXP0022	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 1000, \beta = 0.8,$ $I = 10$	914,22	4,43
EXP0023	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 1000, \beta = 0.8,$ $I = 100$	916,97	51,10

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter. G.	Parâmetros	Dist. (km)	Tempo (s)
EXP0024	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 1000, \beta = 0.8,$ $I = 500$	908,81	439,89
EXP0025	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 1000, \beta = 0.95,$ $I = 10$	913,82	20,32
EXP0026	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 1000, \beta = 0.95,$ $I = 100$	911,46	322,39
EXP0027	Setorizado (FW)	Simulated Annealing	0.1	1	$T_0 = 1000, \beta = 0.95,$ $I = 500$	910,69	2892,16
EXP0028	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 100, \beta = 0.4,$ $I = 10$	908,52	3,33
EXP0029	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 100, \beta = 0.4,$ $I = 100$	909,26	25,85
EXP0030	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 100, \beta = 0.4,$ $I = 500$	897,52	125,29
EXP0031	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 100, \beta = 0.8,$ $I = 10$	909,27	10,88
EXP0032	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 100, \beta = 0.8,$ $I = 100$	905,49	101,08
EXP0033	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 100, \beta = 0.8,$ $I = 500$	904,63	508,46
EXP0034	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 100, \beta = 0.95,$ $I = 10$	905,81	43,81
EXP0035	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 100, \beta = 0.95,$ $I = 100$	900,07	435,89
EXP0036	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 100, \beta = 0.95,$ $I = 500$	901,62	2223,76
EXP0037	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 500, \beta = 0.4,$ $I = 10$	909,69	3,72
EXP0038	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 500, \beta = 0.4,$ $I = 100$	905,12	30,30
EXP0039	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 500, \beta = 0.4,$ $I = 500$	903,83	167,78
EXP0040	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 500, \beta = 0.8,$ $I = 10$	911,37	12,29
EXP0041	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 500, \beta = 0.8,$ $I = 100$	909,07	123,18
EXP0042	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 500, \beta = 0.8,$ $I = 500$	907,02	746,11
EXP0043	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 500, \beta = 0.95,$ $I = 10$	910,21	51,27
EXP0044	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 500, \beta = 0.95,$ $I = 100$	900,56	613,33
EXP0045	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 500, \beta = 0.95,$ $I = 500$	902,18	4519,95
EXP0046	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 1000, \beta = 0.4,$ $I = 10$	913,54	3,94
EXP0047	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 1000, \beta = 0.4,$ $I = 100$	907,86	35,62
EXP0048	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 1000, \beta = 0.4,$ $I = 500$	908,99	248,05
EXP0049	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 1000, \beta = 0.8,$ $I = 10$	906,49	12,94
EXP0050	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 1000, \beta = 0.8,$ $I = 100$	905,91	155,77

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter. G.	Parâmetros	Dist. (km)	Tempo (s)
EXP0051	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 1000, \beta = 0.8,$ $I = 500$	904,80	1318,42
EXP0052	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 1000, \beta = 0.95,$ $I = 10$	903,94	58,66
EXP0053	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 1000, \beta = 0.95,$ $I = 100$	906,24	1005,31
EXP0054	Setorizado (FW)	Simulated Annealing	0.1	3	$T_0 = 1000, \beta = 0.95,$ $I = 500$	908,01	8546,09
EXP0055	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 100, \beta = 0.4,$ $I = 10$	905,73	5,36
EXP0056	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 100, \beta = 0.4,$ $I = 100$	900,41	42,71
EXP0057	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 100, \beta = 0.4,$ $I = 500$	900,81	211,36
EXP0058	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 100, \beta = 0.8,$ $I = 10$	904,96	17,93
EXP0059	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 100, \beta = 0.8,$ $I = 100$	909,26	169,64
EXP0060	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 100, \beta = 0.8,$ $I = 500$	908,75	849,80
EXP0061	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 100, \beta = 0.95,$ $I = 10$	903,93	72,71
EXP0062	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 100, \beta = 0.95,$ $I = 100$	905,55	729,23
EXP0063	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 100, \beta = 0.95,$ $I = 500$	907,57	3749,78
EXP0064	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 500, \beta = 0.4,$ $I = 10$	900,93	6,04
EXP0065	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 500, \beta = 0.4,$ $I = 100$	905,65	50,12
EXP0066	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 500, \beta = 0.4,$ $I = 500$	901,11	279,99
EXP0067	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 500, \beta = 0.8,$ $I = 10$	898,35	20,30
EXP0068	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 500, \beta = 0.8,$ $I = 100$	898,36	204,42
EXP0069	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 500, \beta = 0.8,$ $I = 500$	899,38	1232,06
EXP0070	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 500, \beta = 0.95,$ $I = 10$	906,37	85,51
EXP0071	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 500, \beta = 0.95,$ $I = 100$	907,66	1029,12
EXP0072	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 500, \beta = 0.95,$ $I = 500$	908,60	7555,68
EXP0073	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 1000, \beta = 0.4,$ $I = 10$	903,62	6,39
EXP0074	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 1000, \beta = 0.4,$ $I = 100$	900,60	58,82
EXP0075	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 1000, \beta = 0.4,$ $I = 500$	905,38	410,07
EXP0076	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 1000, \beta = 0.8,$ $I = 10$	907,27	21,57
EXP0077	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 1000, \beta = 0.8,$ $I = 100$	908,63	255,41

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter. G.	Parâmetros	Dist. (km)	Tempo (s)
EXP0078	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 1000, \beta = 0.8,$ $I = 500$	903,45	2186,14
EXP0079	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 1000, \beta = 0.95,$ $I = 10$	904,44	96,41
EXP0080	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 1000, \beta = 0.95,$ $I = 100$	906,99	1685,28
EXP0081	Setorizado (FW)	Simulated Annealing	0.1	5	$T_0 = 1000, \beta = 0.95,$ $I = 500$	904,95	14098,54
EXP0082	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.4,$ $I = 10$	920,54	1,24
EXP0083	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.4,$ $I = 100$	914,57	8,84
EXP0084	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.4,$ $I = 500$	923,69	43,16
EXP0085	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.8,$ $I = 10$	918,97	3,81
EXP0086	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.8,$ $I = 100$	912,66	34,15
EXP0087	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.8,$ $I = 500$	914,72	172,02
EXP0088	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.95,$ $I = 10$	920,77	15,04
EXP0089	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.95,$ $I = 100$	905,80	147,28
EXP0090	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.95,$ $I = 500$	898,38	745,21
EXP0091	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 500, \beta = 0.4,$ $I = 10$	910,48	1,40
EXP0092	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 500, \beta = 0.4,$ $I = 100$	910,48	10,58
EXP0093	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 500, \beta = 0.4,$ $I = 500$	917,68	56,21
EXP0094	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 500, \beta = 0.8,$ $I = 10$	914,04	4,26
EXP0095	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 500, \beta = 0.8,$ $I = 100$	915,80	41,12
EXP0096	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 500, \beta = 0.8,$ $I = 500$	917,98	257,05
EXP0097	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 500, \beta = 0.95,$ $I = 10$	900,12	17,51
EXP0098	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 500, \beta = 0.95,$ $I = 100$	909,29	202,00
EXP0099	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 500, \beta = 0.95,$ $I = 500$	912,12	1517,39
EXP0100	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 1000, \beta = 0.4,$ $I = 10$	910,40	1,44
EXP0101	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 1000, \beta = 0.4,$ $I = 100$	912,42	11,98
EXP0102	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 1000, \beta = 0.4,$ $I = 500$	908,08	86,42
EXP0103	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 1000, \beta = 0.8,$ $I = 10$	917,23	4,58
EXP0104	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 1000, \beta = 0.8,$ $I = 100$	906,15	51,45

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter. G.	Parâmetros	Dist. (km)	Tempo (s)
EXP0105	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 1000, \beta = 0.8,$ $I = 500$	916,01	454,23
EXP0106	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 1000, \beta = 0.95,$ $I = 10$	917,91	19,81
EXP0107	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 1000, \beta = 0.95,$ $I = 100$	912,82	319,43
EXP0108	Setorizado (FW)	Simulated Annealing	0.5	1	$T_0 = 1000, \beta = 0.95,$ $I = 500$	912,74	2791,02
EXP0109	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 100, \beta = 0.4,$ $I = 10$	901,26	3,33
EXP0110	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 100, \beta = 0.4,$ $I = 100$	893,11	25,88
EXP0111	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 100, \beta = 0.4,$ $I = 500$	902,26	128,45
EXP0112	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 100, \beta = 0.8,$ $I = 10$	901,77	10,93
EXP0113	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 100, \beta = 0.8,$ $I = 100$	894,82	102,56
EXP0114	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 100, \beta = 0.8,$ $I = 500$	893,87	514,88
EXP0115	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 100, \beta = 0.95,$ $I = 10$	896,91	44,53
EXP0116	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 100, \beta = 0.95,$ $I = 100$	886,88	439,92
EXP0117	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 100, \beta = 0.95,$ $I = 500$	893,59	2258,41
EXP0118	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 500, \beta = 0.4,$ $I = 10$	895,15	3,75
EXP0119	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 500, \beta = 0.4,$ $I = 100$	898,94	30,36
EXP0120	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 500, \beta = 0.4,$ $I = 500$	908,47	170,43
EXP0121	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 500, \beta = 0.8,$ $I = 10$	902,79	12,51
EXP0122	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 500, \beta = 0.8,$ $I = 100$	897,64	121,87
EXP0123	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 500, \beta = 0.8,$ $I = 500$	900,17	755,68
EXP0124	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 500, \beta = 0.95,$ $I = 10$	894,21	52,08
EXP0125	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 500, \beta = 0.95,$ $I = 100$	900,47	630,82
EXP0126	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 500, \beta = 0.95,$ $I = 500$	896,18	4532,20
EXP0127	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 1000, \beta = 0.4,$ $I = 10$	902,23	3,96
EXP0128	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 1000, \beta = 0.4,$ $I = 100$	893,62	35,76
EXP0129	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 1000, \beta = 0.4,$ $I = 500$	891,20	247,61
EXP0130	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 1000, \beta = 0.8,$ $I = 10$	904,52	12,92
EXP0131	Setorizado (FW)	Simulated Annealing	0.5	3	$T_0 = 1000, \beta = 0.8,$ $I = 100$	894,23	158,51

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter. G.	Parâmetros	Dist. (km)	Tempo (s)
EXP0132	Setorizado	Simulated	0.5	3	$T_0 = 1000, \beta = 0.8,$	905,29	1347,33
	(FW)	Annealing			$I = 500$		
EXP0133	Setorizado	Simulated	0.5	3	$T_0 = 1000, \beta = 0.95,$	903,07	59,73
	(FW)	Annealing			$I = 10$		
EXP0134	Setorizado	Simulated	0.5	3	$T_0 = 1000, \beta = 0.95,$	898,13	1022,87
	(FW)	Annealing			$I = 100$		
EXP0135	Setorizado	Simulated	0.5	3	$T_0 = 1000, \beta = 0.95,$	897,02	8414,00
	(FW)	Annealing			$I = 500$		
EXP0136	Setorizado	Simulated	0.5	5	$T_0 = 100, \beta = 0.4,$	899,72	5,39
	(FW)	Annealing			$I = 10$		
EXP0137	Setorizado	Simulated	0.5	5	$T_0 = 100, \beta = 0.4,$	902,07	43,12
	(FW)	Annealing			$I = 100$		
EXP0138	Setorizado	Simulated	0.5	5	$T_0 = 100, \beta = 0.4,$	895,30	213,86
	(FW)	Annealing			$I = 500$		
EXP0139	Setorizado	Simulated	0.5	5	$T_0 = 100, \beta = 0.8,$	883,79	17,96
	(FW)	Annealing			$I = 10$		
EXP0140	Setorizado	Simulated	0.5	5	$T_0 = 100, \beta = 0.8,$	898,06	167,68
	(FW)	Annealing			$I = 100$		
EXP0141	Setorizado	Simulated	0.5	5	$T_0 = 100, \beta = 0.8,$	891,49	846,79
	(FW)	Annealing			$I = 500$		
EXP0142	Setorizado	Simulated	0.5	5	$T_0 = 100, \beta = 0.95,$	890,42	73,77
	(FW)	Annealing			$I = 10$		
EXP0143	Setorizado	Simulated	0.5	5	$T_0 = 100, \beta = 0.95,$	898,41	738,97
	(FW)	Annealing			$I = 100$		
EXP0144	Setorizado	Simulated	0.5	5	$T_0 = 100, \beta = 0.95,$	883,96	3763,28
	(FW)	Annealing			$I = 500$		
EXP0145	Setorizado	Simulated	0.5	5	$T_0 = 500, \beta = 0.4,$	886,66	6,11
	(FW)	Annealing			$I = 10$		
EXP0146	Setorizado	Simulated	0.5	5	$T_0 = 500, \beta = 0.4,$	896,31	50,83
	(FW)	Annealing			$I = 100$		
EXP0147	Setorizado	Simulated	0.5	5	$T_0 = 500, \beta = 0.4,$	899,99	283,80
	(FW)	Annealing			$I = 500$		
EXP0148	Setorizado	Simulated	0.5	5	$T_0 = 500, \beta = 0.8,$	894,46	20,16
	(FW)	Annealing			$I = 10$		
EXP0149	Setorizado	Simulated	0.5	5	$T_0 = 500, \beta = 0.8,$	891,15	207,64
	(FW)	Annealing			$I = 100$		
EXP0150	Setorizado	Simulated	0.5	5	$T_0 = 500, \beta = 0.8,$	897,55	1248,81
	(FW)	Annealing			$I = 500$		
EXP0151	Setorizado	Simulated	0.5	5	$T_0 = 500, \beta = 0.95,$	897,08	87,08
	(FW)	Annealing			$I = 10$		
EXP0152	Setorizado	Simulated	0.5	5	$T_0 = 500, \beta = 0.95,$	902,65	1026,40
	(FW)	Annealing			$I = 100$		
EXP0153	Setorizado	Simulated	0.5	5	$T_0 = 500, \beta = 0.95,$	897,06	7558,63
	(FW)	Annealing			$I = 500$		
EXP0154	Setorizado	Simulated	0.5	5	$T_0 = 1000, \beta = 0.4,$	899,20	6,49
	(FW)	Annealing			$I = 10$		
EXP0155	Setorizado	Simulated	0.5	5	$T_0 = 1000, \beta = 0.4,$	896,71	60,17
	(FW)	Annealing			$I = 100$		
EXP0156	Setorizado	Simulated	0.5	5	$T_0 = 1000, \beta = 0.4,$	892,82	417,78
	(FW)	Annealing			$I = 500$		
EXP0157	Setorizado	Simulated	0.5	5	$T_0 = 1000, \beta = 0.8,$	888,51	21,76
	(FW)	Annealing			$I = 10$		
EXP0158	Setorizado	Simulated	0.5	5	$T_0 = 1000, \beta = 0.8,$	899,45	267,36
	(FW)	Annealing			$I = 100$		

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter. G.	Parâmetros	Dist. (km)	Tempo (s)
EXP0159	Setorizado (FW)	Simulated Annealing	0.5	5	$T_0 = 1000, \beta = 0.8,$ $I = 500$	890,72	2184,77
EXP0160	Setorizado (FW)	Simulated Annealing	0.5	5	$T_0 = 1000, \beta = 0.95,$ $I = 10$	898,72	100,46
EXP0161	Setorizado (FW)	Simulated Annealing	0.5	5	$T_0 = 1000, \beta = 0.95,$ $I = 100$	886,57	1695,62
EXP0162	Setorizado (FW)	Simulated Annealing	0.5	5	$T_0 = 1000, \beta = 0.95,$ $I = 500$	903,98	14300,02
EXP0163	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 100, \beta = 0.4,$ $I = 10$	908,41	1,28
EXP0164	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 100, \beta = 0.4,$ $I = 100$	919,99	8,89
EXP0165	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 100, \beta = 0.4,$ $I = 500$	907,10	42,49
EXP0166	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 100, \beta = 0.8,$ $I = 10$	916,01	3,84
EXP0167	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 100, \beta = 0.8,$ $I = 100$	909,46	34,27
EXP0168	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 100, \beta = 0.8,$ $I = 500$	914,50	170,63
EXP0169	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 100, \beta = 0.95,$ $I = 10$	923,69	15,16
EXP0170	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 100, \beta = 0.95,$ $I = 100$	913,35	149,86
EXP0171	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 100, \beta = 0.95,$ $I = 500$	904,81	753,14
EXP0172	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 500, \beta = 0.4,$ $I = 10$	903,15	1,39
EXP0173	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 500, \beta = 0.4,$ $I = 100$	918,96	10,69
EXP0174	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 500, \beta = 0.4,$ $I = 500$	914,11	55,35
EXP0175	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 500, \beta = 0.8,$ $I = 10$	910,03	4,24
EXP0176	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 500, \beta = 0.8,$ $I = 100$	920,35	41,57
EXP0177	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 500, \beta = 0.8,$ $I = 500$	909,84	247,79
EXP0178	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 500, \beta = 0.95,$ $I = 10$	906,41	17,18
EXP0179	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 500, \beta = 0.95,$ $I = 100$	910,76	210,02
EXP0180	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 500, \beta = 0.95,$ $I = 500$	912,39	1482,62
EXP0181	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 1000, \beta = 0.4,$ $I = 10$	910,13	1,48
EXP0182	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 1000, \beta = 0.4,$ $I = 100$	925,83	12,40
EXP0183	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 1000, \beta = 0.4,$ $I = 500$	917,54	82,05
EXP0184	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 1000, \beta = 0.8,$ $I = 10$	909,10	4,51
EXP0185	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 1000, \beta = 0.8,$ $I = 100$	915,66	53,73

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter. G.	Parâmetros	Dist. (km)	Tempo (s)
EXP0186	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 1000, \beta = 0.8,$ $I = 500$	913,84	441,04
EXP0187	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 1000, \beta = 0.95,$ $I = 10$	909,97	20,25
EXP0188	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 1000, \beta = 0.95,$ $I = 100$	902,16	340,96
EXP0189	Setorizado (FW)	Simulated Annealing	0.8	1	$T_0 = 1000, \beta = 0.95,$ $I = 500$	924,52	2760,35
EXP0190	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 100, \beta = 0.4,$ $I = 10$	899,74	3,37
EXP0191	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 100, \beta = 0.4,$ $I = 100$	902,76	26,06
EXP0192	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 100, \beta = 0.4,$ $I = 500$	897,58	128,78
EXP0193	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 100, \beta = 0.8,$ $I = 10$	887,10	10,79
EXP0194	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 100, \beta = 0.8,$ $I = 100$	897,56	102,49
EXP0195	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 100, \beta = 0.8,$ $I = 500$	904,09	515,35
EXP0196	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 100, \beta = 0.95,$ $I = 10$	903,16	44,75
EXP0197	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 100, \beta = 0.95,$ $I = 100$	895,18	440,29
EXP0198	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 100, \beta = 0.95,$ $I = 500$	886,34	2247,39
EXP0199	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 500, \beta = 0.4,$ $I = 10$	900,01	3,78
EXP0200	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 500, \beta = 0.4,$ $I = 100$	894,25	31,17
EXP0201	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 500, \beta = 0.4,$ $I = 500$	892,67	168,50
EXP0202	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 500, \beta = 0.8,$ $I = 10$	900,85	12,47
EXP0203	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 500, \beta = 0.8,$ $I = 100$	899,28	125,94
EXP0204	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 500, \beta = 0.8,$ $I = 500$	897,70	759,62
EXP0205	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 500, \beta = 0.95,$ $I = 10$	897,01	52,22
EXP0206	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 500, \beta = 0.95,$ $I = 100$	902,20	629,88
EXP0207	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 500, \beta = 0.95,$ $I = 500$	897,04	4575,08
EXP0208	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 1000, \beta = 0.4,$ $I = 10$	901,99	4,00
EXP0209	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 1000, \beta = 0.4,$ $I = 100$	898,23	36,40
EXP0210	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 1000, \beta = 0.4,$ $I = 500$	899,77	247,76
EXP0211	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 1000, \beta = 0.8,$ $I = 10$	903,96	13,14
EXP0212	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 1000, \beta = 0.8,$ $I = 100$	898,00	158,21

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter. G.	Parâmetros	Dist. (km)	Tempo (s)
EXP0213	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 1000, \beta = 0.8,$ $I = 500$	898,75	1341,97
EXP0214	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 1000, \beta = 0.95,$ $I = 10$	905,94	60,57
EXP0215	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 1000, \beta = 0.95,$ $I = 100$	898,91	1035,59
EXP0216	Setorizado (FW)	Simulated Annealing	0.8	3	$T_0 = 1000, \beta = 0.95,$ $I = 500$	894,20	8507,30
EXP0217	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 100, \beta = 0.4,$ $I = 10$	892,25	5,46
EXP0218	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 100, \beta = 0.4,$ $I = 100$	897,79	43,40
EXP0219	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 100, \beta = 0.4,$ $I = 500$	893,55	212,86
EXP0220	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 100, \beta = 0.8,$ $I = 10$	897,63	18,24
EXP0221	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 100, \beta = 0.8,$ $I = 100$	886,01	170,61
EXP0222	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 100, \beta = 0.8,$ $I = 500$	903,53	866,95
EXP0223	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 100, \beta = 0.95,$ $I = 10$	898,91	74,82
EXP0224	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 100, \beta = 0.95,$ $I = 100$	888,51	739,44
EXP0225	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 100, \beta = 0.95,$ $I = 500$	889,82	3822,41
EXP0226	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 500, \beta = 0.4,$ $I = 10$	895,52	6,17
EXP0227	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 500, \beta = 0.4,$ $I = 100$	891,53	51,80
EXP0228	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 500, \beta = 0.4,$ $I = 500$	890,80	287,45
EXP0229	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 500, \beta = 0.8,$ $I = 10$	887,46	20,67
EXP0230	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 500, \beta = 0.8,$ $I = 100$	900,10	209,04
EXP0231	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 500, \beta = 0.8,$ $I = 500$	888,69	1279,38
EXP0232	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 500, \beta = 0.95,$ $I = 10$	899,92	88,13
EXP0233	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 500, \beta = 0.95,$ $I = 100$	891,46	1026,03
EXP0234	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 500, \beta = 0.95,$ $I = 500$	888,82	7598,34
EXP0235	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 1000, \beta = 0.4,$ $I = 10$	894,88	6,47
EXP0236	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 1000, \beta = 0.4,$ $I = 100$	899,33	61,78
EXP0237	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 1000, \beta = 0.4,$ $I = 500$	885,81	425,08
EXP0238	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 1000, \beta = 0.8,$ $I = 10$	888,79	21,87
EXP0239	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 1000, \beta = 0.8,$ $I = 100$	900,89	266,56

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter.	G. Parâmetros	Dist. (km)	Tempo (s)
EXP0240	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 1000, \beta = 0.8, I = 500$	898,87	2213,94
EXP0241	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 1000, \beta = 0.95, I = 10$	892,29	100,48
EXP0242	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 1000, \beta = 0.95, I = 100$	895,22	1699,56
EXP0243	Setorizado (FW)	Simulated Annealing	0.8	5	$T_0 = 1000, \beta = 0.95, I = 500$	890,64	14229,26
EXP0001	Setorizado (Dijkstra)	melhor lhoria	me- 0.1	1	-	905,97	80149,03
EXP0041	Setorizado (Dijkstra)	melhor lhoria	me- 0.8	5	-	873,84	413789,35
EXP0027	Setorizado (Dijkstra)	primeira lhoria	me- 0.5	5	-	894,71	205362,87
EXP0032	Setorizado (Dijkstra)	primeira lhoria	me- 0.8	1	-	906,93	28152,09
EXP0018	Setorizado (Dijkstra)	descida dômica	ran- 0.5	1	$I_{swap} = 50$	908,80	7,74
EXP0039	Setorizado (Dijkstra)	descida dômica	ran- 0.8	3	$I_{swap} = 100$	884,95	44,20
EXP0082	Setorizado (Dijkstra)	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.4, I = 10$	909,99	20,11
EXP0139	Setorizado (Dijkstra)	Simulated Annealing	0.5	5	$T_0 = 100, \beta = 0.8, I = 10$	888,19	378,73
EXP0001	Simplificado (Carvalho)	melhor lhoria	me- 0.1	1	-	204,21	173,17
EXP0041	Simplificado (Carvalho)	melhor lhoria	me- 0.8	5	-	201,38	869,13
EXP0027	Simplificado (Carvalho)	primeira lhoria	me- 0.5	5	-	202,39	199,20
EXP0032	Simplificado (Carvalho)	primeira lhoria	me- 0.8	1	-	203,01	43,09
EXP0018	Simplificado (Carvalho)	descida dômica	ran- 0.5	1	$I_{swap} = 50$	211,68	0,24
EXP0039	Simplificado (Carvalho)	descida dômica	ran- 0.8	3	$I_{swap} = 100$	199,86	0,90
EXP0082	Simplificado (Carvalho)	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.4, I = 10$	207,32	0,39
EXP0139	Simplificado (Carvalho)	Simulated Annealing	0.5	5	$T_0 = 100, \beta = 0.8, I = 10$	202,81	5,28
EXP0001	Malha Unificada	melhor lhoria	me- 0.1	1	-	1021,59	7212,48
EXP0041	Malha Unificada	melhor lhoria	me- 0.8	5	-	1001,06	35073,43
EXP0027	Malha Unificada	primeira lhoria	me- 0.5	5	-	1006,63	22052,26
EXP0032	Malha Unificada	primeira lhoria	me- 0.8	1	-	1021,71	6840,52
EXP0018	Malha Unificada	descida dômica	ran- 0.5	1	$I_{swap} = 50$	1010,20	1,83
EXP0039	Malha Unificada	descida dômica	ran- 0.8	3	$I_{swap} = 100$	1027,35	6,18
EXP0082	Malha Unificada	Simulated Annealing	0.5	1	$T_0 = 100, \beta = 0.4, I = 10$	1031,02	2,57

Continua na próxima página...

Continuação da Tabela 8 da página anterior

Exp.	Cenário	Busca local	α	Iter.	G.	Parâmetros	Dist. (km)	Tempo (s)
EXP0139	Malha Unificada	Simulated Annealing	0.5	5		$T_0 = 100, \beta = 0.8, I = 10$	1007,44	25,71