

UNIVERSIDADE FEDERAL DE OURO PRETO
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS
DEPARTAMENTO DE COMPUTAÇÃO

JOÃO PEDRO SILVA BICALHO

**EFEITOS DA LOCALIZAÇÃO DE ESTAÇÕES DE RECARGA NO
PROBLEMA DE COBERTURA COM DRONES SOB RESTRIÇÕES DE
AUTONOMIA**

Ouro Preto
2026

JOÃO PEDRO SILVA BICALHO

**EFEITOS DA LOCALIZAÇÃO DE ESTAÇÕES DE RECARGA NO PROBLEMA DE
COBERTURA COM DRONES SOB RESTRIÇÕES DE AUTONOMIA**

Monografia apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como parte dos requisitos necessários para a obtenção do grau de Bacharel em Ciência da Computação.

Orientadora: Prof. Dra. Fernanda Sumika Hojo de Souza

Ouro Preto
2026



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



FOLHA DE APROVAÇÃO

João Pedro Silva Bicalho

**EFEITOS DA LOCALIZAÇÃO DE ESTAÇÕES DE RECARGA EM PROBLEMAS DE COBERTURA COM DRONES E
RESTRIÇÕES DE AUTONOMIA**

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

Aprovada em 20 de Julho de 2026.

Membros da banca

Fernanda Sumika Hojo de Souza (Orientadora) - Doutora - Universidade Federal de Ouro Preto
Daniel Ludovico Guidoni (Examinador) - Doutor - Universidade Federal de Ouro Preto
Puca Huachi Vaz Penna (Examinador) - Doutor - Universidade Federal de Ouro Preto

Fernanda Sumika Hojo de Souza, Orientadora do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 20/07/2026.



Documento assinado eletronicamente por **Fernanda Sumika Hojo de Souza, PROFESSOR DE MAGISTERIO SUPERIOR**, em 28/07/2026, às 09:48, 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 **1142648** e o código CRC **687F6D50**.

Resumo

O uso de drones para a realização de entregas tem sido estudado como uma alternativa para reduzir custos operacionais e tempo de atendimento. Entretanto, a limitação da autonomia energética desses veículos impõe restrições importantes ao planejamento das operações. Neste trabalho é proposto um modelo matemático para o planejamento de entregas por drones considerando restrições energéticas e a possibilidade de utilização de estações de recarga intermediárias. O modelo tem como objetivo minimizar o consumo energético total do sistema, penalizando demandas não atendidas. O modelo decide simultaneamente a abertura de facilidades, a instalação de estações de recarga, a alocação dos clientes e as rotas multi-hop de ida e retorno, considerando consumo energético distinto para o voo com carga e sem carga. Os experimentos computacionais foram realizados utilizando o solver Gurobi, a partir de instâncias metropolitanas realísticas, de São Paulo e Portland, variando o número máximo de facilidades, o número máximo de estações de recarga, o número de drones e diferentes níveis percentuais de autonomia da bateria. Os resultados indicam que a cobertura não cresce linearmente com o número de estações instaladas. Observa-se um comportamento de limiar, no qual em níveis baixos de bateria, a rede permanece parcialmente desconectada mesmo com a instalação de novas estações; em níveis intermediários, as estações de recarga produzem ganhos expressivos de cobertura; e, em níveis elevados de autonomia, a cobertura satura rapidamente, tornando estações adicionais menos relevantes. A comparação entre São Paulo e Portland mostra que a efetividade da infraestrutura de recarga depende da distribuição espacial dos clientes e dos locais candidatos. Além disso, os resultados evidenciam que aumentar o número de facilidades tende a reduzir o consumo médio de energia e o número médio de saltos nas rotas. A formulação exata resolveu a maior parte dos cenários em tempo computacional adequado, indicando sua viabilidade para análises estratégicas de planejamento de infraestrutura em redes urbanas de entrega por drones.

Palavras-chave: Drones. Estações de recarga. Planejamento de entregas. Modelagem matemática. Otimização..

Abstract

The use of drones for delivery operations has been studied as an alternative to reduce operational costs and service times. However, the limited energy autonomy of these vehicles imposes significant constraints on operational planning. This study proposes a mathematical model for drone delivery planning that accounts for energy constraints and the potential use of intermediate charging stations. The model aims to minimize the system's total energy consumption while penalizing unfulfilled demands. It simultaneously determines facility openings, charging station installations, customer allocation, and multi-hop round-trip routes, distinguishing between energy consumption for loaded and unloaded flights. Computational experiments were conducted using the Gurobi solver based on realistic metropolitan instances from São Paulo and Portland, varying the maximum number of facilities, charging stations, and drones, as well as battery autonomy levels. The results indicate that coverage does not increase linearly with the number of installed stations. A threshold behavior is observed: at low battery levels, the network remains partially disconnected despite the installation of new stations; at intermediate levels, charging stations yield significant coverage gains; and at high autonomy levels, coverage quickly saturates, rendering additional stations less relevant. A comparison between São Paulo and Portland reveals that the effectiveness of the charging infrastructure depends on the spatial distribution of customers and candidate locations. Furthermore, the results demonstrate that increasing the number of facilities tends to reduce both average energy consumption and the average number of hops per route. The exact formulation solved most scenarios within a reasonable timeframe, indicating its viability for strategic infrastructure planning analyses in urban drone delivery networks.

Keywords: Drones. Recharging stations. Delivery planning. Mathematical modeling. Optimization.

Lista de Figuras

Figura 4.1 – Mapa da região metropolitana de Portland	17
Figura 4.2 – Mapa da região metropolitana de São Paulo	18
Figura 4.3 – Histograma de potencial de alcance das demandas - Sem Estações	19
Figura 4.4 – Distribuição acumulada do percentual de alcance das demandas	20
Figura 4.5 – Histograma de potencial de alcance das demandas - Todas as estações disponíveis	21
Figura 4.6 – Efeito do aumento da autonomia da bateria B - Portland	23
Figura 4.7 – Efeito do aumento da autonomia da bateria B - São Paulo	25
Figura 4.8 – Solução gráfica para a instância de Portland - $P = 1, q = 9$ e $B = 1$	26
Figura 4.9 – Solução gráfica para a instância de São Paulo - $P = 2, q = 9$ e $B = 0.60$	27
Figura 4.10–Energia média para casos de cobertura máxima - Portland	28
Figura 4.11–Energia média para casos de cobertura máxima - São Paulo	29
Figura 4.12–Dispersão de pontos de arcos médios em relação à cobertura - Portland	30
Figura 4.13–Dispersão de pontos de arcos médios em relação a cobertura - São Paulo	30

Lista de Tabelas

Tabela 4.1 – Parâmetros comuns utilizados na configuração das instâncias	20
Tabela 4.2 – Parâmetros específicos utilizados na configuração das instâncias	21
Tabela 4.3 – Número mínimo de estações de recarga necessário para atingir 100% de cobertura da demanda	25
Tabela 4.4 – Todos os cenários que atingiram o limite de tempo (3600 s)	31

Lista de Abreviaturas e Siglas

IAGen	Inteligência Artificial Generativa
IoT	<i>Internet of Things</i>
ONU	Organização das Nações Unidas
OSM	<i>OpenStreetMap</i>
PL	Programação Linear
PLI	Programação Linear Inteira
POIs	Pontos de Interesse
RMSP	Região Metropolitana de São Paulo
UAVs	<i>Unmanned Aerial Vehicles</i>
UFOP	Universidade Federal de Ouro Preto
VANTs	Veículos Aéreos Não Tripulados
ZCTAs	Áreas Tabuladas de Códigos Postais

Sumário

1	Introdução	1
1.1	Problema de Localização de Facilidades e Alocação de Drones	2
1.2	Objetivos	3
1.2.1	Objetivo geral	3
1.2.2	Objetivos específicos	3
1.3	Justificativa	3
1.4	Organização do Trabalho	4
2	Fundamentação Teórica	5
2.1	Cidades Inteligentes e Logística Urbana	5
2.2	Trabalhos Relacionados	6
2.3	Técnicas de Otimização	8
3	Metodologia	10
3.1	Modelagem	10
3.1.1	Rede de fluxo	11
3.1.2	Formulação Matemática	11
3.1.3	Restrições de Atendimento	12
3.1.4	Restrições de Conservação de Fluxo	13
3.1.5	Restrição de Ativação das Estações	13
3.1.6	Restrições Estruturais	13
3.1.7	Função Objetivo	13
3.1.8	Pré-processamento das Instâncias	16
3.2	Ferramentas e Ambiente Computacional	16
4	Resultados	17
4.1	Métricas de Avaliação	21
4.2	Análise dos Resultados	22
5	Considerações Finais	33
5.1	Conclusão	33
5.2	Trabalhos Futuros	34
	Referências	36
	Apêndices	38
	APÊNDICE A Pontos de Facilidades - São Paulo	39
	APÊNDICE B Pontos de demanda - São Paulo	47
	APÊNDICE C Resultados do modelo para instância de Portland	53

APÊNDICE D	Resultados do modelo para instância de São Paulo	55
Anexos		57
ANEXO A	Pontos de Facilidades - Portland	58
ANEXO B	Pontos de demandas - Portland	61
ANEXO C	Parâmetros referentes aos drones	65

1 Introdução

O acelerado processo de urbanização tem intensificado desafios relacionados à infraestrutura e à mobilidade nos grandes centros urbanos. Conforme projeção da Organização das Nações Unidas (ONU), espera-se que 66% da população global seja urbana até 2050. Atualmente, em decorrência desse processo de expansão demográfica, estima-se que as cidades consumam 75% de toda a energia gerada, sendo responsáveis por quase 80% da emissão de gases de efeito estufa (Silva; Khan; Han, 2018). Intrinsecamente ligado a esse alto consumo energético e às emissões de poluentes, destaca-se o desafio da mobilidade urbana. Esse processo de crescimento intensifica problemas referentes à infraestrutura de transportes, como congestionamentos, escassez de recursos e degradação da malha viária (Gentili et al., 2022).

Adicionalmente, a ascensão do *e-commerce* implicou o aumento da utilização do modal viário para o transporte de cargas e mercadorias nos grandes centros urbanos. As operações logísticas de última milha (*last-mile delivery*) — referentes aos trajetos entre os centros de distribuição e o consumidor final — são predominantemente realizadas por motocicletas, vans e furgões. Dessa forma, contribuem ainda mais com a emissão de gases e saturação da malha viária, o que impulsiona a busca por formas alternativas de transporte.

Diante dos impactos logísticos e ambientais derivados do intenso crescimento populacional, consolidou-se o conceito de cidades inteligentes, cujo propósito é mitigar e solucionar estes desafios urbanos. Um de seus objetivos principais consiste em melhorar a qualidade de vida e mantê-la para as próximas gerações (Silva; Khan; Han, 2018). Cidades inteligentes promovem a integração das Tecnologias da Informação e Comunicação nas operações urbanas para que se tornem mais eficientes. Suas principais áreas de atuação são o gerenciamento de energia, transporte e saúde, visando justamente atender às demandas do crescimento desordenado da urbanização (Silva; Khan; Han, 2018).

Uma das propostas das cidades inteligentes para o problema logístico de última milha envolve a utilização de drones para esse tipo de entrega. Estes veículos apresentam diversas vantagens operacionais para o transporte de cargas, além de terem uma elevada eficiência energética, melhor mobilidade, maior capacidade de acesso a áreas remotas e de emitirem menos poluentes (Mohsan et al., 2022). Atualmente, corporações como a Zipline (Zipline, 2026) executam entregas de última milha, abrangendo produtos médicos, alimentos, itens de varejo e produtos agrícolas. A referida companhia dispõe de duas infraestruturas operacionais: uma para entregas de longo alcance e outra para entregas residenciais, atuando, atualmente, em sete países diferentes.

No cenário brasileiro, a empresa iFood iniciou a implementação de drones como uma solução logística para acesso a áreas remotas (iFood, 2026). Neste caso, o projeto tende a associar o uso de drones e de entregadores terrestres de modo a formar uma frota heterogênea. Esta

iniciativa ainda se encontra em fase inicial, porém tem recebido investimentos expressivos e ainda depende da adaptação da regulamentação para a operação de drones em maior escala.

Apesar deste potencial inovador, um dos principais desafios para adotar drones é a limitação do alcance operacional (Ghelichi; Gentili; Mirchandani, 2021). Estes veículos possuem autonomia restrita, estritamente dependente da capacidade de armazenamento de suas baterias. Tal limitação é diretamente proporcional à carga que estará transportando, pois quanto mais pesado o veículo estiver, maior será o consumo energético e, portanto, menor a sua autonomia de voo.

Devido a essa limitação operacional, a utilização dos drones para cobrir grandes áreas urbanas partindo de apenas um centro de distribuição torna-se inviável, sendo necessária a implantação de estruturas adicionais de apoio na região de atendimento. Como alternativas viáveis, destaca-se a instalação de múltiplos centros de lançamento, visando distribuí-los estrategicamente para que consigam abranger um maior número de clientes, bem como a adição de estações de recarga ao longo das rotas (Ghelichi; Gentili; Mirchandani, 2021), de forma a recarregar as baterias dos drones e ampliar o alcance operacional.

A decisão sobre a localização dos centros de lançamento e das estações de recarga, juntamente com a escolha de quais veículos da frota atenderão cada cliente, não é uma tarefa trivial. Estas definições envolvem um grande número de combinações possíveis, caracterizando um problema de elevada complexidade computacional. Problemas desta natureza são frequentemente modelados como problemas de localização de facilidades com cobertura máxima, em que se busca maximizar a cobertura de atendimento a demandas ou então minimizar o custo operacional sob restrições rígidas de autonomia e tempo.

1.1 Problema de Localização de Facilidades e Alocação de Drones

O problema abordado caracteriza-se como uma variação do *Maximum Covering Location Problem* (Megiddo; Zemel; Hakimi, 1983) aplicado à logística de drones. O cenário consiste em um conjunto de pontos de demanda dispersos em uma área e um conjunto de locais candidatos à instalação de facilidades, além de um conjunto de possíveis pontos para estações de recarga. O objetivo do problema é selecionar um subconjunto ótimo de instalações que maximize a quantidade total de demanda atendida, respeitando os recursos limitados e as restrições do sistema.

Adicionalmente, devem ser consideradas restrições referentes à autonomia dinâmica dos drones, baseadas na modelagem de uma função dependente da distância e da carga transportada. O custo energético do percurso é mensurado pela soma do gasto da ida (com carga) e da volta (sem carga) entre o cliente e a facilidade designada. As estações de recarga atuam como infraestrutura

intermediária para ampliar o raio de ação dos veículos, possibilitando o atendimento das demandas mais remotas que não poderiam ser alcançadas em um voo direto sem esse intermédio.

Para garantir a viabilidade da solução, o problema impõe ainda restrições para que cada drone seja alocado a apenas uma facilidade e que a capacidade de atendimento de cada depósito não seja excedida. Portanto, a solução do modelo retornará a localização ótima dos depósitos e das estações de recarga, bem como a alocação das demandas aos drones, de modo que o atendimento da demanda coberta seja maximizado dentro das limitações energéticas impostas.

1.2 Objetivos

1.2.1 Objetivo geral

Desenvolver e analisar um modelo de otimização para o problema de localização de facilidades e estações de recarga visando maximizar a cobertura por drones em cidades inteligentes.

1.2.2 Objetivos específicos

- Modelar matematicamente o problema proposto considerando as restrições de bateria e recarga;
- Analisar os efeitos da inclusão de estações de recarga na cobertura do sistema através de experimentos;
- Desenvolver um cenário realístico de teste para o modelo matemático apresentado.

1.3 Justificativa

A urgência em modernizar as operações logísticas urbanas — impulsionada pelo crescimento do comércio eletrônico e pela saturação da malha viária — motiva a busca por novos modais de transporte, visando tornar mais eficiente o transporte de cargas nas Cidades Inteligentes. A adoção de drones representa uma mudança de paradigma e apresenta benefícios como a redução de custos operacionais e de emissões de carbono. Porém, a autonomia energética dos drones constitui uma limitação operacional crítica para esta solução e, por isso, estudar onde se devem instalar pontos de recarga e analisar o impacto de sua implantação torna-se necessário.

No contexto da Ciência da Computação, a relevância se dá pela aplicação de métodos de otimização para a resolução do problema. A escolha da Pesquisa Operacional, especificamente através da modelagem matemática e de métodos heurísticos, justifica-se pela natureza NP-Difícil do problema. Em cenários reais, com múltiplas variáveis, a busca por soluções ótimas por métodos empíricos torna-se inviável. O uso de técnicas de otimização permite não só encontrar

uma configuração de rede viável, mas também explorar fronteiras de eficiência que maximizem o retorno sobre o investimento em infraestrutura.

1.4 Organização do Trabalho

O restante deste trabalho está organizado da seguinte forma. O Capítulo 2 apresenta a revisão da literatura, abordando os principais conceitos relacionados à entrega por drones, problemas de cobertura, localização de facilidades e uso de estações de recarga em redes com restrições de autonomia. O Capítulo 3 descreve a metodologia do trabalho, incluindo a formulação matemática proposta, os dados utilizados e as ferramentas adotadas. O Capítulo 4 apresenta os cenários experimentais considerados e discute os resultados computacionais, analisando os efeitos da variação do número de facilidades, do número de estações de recarga e da autonomia dos drones sobre a cobertura, o consumo de energia e a estrutura das rotas. Por fim, o Capítulo 5 traz as conclusões do trabalho, destacando as principais contribuições, as limitações da abordagem proposta e possíveis direções para trabalhos futuros.

2 Fundamentação Teórica

Este capítulo apresenta o contexto no qual esta pesquisa está inserida. Inicialmente, são levantados os desafios presentes na logística urbana de cidades inteligentes, seguidos dos principais trabalhos relacionados que fundamentaram esta proposta. Por fim, destaca-se o papel das técnicas de otimização na resolução do problema abordado.

2.1 Cidades Inteligentes e Logística Urbana

O avanço das tecnologias digitais e da comunicação entre dispositivos tem transformado o modo como ambientes urbanos são planejados, monitorados e gerenciados. Avanços na computação ubíqua, em redes de sensores sem fio e na comunicação máquina-máquina impulsionaram a ideia de *Internet of Things* (IoT). De acordo com [Silva, Khan e Han \(2018\)](#), o conceito de cidades inteligentes surgiu a partir da aplicação da IoT, visando utilizar a tecnologia para apoiar a tomada de decisão contextual e tornar as cidades mais eficientes.

Segundo [Silva, Khan e Han \(2018\)](#), as cidades inteligentes têm como principal objetivo melhorar a qualidade de vida da população frente ao intenso crescimento urbano, garantindo também a disponibilidade de recursos para as gerações atuais e futuras. Esse desenvolvimento focado na sustentabilidade é um dos principais pilares desse novo paradigma. Entre os diversos desafios presentes nesse contexto, a mobilidade urbana e a logística de distribuição destacam-se por impactarem diretamente a eficiência operacional das cidades, o consumo energético, a emissão de poluentes e a qualidade dos serviços prestados. Dessa forma, a otimização dos sistemas logísticos torna-se um componente essencial para a construção de cidades inteligentes mais eficientes e resilientes.

O crescimento acelerado da urbanização e do comércio eletrônico intensificou a demanda por serviços de entrega rápida, tornando a logística de última milha um dos maiores desafios dos grandes centros urbanos. Este cenário decorre da predominância do transporte rodoviário como o principal modal para operações de distribuição urbana, o que sobrecarrega a infraestrutura existente. Como consequência dessa elevada dependência, aliada ao aumento contínuo da demanda, os congestionamentos tornam-se cada vez mais frequentes, visto que as vias públicas dividem sua capacidade entre veículos pessoais e frotas de entrega. Além dos impactos operacionais, esse modelo logístico tradicional eleva os custos do serviço e a emissão de gases poluentes, uma vez que grande parte da frota utiliza combustíveis fósseis.

Nesse contexto, a utilização de drones emerge como uma alternativa promissora, apresentando potencial para redução de custos operacionais e expressiva diminuição nas emissões de poluentes, por operarem exclusivamente com energia elétrica, como estudado e evidenciado por

Shavarani et al. (2018).

Um dos grandes benefícios da adoção de drones é que eles não dependem da infraestrutura viária, reduzindo a influência dos congestionamentos urbanos sobre os tempos de entrega (Mohsan et al., 2022). Entretanto, apesar destas vantagens, a utilização de Veículos Aéreos Não Tripulados (VANTs) em operações logísticas ainda enfrenta limitações técnicas importantes, sendo a restrição imposta pela capacidade energética da bateria um dos principais obstáculos para sua adoção em larga escala (Dukkanci; Campbell; Kara, 2024).

A limitação energética dos drones decorre principalmente da baixa densidade das baterias atuais, característica que restringe o tempo de voo e torna a autonomia altamente dependente da carga transportada e da distância percorrida. Como consequência, clientes localizados em regiões mais afastadas podem tornar-se inacessíveis para o atendimento direto. Para contornar essa barreira, diversas estratégias têm sido propostas na literatura, destacando-se a implantação de infraestruturas de apoio energético, como investigado nos estudos de Ghelichi, Gentili e Mirchandani (2021) e Shavarani et al. (2018).

2.2 Trabalhos Relacionados

A incorporação de drones às operações logísticas modificou a forma como os problemas clássicos de localização de facilidades são modelados. Conforme a classificação proposta por Dukkanci, Campbell e Kara (2024), a literatura de localização para drones divide-se majoritariamente entre o uso exclusivo de drones e sistemas híbridos com outros veículos. Este trabalho segue a primeira classe, introduzindo restrições relacionadas à autonomia energética, capacidade de carga, consumo dinâmico de bateria e planejamento de rotas. Um dos primeiros trabalhos a incorporar explicitamente o consumo de energia dos drones ao problema de localização foi proposto por Chauhan, Unnikrishnan e Figliozzi (2019), que formularam um modelo de cobertura máxima considerando simultaneamente a carga transportada, a distância percorrida e a autonomia da bateria. Contudo, essa abordagem apresenta limitações em cenários onde a dispersão geográfica dos pontos de demanda excede a autonomia de uma viagem de ida e volta (*round-trip*), inviabilizando o atendimento de clientes localizados além do raio operacional da base.

Com o objetivo de superar as limitações impostas pela autonomia das baterias, diferentes estratégias de infraestrutura passaram a ser incorporadas aos modelos de localização e roteamento. Entre essas abordagens, destaca-se a utilização de estações intermediárias de recarga, que permitem ampliar o alcance operacional dos veículos por meio de paradas ao longo da rota. Nesse contexto, Shavarani et al. (2018) propõem uma estrutura logística hierárquica composta por bases de lançamento e pontos de recarga, representando explicitamente a rede por meio de arestas para otimizar o planejamento das rotas. Em uma abordagem complementar, Ghelichi, Gentili e Mirchandani (2021) investigam a operação dessas estações considerando restrições de capacidade e coordenação do acesso por meio de *time-slots*, permitindo que múltiplos drones compartilhem

a infraestrutura de recarga de forma organizada. Em conjunto, esses estudos demonstram que a inserção de estações intermediárias amplia significativamente a flexibilidade operacional da rede logística.

Embora a incorporação de estações de recarga represente um avanço importante, grande parte dos modelos encontrados na literatura ainda considera o atendimento das demandas como uma restrição rígida. Nessa abordagem, clientes localizados em regiões remotas devem ser obrigatoriamente atendidos, mesmo quando isso implica trajetos excessivamente longos e elevados custos operacionais. Como consequência, soluções matematicamente viáveis podem se tornar ineficientes sob o ponto de vista econômico. Buscando flexibilizar essa característica, [Gentili et al. \(2022\)](#) propõem uma formulação baseada em uma função de desutilidade, permitindo penalizar situações em que o custo para atendimento supera o benefício obtido, além de considerar a realocação dinâmica de plataformas para operações envolvendo produtos perecíveis. Tal abordagem representa um avanço ao incorporar aspectos financeiros ao processo decisório, porém não investiga de forma específica o impacto da infraestrutura de recarga sobre o desempenho do sistema.

Um trabalho diretamente relacionado é apresentado por [Pinto e Lagorio \(2022\)](#), que propõem um modelo de projeto de rede para entregas ponto a ponto por drones com estações intermediárias de recarga. O modelo considera a localização das estações necessárias para conectar *hubs* previamente existentes aos pontos de entrega, de modo que clientes localizados além da autonomia direta possam ser atendidos. A função biobjetivo combina a minimização do número de estações instaladas (associada ao investimento em infraestrutura) e a minimização do comprimento total dos caminhos (associada ao custo operacional). Além do modelo exato, os autores propõem uma heurística baseada no pré-processamento de múltiplos caminhos mínimos, visando reduzir o tempo computacional em instâncias maiores. Como diferenças importantes em relação à presente proposta, destaca-se a consideração de *hubs* fixos e a obrigatoriedade de atendimento. A formulação desenvolvida nesta pesquisa, por sua vez, incorpora simultaneamente a seleção de facilidades, a possibilidade de não atendimento mediante penalização, rotas específicas de ida e retorno, e um cálculo de consumo energético diferenciado para deslocamentos com e sem carga.

Trabalhos mais recentes reforçam a relevância das restrições de autonomia e da infraestrutura de apoio em operações logísticas. [Liu \(2023\)](#) investigam um problema de roteamento de drones com restrição de bateria em uma rede com múltiplos depósitos, considerando decisões de atendimento através de uma abordagem integrada de otimização e simulação. Paralelamente, [Li et al. \(2026\)](#) integram a localização de estações de recarga e o planejamento de rotas de UAVs em redes de entrega de grande escala, propondo uma estrutura de otimização em cascata voltada à eficiência energética. Esses trabalhos evidenciam a importância da interface entre autonomia limitada, infraestrutura de recarga e planejamento de rotas.

Diante desse contexto, o presente trabalho propõe uma nova formulação matemática para

o problema de localização de facilidades com drones, baseada em uma representação de fluxo em rede capaz de modelar explicitamente o deslocamento dos drones entre facilidades, estações de recarga e clientes. Diferentemente dos trabalhos mais próximos encontrados na literatura, a formulação combina a minimização do consumo energético com penalidades para demandas não atendidas, permitindo analisar de forma integrada os efeitos da autonomia da bateria, da infraestrutura de recarga e da distribuição espacial das demandas sobre o desempenho do sistema.

Apesar dos avanços observados na literatura quanto à incorporação de estações de recarga em problemas de localização e roteamento de drones, a maior parte dos estudos concentra-se na proposição de novas estruturas de rede ou em estratégias para determinar sua localização ótima. Em contrapartida, ainda são escassos trabalhos que investiguem, de forma sistemática, como a quantidade de estações de recarga influencia o desempenho do sistema sob diferentes configurações operacionais. Aspectos como a interação entre a autonomia da bateria, o número de facilidades disponíveis, a distribuição espacial das demandas e o benefício efetivamente proporcionado pela infraestrutura de recarga permanecem pouco explorados de forma conjunta.

2.3 Técnicas de Otimização

A otimização representa um processo de busca pela melhor solução possível dentro de um conjunto de alternativas viáveis, dada por um critério específico de eficiência. A otimização matemática é essencial em várias áreas de estudo, como economia, engenharia e gestão. Nesse campo, utilizam-se definições e métodos matemáticos para retornar a melhor solução viável para um problema, definida como solução ótima. Este resultado é representado pelo valor atribuído às variáveis de decisão. A partir delas, junto a um conjunto de parâmetros, formula-se a função objetivo, que visa quantificar a qualidade da solução. Adicionalmente, o modelo deve respeitar um conjunto de restrições, as quais delimitam o espaço de viabilidade e tornam a formulação aderente ao mundo real.

As variáveis de decisão constituem um dos principais elementos dessa área e delimitam quais métodos podem ser usados para encontrar a solução ótima. A Programação Linear (PL) (Dantzig, 1963; Bazaraa; Jarvis; Sherali, 2004) resolve problemas em que as variáveis são contínuas. Embora a PL forneça soluções exatas e eficientes em diversos domínios, em muitos cenários práticos é indispensável que as variáveis de decisão pertençam ao conjunto dos inteiros. Por exemplo, no caso dos problemas de cobertura, a decisão de instalar ou não uma infraestrutura deve ser representada por variáveis binárias $\{0, 1\}$. Por isso, utiliza-se a Programação Linear Inteira (PLI) (Wolsey, 1998), na qual as variáveis se restringem ao conjunto dos inteiros ($x \in \mathbb{Z}$), tornando a resolução computacionalmente mais complexa que a PL convencional.

Problemas de PLI tendem a apresentar elevada complexidade computacional. À medida que o tamanho da rede aumenta, o número de combinações possíveis cresce exponencialmente, tornando a resolução mais difícil. Ainda assim, em diversas aplicações, modelos exatos podem

ser resolvidos de forma eficiente por *solvers* comerciais, que utilizam técnicas como *branch-and-bound* (Land; Doig, 1960), *branch-and-cut* (Wolsey, 1998), relaxações lineares e planos de corte (Gomory, 1958) para explorar o espaço de soluções. Neste trabalho, optou-se por utilizar uma formulação exata de PLI, uma vez que os cenários avaliados puderam ser resolvidos em tempo computacional adequado. Dessa forma, foi possível obter soluções ótimas ou com baixos valores de *gap*, permitindo analisar com maior precisão os efeitos da quantidade de facilidades, estações de recarga e autonomia dos drones sobre a cobertura e o consumo energético.

3 Metodologia

Este capítulo apresenta a metodologia adotada no desenvolvimento deste trabalho. A modelagem baseada em PLI envolve variáveis de decisão e restrições inerentes ao problema de cobertura por drones, sendo introduzidas juntamente com a notação adotada. Cada restrição é discutida, destacando-se sua importância no sistema de transporte e entrega. Por fim, as ferramentas computacionais adotadas são apresentadas na sequência.

3.1 Modelagem

O problema clássico de localização de facilidades com drones considera apenas o atendimento direto entre facilidades e clientes (Chauhan; Unnikrishnan; Figliozzi, 2019). Porém, devido às limitações impostas pela autonomia energética dos drones, o atendimento de parte das demandas pode se tornar inviável, reduzindo significativamente a cobertura do sistema, uma vez que esses clientes passam a estar fora do alcance prático. Nesse contexto, este trabalho propõe a incorporação de estações de recarga como elementos intermediários da rede logística, permitindo a ampliação do raio operacional dos veículos.

Com base nessa motivação, o presente estudo propõe uma extensão do problema clássico de localização de facilidades com drones, incorporando estações de recarga. O objetivo principal é minimizar o consumo energético total e a penalização associada a demandas não atendidas, respeitando restrições de capacidade das facilidades, orçamento energético dos drones e limites operacionais do sistema. Dessa forma, o modelo integra simultaneamente decisões de localização, roteamento e utilização de estações de recarga.

A formulação matemática é construída sobre três conjuntos principais: clientes, locais candidatos a facilidades e locais candidatos a estações de recarga. A modelagem apresentada adota uma representação de fluxo em rede, em contraste com abordagens como a de (Chauhan; Unnikrishnan; Figliozzi, 2019). Esta nova representação permite descrever explicitamente o percurso realizado pelos drones entre facilidades, estações de recarga e clientes, garantindo que as restrições energéticas sejam respeitadas em cada deslocamento e permitindo a utilização de múltiplas paradas intermediárias. Essa característica amplia o conjunto de clientes potencialmente atendidos sem exigir aumento da autonomia da bateria. Nesse modelo, as variáveis de decisão indicam a abertura de uma facilidade ou de uma estação de recarga, a alocação de clientes a uma facilidade e o fluxo na rede logística, representando os percursos (arcos) de ida e volta.

A definição da função objetivo como um problema de minimização visa priorizar as rotas de menor custo energético. Por outro lado, a inserção de uma penalidade para demandas não atendidas atua como um incentivo para maximizar a cobertura das demandas, uma vez que o

custo desta penalidade é substancialmente superior ao custo de operar uma rota longa.

3.1.1 Rede de fluxo

A formulação desenvolvida transforma os dados geográficos de entrada — como pontos de demanda, facilidades e estações de recarga — em nós de uma rede. Dessa forma, a rede representa explicitamente todas as possibilidades de deslocamento do drone entre esses pontos. Assim, para atender um cliente, o drone poderá se deslocar para outros nós, sempre obedecendo à sua autonomia energética. Este trajeto entre dois nós é denominado arco (*hop*) e é classificado em arcos de ida e de volta. A diferença entre eles reside na direção do trajeto e no peso do drone. A ausência de carga nos *hops* de volta implica em um menor consumo energético, uma vez que o drone fará menos esforço trator para se locomover. Para a ida, os seguintes arcos são possíveis:

- Sair de uma facilidade para um cliente;
- Sair de uma facilidade para uma estação de recarga;
- Sair de uma estação de recarga para um cliente;
- Sair de uma estação de recarga para outra estação de recarga.

Já para a volta, o drone é restrito a retornar para a mesma facilidade da qual partiu, podendo passar por diversas estações de recarga intermediárias. Os *hops* que os drones podem utilizar para retornar às suas bases são:

- Sair de um cliente para uma facilidade;
- Sair de um cliente para uma estação de recarga;
- Sair de uma estação de recarga para uma facilidade;
- Sair de uma estação de recarga para outra estação de recarga.

A partir dessas possibilidades de deslocamento, torna-se possível construir a rede direcionada utilizada na formulação matemática apresentada na seção seguinte.

3.1.2 Formulação Matemática

Sejam $\mathcal{I}$ o conjunto de clientes, $\mathcal{J}$ o conjunto de locais candidatos a facilidades e $\mathcal{R}$ o conjunto de locais candidatos a estações de recarga. Para cada cliente $i \in \mathcal{I}$, considera-se uma rota de ida, realizada com o pacote, e uma rota de volta, realizada sem o pacote. A partir dessas variáveis, os arcos viáveis são definidos com a seguinte formulação.

Os conjuntos A_i^+ e A_i^- representam apenas os arcos energeticamente viáveis.

$$A_i^+ = \{(u, v) : u \in \mathcal{J} \cup \mathcal{R}, v \in \mathcal{R} \cup \{i\}, u \neq v, e_{uv}^+ \leq B\}, \quad (3.1)$$

$$A_i^- = \{(u, v) : u \in \{i\} \cup \mathcal{R}, v \in \mathcal{R} \cup \mathcal{J}, u \neq v, e_{uv}^- \leq B\}. \quad (3.2)$$

O conjunto de todos os arcos viáveis de ida (A_i^+) que o drone pode utilizar durante a viagem até o cliente i é definido por (3.1). A equação garante que o nó de origem de um arco seja uma facilidade ou uma estação de recarga, e que o destino seja exclusivamente o cliente ou uma outra estação de recarga, evitando *loops* ($u \neq v$) e garantindo que o consumo e_{uv}^+ não supere a autonomia da bateria (B). Esta limitação energética elimina previamente os arcos inviáveis, reduzindo o espaço de busca do modelo, uma vez que não haverá variáveis de decisão para trajetos inacessíveis.

De maneira análoga, o conjunto de arcos viáveis de volta é representado por (3.2). Neste caso, o fluxo é invertido: os nós de origem são os clientes i ou uma estação de recarga, e o destino é outra estação de recarga ou uma base de facilidade, sempre respeitando a autonomia da bateria. A separação entre ida e volta é fundamental para o sistema, visto que os arcos terão custos energéticos diferentes. Isso ocorre porque um drone fará menos esforço na locomoção descarregado (volta) do que transportando carga (ida).

3.1.3 Restrições de Atendimento

Uma vez definida a alocação de um cliente a uma facilidade, o modelo deve garantir uma rota completa entre os dois. Desta forma, as restrições de atendimento estabelecem uma correspondência entre a decisão de alocação e a ativação dos arcos utilizados nas rotas.

Inicialmente, apenas facilidades podem ser nós de partida de uma rota de ida, como expresso na restrição (3.8). Assim, quando for definido que um cliente foi alocado a uma facilidade j , necessariamente haverá um arco em direção ao cliente partindo de j .

A partir do momento em que o drone sai de uma facilidade, ele deverá atender um cliente i . Se o modelo decidiu atender i , necessariamente haverá exclusivamente um arco de ida em direção a ele. Caso contrário, não haverá arcos em direção a i . Esta condição é assegurada por (3.10).

Já para a volta, a restrição (3.11) condiciona a existência de um arco de volta saindo do nó do cliente i , iniciando o caminho de retorno. Por fim, (3.9) garante o fechamento do ciclo, exigindo que o drone retorne diretamente à mesma facilidade j da qual partiu.

3.1.4 Restrições de Conservação de Fluxo

Durante as viagens, os drones poderão recarregar suas baterias em estações de recarga r . Para garantir que um drone utilize tais estruturas apenas como pontos intermediários, a restrição (3.12) define que, caso um drone carregado utilize um arco de ida incidente a r , deverá obrigatoriamente existir um arco de ida saindo de r , de modo que ele prossiga no trajeto rumo ao cliente.

Da mesma forma, há a necessidade de garantir que o drone, ao entregar um pacote ao cliente, retorne à sua base original, podendo fazer uso de estações de recarga. Se houver um arco de volta chegando a uma estação r , deverá também existir um arco de volta saindo de r , como garantido em (3.13).

3.1.5 Restrição de Ativação das Estações

Durante os trajetos de ida e volta, os drones poderão utilizar as estações de recarga. A partir de uma lista de candidatas, o modelo terá como parâmetro uma quantidade máxima de estruturas que podem ser instaladas. As restrições (3.14) e (3.15) definem que só poderá haver arcos de fluxo entrando e saindo delas se o modelo decidir pela sua ativação.

3.1.6 Restrições Estruturais

Uma das principais decisões do modelo é determinar se um cliente i será atendido ou não. Esta dinâmica está dividida em alocar uma única facilidade j que irá atender i , ou deixá-lo desatendido, sofrendo a devida penalização. Este cenário é regido por (3.4), que define o estado de atendimento do cliente. Além disso, o modelo só poderá alocar um cliente a uma facilidade se esta for definida como aberta dentre as opções candidatas, condição garantida por (3.6).

O modelo proposto define limites orçamentários para o número de estruturas que podem ser ativadas. As facilidades têm seu número delimitado por P , o que é garantido pela restrição (3.5). Da mesma maneira, o número limite de estações de recarga que poderão ser ativadas é garantido por (3.7).

3.1.7 Função Objetivo

Embora o problema envolva dois objetivos conflitantes, a formulação os incorpora em uma única função objetivo por meio da utilização de uma penalidade suficientemente elevada para o não atendimento. A princípio, a equação (3.3) define como objetivo minimizar o gasto energético dos drones, tanto nas rotas de ida quanto nas de volta. Porém, o termo da penalidade atua como um mecanismo de contrabalanço, induzindo o modelo a maximizar o atendimento à demanda. Isso acontece porque o valor da penalidade é projetado para ser significativamente alto,

de modo que não se justifica deixar de atender um cliente mesmo que a rota seja energeticamente custosa.

Seja a notação adotada a seguir.

Conjuntos Descrição

$\mathcal{I}$	Pontos de demanda
$\mathcal{J}$	Possíveis facilidades
$\mathcal{R}$	Possíveis pontos de recarga

Índices

$i \in \mathcal{I}$	Demandas
$j \in \mathcal{J}$	Facilidades
$r \in \mathcal{R}$	Estações de recarga

Parâmetros

B	Capacidade energética máxima da bateria do drone
P	Número máximo de facilidades a serem abertas
q	Número máximo de estações de recarga a serem abertas
Λ	Penalidade para clientes não atendidos
e_{iuv}^+	Energia consumida no arco (u, v) na rota de ida (com carga)
e_{iuv}^-	Energia consumida no arco (u, v) na rota de volta (sem carga)

Variáveis de decisão

y_j	1 se uma facilidade for aberta no local j , e 0 caso contrário.
v_r	1 se uma estação de recarga for instalada em r , e 0 caso contrário
z_{ij}	1 se o cliente i for alocado à facilidade j , e 0 caso contrário
u_i	1 se o cliente i não for atendido (penalizado), e 0 caso contrário
x_{iuv}^+	1 se o arco (u, v) for usado na rota de ida do cliente i , e 0 c.c.
x_{iuv}^-	1 se o arco (u, v) for usado na rota de volta do cliente i , e 0 c.c.

A formulação matemática do problema é dada por:

$$\min \sum_{i \in \mathcal{I}} \left(\sum_{(u,v) \in A_i^+} e_{iuv}^+ x_{iuv}^+ + \sum_{(u,v) \in A_i^-} e_{iuv}^- x_{iuv}^- \right) + \Lambda \sum_{i \in \mathcal{I}} u_i \quad (3.3)$$

sujeito a:

$$\sum_{j \in \mathcal{J}} z_{ij} + u_i = 1, \quad \forall i \in \mathcal{I}. \quad (3.4)$$

$$\sum_{j \in \mathcal{J}} y_j \leq P. \quad (3.5)$$

$$z_{ij} \leq y_j, \quad \forall i \in \mathcal{I}, j \in \mathcal{J}. \quad (3.6)$$

$$\sum_{r \in \mathcal{R}} v_r \leq q. \quad (3.7)$$

$$\sum_{(j,w) \in A_i^+} x_{ijw}^+ = z_{ij}, \quad \forall i \in \mathcal{I}, j \in \mathcal{J}. \quad (3.8)$$

$$\sum_{(w,j) \in A_i^-} x_{iww}^- = z_{ij}, \quad \forall i \in \mathcal{I}, j \in \mathcal{J}. \quad (3.9)$$

$$\sum_{(w,i) \in A_i^+} x_{iwi}^+ = 1 - u_i, \quad \forall i \in \mathcal{I}. \quad (3.10)$$

$$\sum_{(i,w) \in A_i^-} x_{iww}^- = 1 - u_i, \quad \forall i \in \mathcal{I}. \quad (3.11)$$

$$\sum_{(w,r) \in A_i^+} x_{iwr}^+ = \sum_{(r,w) \in A_i^+} x_{irw}^+, \quad \forall i \in \mathcal{I}, r \in \mathcal{R}. \quad (3.12)$$

$$\sum_{(w,r) \in A_i^-} x_{iwr}^- = \sum_{(r,w) \in A_i^-} x_{irw}^-, \quad \forall i \in \mathcal{I}, r \in \mathcal{R}. \quad (3.13)$$

$$x_{iuv}^+ \leq v_r, \quad \forall i \in \mathcal{I}, (u,v) \in A_i^+, r \in \{u,v\} \cap \mathcal{R}. \quad (3.14)$$

$$x_{iuv}^- \leq v_r, \quad \forall i \in \mathcal{I}, (u,v) \in A_i^-, r \in \{u,v\} \cap \mathcal{R}. \quad (3.15)$$

A formulação (3.3)-(3.15) pode ser resolvida através de algoritmos *branch-and-bound* e *branch-and-cut* disponíveis em pacotes de otimização. Embora instâncias menores e com configurações favoráveis de autonomia sejam passíveis de soluções exatas ou com pequenos valores de *gap* em tempo hábil, a avaliação experimental demonstrou que a resolução se torna intratável com o aumento do tamanho da malha urbana e da densidade de clientes. Esse rápido crescimento evidencia as limitações dos métodos exatos para instâncias de grande porte, o que motiva fortemente o desenvolvimento e a aplicação de abordagens heurísticas para este problema em trabalhos futuros.

3.1.8 Pré-processamento das Instâncias

As instâncias de entrada são pré-processadas antes de serem conduzidas à resolução via *solver*. Nesta etapa, são utilizadas as coordenadas geográficas dos pontos representando as facilidades, estações de recarga e demanda, além da massa referente ao pacote de cada cliente.

Com a definição dos nós, o cálculo das distâncias foi realizado com base em fórmulas propostas na literatura pertinente. Posteriormente, foi calculado também o gasto energético de ida e volta para cada cliente, em todos os possíveis arcos, valores que diferem entre si devido à presença da massa do pacote no trajeto de ida.

A partir dos dados de energia definidos, foram removidos os arcos cujo consumo energético fosse maior que a capacidade da bateria estipulada. Este processo elimina previamente deslocamentos inviáveis, reduzindo a quantidade de potenciais variáveis de fluxo criadas e, consequentemente, diminuindo o esforço computacional do algoritmo de otimização para explorar o espaço de busca.

3.2 Ferramentas e Ambiente Computacional

A implementação computacional do modelo matemático e dos métodos de solução foi realizada predominantemente na linguagem Python, justificando-se pela sua ampla disponibilidade de bibliotecas científicas e de otimização. Nesta linguagem, foram desenvolvidos a implementação do modelo, o pré-processamento dos dados e a análise dos resultados. Para a resolução deste modelo de PLI, foi utilizado o *solver* Gurobi ([Gurobi Optimization, LLC, 2024](#)), integrado por meio da interface *gurobipy*.

O pré-processamento de dados contou com a utilização da biblioteca NumPy para operações matriciais, do Pandas para o tratamento de dados estruturados e o Matplotlib para a geração de visualizações gráficas. Além destas, foram empregadas as bibliotecas GeoPandas para manipulação dos dados espaciais e o OSMnx para a obtenção dos pontos de interesse (POIs) diretamente da malha urbana, auxiliando no desenvolvimento da instância realística proposta.

Os experimentos computacionais foram conduzidos em um computador pessoal equipado com um processador Intel Core i7-7500U @ 2.70GHz, com 8 GB de memória RAM. A versão do Python utilizada foi a 3.13.1, e a do *gurobipy*, 11.0.3, operando sob o sistema Windows (64 bits).

4 Resultados

O modelo matemático avaliado neste capítulo consiste em uma extensão direta da formulação proposta por [Chauhan, Unnikrishnan e Figliozi \(2019\)](#), diferenciando-se primordialmente pela adição da infraestrutura de estações de recarga e pela possibilidade de rotas com múltiplas paradas. As instâncias de teste utilizadas neste trabalho foram baseadas no cenário proposto pelos referidos autores, que abordaram o problema de localização de facilidades com atendimento por drones na Região Metropolitana de Portland. Para a geração dos pontos no mapa, os autores definiram que o conjunto de clientes corresponderia aos centroides das Áreas Tabuladas de Códigos Postais (ZCTAs) da respectiva região, totalizando 122 pontos ($|I| = 122$). Por fim, definiu-se para cada um dos pontos um peso w_i distribuído entre 0, 5 kg e 5 kg, em intervalos granulares de 0, 25 kg. Os potenciais pontos de instalação foram definidos por localizações reais de centros comunitários, compondo um conjunto de 104 centros de lançamento ($|J| = 104$). Finalmente, dispôs-se um *grid* regular 5×5 composto por linhas verticais e horizontais igualmente espaçadas na área de interesse. As interseções destas linhas representaram os locais candidatos para a instalação das estações de recarga. A Figura 4.1 representa o cenário de Portland.




Figura 4.1 – Mapa da região metropolitana de Portland

Além do cenário da literatura considerado, por meio do *OpenStreetMap* (OSM)¹ e da biblioteca GeoPandas, foi gerado um novo cenário baseado na Região Metropolitana de São Paulo (RMSP). Foram considerados um conjunto de facilidades ($|J| = 295$) e um conjunto de clientes ($|I| = 200$). As facilidades correspondem a localidades reais de hospitais. As coordenadas das demandas foram geradas a partir dos centroides após aplicar a técnica de clusterização *K-means* aos setores censitários da RMSP para $k = 200$. As respectivas demandas foram geradas aleatoriamente segundo o seguinte procedimento: a soma de uma parte inteira (P_i) com uma parte fracionária (P_f), tal que $P_i \in \{1, 2, 3, 4, 5\}$ e $P_f \in \{0,25; 0,50; 0,75\}$. Ambas as partes foram selecionadas de forma aleatória e independente, seguindo uma distribuição uniforme. A Figura 4.2 ilustra o cenário em questão.




Figura 4.2 – Mapa da região metropolitana de São Paulo

As coordenadas dos potenciais pontos de facilidades e clientes foram obtidas através de dados realísticos em ambos os cenários. Por outro lado, os potenciais locais para instalação de estações de recarga em São Paulo foram gerados dispondo um *grid* regular 5×5 , da mesma maneira proposta para o cenário de Portland.

Para avaliar a escalabilidade do modelo e sua sensibilidade aos diferentes cenários, foram considerados diferentes valores para os parâmetros do problema, expandindo o conjunto para diversas instâncias de entrada. O limite de facilidades abertas (P) foi definido pelo conjunto $P \in \{1, 2, 3\}$; o limite de estações de recarga (q) variou de 0 até 15 (em incrementos de 3). Por fim, a partir do cálculo de autonomia da bateria do drone (B), baseado na literatura consolidada, foram

¹ www.openstreetmap.org

gerados cenários a partir de frações dessa capacidade, sendo eles $B' = \{0,4B; 0,6B; 0,8B; 1B\}$. Ao todo, foram avaliadas 72 instâncias de cada cenário, totalizando 144 execuções.

A estratégia avaliativa consistiu em uma análise comparativa entre considerar ($q \geq 1$) ou não considerar ($q = 0$) estações de recarga como intermediárias nas rotas para atingir os clientes. Em ambos os casos, foi estabelecido um limite de tempo de uma hora (3600 segundos).

Os cenários avaliados apresentam características espaciais distintas, sendo que algumas diferenças podem ser observadas visualmente. A concentração dos pontos no centro do mapa de São Paulo é significativamente maior que a de Portland, bem como os pontos de demanda são significativamente menos esparsos. Por isso, torna-se necessária uma análise prévia das instâncias para facilitar a interpretação adequada durante a comparação dos resultados.

A Figura 4.3 apresenta o potencial de alcance de cada potencial facilidade sem o uso de estações de recarga. O eixo x representa o percentual do total dos clientes que a facilidade consegue alcançar, enquanto o eixo y representa o percentual da quantidade de demandas que está no intervalo definido. Observa-se que as facilidades apresentam diferentes características espaciais, como mostra a predominância das facilidades de Portland nas menores faixas de cobertura. Verifica-se também que há um crescimento gradativo dos percentuais das facilidades de São Paulo. Essas observações indicam que os potenciais pontos de facilidades de Portland alcançam percentualmente menos clientes do que em São Paulo e que a seleção das facilidades para o problema tratado em Portland tende a ser mais restritiva pela esparsidade dos pontos de demanda.




Figura 4.3 – Histograma de potencial de alcance das demandas - Sem Estações

Ao analisar a distribuição acumulada, observa-se na Figura 4.4 que o conjunto de facilidades de São Paulo apresenta maior potencial de cobertura que o de Portland, já que a curva vermelha está projetada à direita da azul. Assim, São Paulo tem metade do seu conjunto de

facilidades atingindo de 40% a 70% dos clientes e o restante praticamente entre 0% e 40%. Já a instância de Portland tem aproximadamente metade do conjunto dividido em percentuais semelhantes nos intervalos de 0% até 40%, com algumas variações, e o restante se concentra no intervalo de 40% a 50%. Sendo assim, essa análise inicial sugere que os pontos de facilidade de Portland tendem a utilizar mais pontos de recarga do que os de São Paulo.




Figura 4.4 – Distribuição acumulada do percentual de alcance das demandas

Avaliou-se também o efeito da inserção das estações de recarga sobre a capacidade de cobertura das demandas, utilizando a mesma análise apresentada na Figura 4.3. A utilização de estações de recarga amplia o alcance operacional dos drones, conforme mostrado na Figura 4.5. Como o modelo considera a possibilidade de utilizar diversas estações no trajeto para chegar a um cliente, o alcance potencial é maximizado em ambos os cenários considerando a capacidade de bateria adotada como referência na literatura. Dessa forma, em ambas as instâncias é garantida a possibilidade de atingir toda a demanda por meio do uso de estações.

As Tabelas 4.1 e 4.2 resumizam os parâmetros utilizados na configuração das instâncias.

Tabela 4.1 – Parâmetros comuns utilizados na configuração das instâncias

Notação	Descrição	Valor
P	Número de facilidades abertas	[1, 2, 3]
q	Número de estações de recarga	[0 – 15]
η	Eficiência de transferência de energia	0,66
θ_s	Relação de elevação para arrasto	3, 5
B	Capacidade da bateria (Total)	$777Wh * 0,8$
$m_b + m_t$	Massa da bateria + massa do drone	10, 1

O consumo de energia das viagens de cada drone é calculado baseado na distância entre o cliente e a facilidade, na massa do drone e de sua bateria, na carga do pacote e nas constantes




Figura 4.5 – Histograma de potencial de alcance das demandas - Todas as estações disponíveis

Tabela 4.2 – Parâmetros específicos utilizados na configuração das instâncias

Notação	Descrição	Valor - Portland	Valor - São Paulo
I	Conjunto de clientes	$ I = 122$	$ I = 200$
J	Conjunto de potenciais facilidades	$ J = 104$	$ J = 295$
w_i	Demanda do cliente (carga)	$[0, 5 - 5, 0]$	$[1, 25 - 5, 75]$

de eficiência, gravidade e sustentação sobre arrasto. As equações (4.1) e (4.2) definem o cálculo de ida e volta entre dois nós u e v para o percurso do cliente i , respectivamente, seguindo as mesmas diretrizes adotadas em (Chauhan; Unnikrishnan; Figliozzi, 2019).

$$e_{uv}^+ = \frac{(m_t + m_b) + w_i}{\theta_s * \eta} * g * d_{uv} \quad (4.1)$$

$$e_{uv}^- = \frac{(m_t + m_b)}{\theta_s * \eta} * g * d_{uv} \quad (4.2)$$

4.1 Métricas de Avaliação

As avaliações das soluções encontradas serão feitas a partir de um conjunto de métricas quantitativas que demonstram tanto a qualidade operacional como o custo computacional. Os principais quesitos considerados são:

- Cobertura de demandas: Total da demanda atendida
- Energia total consumida: Soma dos custos de energia associados às rotas dos drones
- Número de hops: Número médio de arcos para atender um cliente

- Penalização por não atendimento: Valor agregado ao não atendimento de uma demanda. Cabe ressaltar que o valor desta penalidade foi calibrado para ser estritamente superior a qualquer custo energético, garantindo que o modelo sempre priorize o atendimento de um cliente em detrimento da redução do consumo energético da frota.
- Tempo computacional: O tempo total necessário para encontrar a solução

4.2 Análise dos Resultados

Os resultados obtidos permitem avaliar o impacto da inserção de estações de recarga sobre a cobertura das demandas, bem como analisar a influência dos parâmetros P , B e q no comportamento do modelo. Além disso, buscou-se identificar o ponto em que a abertura de novas estações deixa de produzir ganhos significativos de cobertura.

A autonomia da bateria é um dos fatores de maior influência sobre a cobertura das demandas. Na Figura 4.6, são apresentados os resultados para o cenário de Portland, onde os gráficos de linha evidenciam que o aumento da autonomia da bateria resulta diretamente em aumento do percentual de atendimento da demanda. Esse comportamento ocorre porque uma maior autonomia amplia o conjunto de rotas energeticamente viáveis, permitindo que clientes anteriormente inalcançáveis passem a ser atendidos. Para os três parâmetros de número de facilidades abertas (P), conclui-se também que a utilização de estações é benéfica para o modelo, uma vez que há um crescimento monotônico das curvas com o aumento das estações de recarga.




Figura 4.6 – Efeito do aumento da autonomia da bateria B - Portland

Contudo, em um certo ponto, os valores estagnam. Esse comportamento indica um fenômeno de saturação. Após determinado número de estações abertas, praticamente todos os clientes energeticamente alcançáveis já podem ser atendidos, de modo que novas estações deixam de gerar benefícios adicionais. Quando $B = 0.4$, entre 3 e 6 estações são suficientes para melhorar a cobertura, porém, a partir desse valor não há mais efeito prático expressivo. Com o aumento da autonomia, consegue-se visualizar que maiores $|q|$ implicam em mais cobertura, até que o sistema atinja seu limite estrutural, como nos casos de $B = 0.6$ e $B = 0.8$. Considerando um valor de bateria suficientemente grande, como no caso de $B = 1.0$, os valores mínimos de q já são suficientes para alcançar a melhor cobertura encontrada no cenário, em diferentes valores de P .

A Figura 4.6 mostra ainda que para os valores de P , as curvas para 2 e 3 se comportam e se aproximam bem mais do que as de 1 e 2, ainda mais com o aumento de q . Esse comportamento sugere que o ganho marginal obtido ao aumentar o número de facilidades diminui após determinado valor de P . Uma vez que as principais regiões de demanda já se encontram cobertas

por duas facilidades, a abertura de uma terceira facilidade produz um incremento relativamente pequeno na cobertura. Esse comportamento pode ser explicado pela maior área de cobertura proporcionada pela distribuição espacial das facilidades.

A Figura 4.7 indica um comportamento semelhante para a instância de São Paulo, embora esta atinja níveis máximos de cobertura com valores menores de q . O aumento de B deixa explícita a influência desse parâmetro na utilização de pontos de recarga e na cobertura alcançada: em casos como $B = 1$ e $B = 0.8$, a autonomia do drone permite que uma parte considerável dos clientes seja atendida, precisando de poucas estações de recarga. A maior densidade espacial dos clientes reduz as distâncias médias entre facilidades e demandas, tornando menos necessária a utilização de estações intermediárias neste cenário.

Em valores menores, como nos de $B = 0.6$ e $B = 0.4$, como a autonomia ainda não é suficiente para cobrir as demandas necessárias, o aumento do número de estações de recarga permite alcançar ainda mais clientes. Esse comportamento confirma a hipótese levantada na análise das instâncias, segundo a qual a maior dispersão espacial em Portland aumenta a dependência das estações de recarga.

Devido às diferenças espaciais das instâncias, no caso de São Paulo, é possível atingir 100% de cobertura em um cenário sem recargas, se a autonomia da bateria for suficientemente grande ($B = 1, 0$) e uma maior quantidade de facilidades estiver aberta. No cenário de Portland, atingir a cobertura total das demandas só se mostra possível combinando alta autonomia, maior número de facilidades abertas e uso de estações de recarga.

A Tabela 4.3 apresenta o menor número de estações de recarga necessário para atingir 100% de cobertura da demanda em cada combinação de cenário, autonomia da bateria (B) e número de facilidades (P). Observa-se que a autonomia da bateria é determinante para a cobertura total: com ($B = 0,4$), nenhuma instância atinge 100% de atendimento, mesmo com mais facilidades e estações. Em São Paulo, a cobertura total passa a ser possível a partir de ($B = 0,6$), enquanto em Portland isso ocorre apenas a partir de ($B = 0,8$), indicando que Portland apresenta uma configuração espacial mais restritiva. A tabela também mostra que o aumento de (P) reduz a necessidade de estações, pois mais facilidades diminuem as distâncias até os clientes. Em São Paulo, por exemplo, com ($B = 0,6$), são necessárias 12 estações para ($P = 1$), 9 para ($P = 2$) e 6 para ($P = 3$). Esses resultados evidenciam que as estações de recarga ampliam a cobertura, mas seu efeito depende da autonomia dos drones e da distribuição espacial da rede.




Figura 4.7 – Efeito do aumento da autonomia da bateria B - São Paulo

Cenário	B	$P = 1$	$P = 2$	$P = 3$
Portland	0,4	Não atinge	Não atinge	Não atinge
	0,6	Não atinge	Não atinge	Não atinge
	0,8	Não atinge	Não atinge	12
	1,0	9	9	6
São Paulo	0,4	Não atinge	Não atinge	Não atinge
	0,6	12	9	6
	0,8	6	3	3
	1,0	3	3	0

Tabela 4.3 – Número mínimo de estações de recarga necessário para atingir 100% de cobertura da demanda

Para deixar mais evidente a importância das estações de recarga, destaca-se que o único cenário em que todos os clientes são atendidos sem utilizar estações de recarga seria no mapa de São Paulo, com os parâmetros $P = 3$, $B = 1.0$. Em todas as outras 23 instâncias comparativas, a utilização de estações de recarga aumentou a cobertura.

A Figura 4.8 apresenta a solução gráfica obtida para a instância de Portland, operando com $P = 1$, $q = 9$ e $B = 1$. Observa-se que, durante o trajeto de ida entre a facilidade e o cliente, a utilização de estações de recarga amplia expressivamente o alcance operacional da rede logística. Esse ganho estrutural ocorre porque os drones podem recarregar suas baterias no decorrer do percurso, viabilizando deslocamentos mais longos, mesmo com a penalidade energética causada pelo peso do pacote. Desse modo, constata-se que as rotas de ida demandam maior utilização de paradas intermediárias para recarga. Em contrapartida, durante o trajeto de retorno, verifica-se que parte das estações deixa de ser visitada, pois o drone percorre o trajeto descarregado, minimizando significativamente o consumo energético.




Figura 4.8 – Solução gráfica para a instância de Portland - $P = 1$, $q = 9$ e $B = 1$

Paralelamente, a Figura 4.9 apresenta a topologia de roteamento gerada para o cenário de São Paulo, com parâmetros estabelecidos em $P = 2$, $q = 9$ e $B = 0,60$. Observa-se que o padrão comportamental identificado em Portland repete-se de forma consistente na RMSP, tanto em relação à ampliação do raio de alcance proporcionada pelas estações quanto à assimetria na necessidade de recarga entre os trajetos de ida e de volta. Esse resultado evidencia que as diferenças da densidade geográfica urbana entre as instâncias não alteram, de forma qualitativa, a eficiência e o comportamento prático do modelo de localização proposto.




Figura 4.9 – Solução gráfica para a instância de São Paulo - $P = 2$, $q = 9$ e $B = 0.60$

A Figura 4.10 permite avaliar a relação entre o gasto médio energético nos casos de cobertura máxima. Não foram avaliados casos com coberturas parciais por não permitirem uma

comparação direta.




Figura 4.10 – Energia média para casos de cobertura máxima - Portland

No cenário de Portland, a energia média por cliente tende a diminuir com o aumento do número de estações de recarga. Esse comportamento indica que a utilização de estações permite selecionar trajetórias energeticamente mais eficientes, ainda que o número de arcos percorridos seja maior. Neste caso, para qualquer valor de B , a média de energia gasta por cliente diminui com o aumento de P e q , indicando que abrir estações de recarga permite selecionar rotas melhores para os clientes. Nos casos em que não diminui, o valor permanece constante, demonstrando que a solução chegou ao valor ótimo com um valor de q inferior.

Do mesmo modo, para a instância de São Paulo, é possível verificar tal comportamento: os valores diminuem ou estagnam com o aumento de q . Em comparação com Portland, observa-se que a redução do consumo energético ocorre com menores valores de q , refletindo novamente a menor dispersão espacial da instância.

Outro comportamento que ambos os mapas compartilham é que o aumento do número de facilidades implica na diminuição média do gasto de energia. Na imagem 4.10, no caso de




Figura 4.11 – Energia média para casos de cobertura máxima - São Paulo

$B = 1.0$ e $q = 9$, o retângulo representante para cada parâmetro P contém uma diferença significativa na intensidade das cores, indicando que estão em pontos distantes da escala do mapa de calor. Na imagem 4.11, o mapa de calor deixa ainda mais evidente que a possibilidade de abrir mais facilidades converte-se em menor consumo energético médio, por permitir que estas estruturas estejam melhor distribuídas e, assim, utilizem rotas menos custosas em valores menores de P .

Observa-se que, ao abrir mais estações de recarga e escolher rotas compostas por um maior número de segmentos, a quantidade de arcos médios por cliente atendido aumenta. A relação constatada é que aumentar o número de estações de recarga, em muitos casos, minimiza o consumo energético médio no modelo, aumenta a cobertura e o número de arcos médios.

Ao aumentar a disponibilidade de estações de recarga para um nível de cobertura semelhante, observa-se uma redução na quantidade média de arcos (*hops*) que compõem as rotas. Devido à propriedade da desigualdade triangular, trajetórias compostas por menos paradas tendem a se aproximar do caminho direto, resultando em uma distância total percorrida menor do

que caminhos com múltiplos desvios. Dessa forma, o consumo energético total diminui, uma vez que o modelo consegue selecionar estações estrategicamente posicionadas, evitando que os drones realizem trajetos excessivamente fragmentados apenas para garantir a recarga.

Na Figura 4.12 é possível notar que a utilização dos arcos é mais frequente em valores menores de P e B . Casos como $P = 3$, $B = 0,6$ expressam que, para cenários em que há estações de recarga, o número de arcos médios por cliente aumenta significativamente quando comparado aos cenários em que não há estações de recarga. Este crescimento indica a grande utilização de estações de recarga visando minimizar o consumo energético das entregas.




Figura 4.12 – Dispersão de pontos de arcos médios em relação à cobertura - Portland




Figura 4.13 – Dispersão de pontos de arcos médios em relação a cobertura - São Paulo

Este comportamento se repete na instância de São Paulo. Porém, na imagem 4.13, em valores que a autonomia da bateria (B) é suficiente, e consegue-se distribuir facilidades no mapa ($P \geq 2$), as estações são subutilizadas, visto que o trajeto de ida e volta é mais eficiente que parar em um ponto intermediário. Contudo, mesmo diante deste cenário, estações de recarga são utilizadas e convertem o aumento do número médio de arcos em cobertura de clientes. Essa dinâmica evidencia que as estações de recarga passam a desempenhar papel secundário quando a autonomia da bateria e a distribuição das facilidades já são suficientes para atender a maior parte das demandas.

Por fim, por se tratar de um problema NP-Difícil, alguns cenários atingiram o tempo limite de 3600 segundos imposto, e suas respectivas soluções ótimas não foram encontradas pelo *solver*. A Tabela 4.4 consolida esses casos e destaca que exclusivamente as instâncias de São Paulo esgotaram esse tempo. Adicionalmente, nota-se que os tempos computacionais de São Paulo foram, no geral, maiores, cujos dados completos de todas as execuções podem ser consultados no Apêndice D. A característica semelhante que os cenários compartilham é a dos valores intermediários da autonomia da bateria (B) e de valores menores de estações de recarga.

P	q	B	Cobertura	Energia total	Gap	Tempo (s)	Instância
1	3	0,6	89,5%	96132	0,1851	3695,26	São Paulo
1	3	0,8	98%	115380	0,0957	3682,53	São Paulo
2	6	0,6	99,5%	102147	0,0753	3653,03	São Paulo
3	3	0,6	98,5%	82206	0,0672	3652,01	São Paulo
2	3	0,6	96%	88796	0,1262	3651,57	São Paulo
1	6	0,6	97%	118048	0,1324	3650,90	São Paulo
1	9	0,6	99,5%	123051	0,0513	3649,99	São Paulo

Tabela 4.4 – Todos os cenários que atingiram o limite de tempo (3600 s)

Como observado na Tabela 4.4, o *solver* retornou o *gap* do cenário $P = 1$, $q = 3$ e $B = 0,6$ relativamente maior do que os outros que atingiram o tempo limite (18,51%). Esta métrica indica que a solução tem um potencial de melhora de até 18,51%, podendo assim, durante a busca por soluções, encontrar rotas melhores e até alcançar clientes que antes não eram atendidos. Esse fato não significa que a solução atual esteja distante do ótimo, mas apenas que o *solver* não conseguiu provar a otimalidade dentro do limite de tempo estabelecido.

Os maiores tempos computacionais concentram-se nos cenários intermediários de autonomia ($B = 0.6$), nos quais coexistem diversas alternativas viáveis de roteamento com e sem a utilização de estações de recarga. Essa maior quantidade de combinações aumenta significativamente o espaço de busca explorado pelo *solver*.

Além disso, a coluna de cobertura indica que, por mais que não tenha atingido a otimalidade, o modelo consegue entregar boas soluções consistentes. Outro fator a se considerar é o tamanho das instâncias: enquanto Portland conta com 104 facilidades e 122 pontos de demanda no mapa, São Paulo contém 295 facilidades e 200 demandas. Tais valores influenciam diretamente o aumento das combinações, visto que as variáveis de roteamento irão representar todas as possíveis rotas entre os pontos destacados no mapa, podendo assim explodir combinatoriamente as soluções do problema.

Como as variáveis de roteamento são definidas para cada combinação viável entre facilidades, clientes e estações de recarga, o crescimento do número de candidatos provoca um aumento aproximadamente quadrático no número de arcos considerados pelo modelo. Consequentemente, o número de variáveis binárias cresce rapidamente, elevando substancialmente a dificuldade

computacional do problema. Diante deste crescimento exponencial, evidenciado não apenas pelas instâncias que esgotaram o tempo limite estipulado em 3600 segundos, mas também por outras execuções que consumiram consideráveis minutos de processamento, ressalta-se que o desenvolvimento e a implementação de métodos heurísticos constituem uma frente altamente relevante e necessária para assegurar a escalabilidade e a aplicabilidade de soluções em malhas urbanas de grande porte.

5 Considerações Finais

5.1 Conclusão

Este trabalho abordou o problema de localização de facilidades com drones considerando restrições energéticas e a utilização de estações de recarga intermediárias. Em aplicações práticas, esse modelo é aplicado em sistemas de logística de entrega de última milha, atendimento emergencial e distribuição em áreas urbanas. Nele, o principal desafio consiste em definir pontos estratégicos capazes de maximizar o atendimento às demandas considerando as limitações de autonomia energética dos drones. Ao introduzir estações de recarga no modelo, o raio de alcance dos drones aumenta e surgem novas possibilidades de atendimento às demandas. Diante disso, o objetivo deste estudo foi avaliar e compreender o impacto da localização de estações de recarga no problema de localização de facilidades e cobertura com drones.

O novo modelo matemático proposto é capaz de representar as estações de recarga na ampliação do alcance operacional dos drones, permitindo o atendimento a demandas que no cenário sem estações de recarga seriam inviáveis. Diferentemente dos modelos já consolidados na literatura, o modelo proposto tem como principal objetivo a minimização do consumo energético total com penalidades de demandas não atendidas. Além disso, a inclusão das estações de recarga permitiu comparar diretamente cenários com e sem essa infraestrutura. Para fins comparativos, também foi desenvolvida uma instância baseada na região metropolitana da cidade de São Paulo, a qual foi testada utilizando os mesmos parâmetros da instância de Portland, amplamente utilizada na literatura. Dessa forma, o modelo integra simultaneamente decisões de localização, roteamento e utilização de estações de recarga em uma única formulação.

A análise dos dados resultantes do experimento permitiu evidenciar que a autonomia da bateria é o parâmetro de maior influência sobre a cobertura. Verificou-se também que a utilização de estações de recarga aumenta significativamente o atendimento das demandas, principalmente para casos com autonomia energética mais restritiva. Entretanto, notou-se que, a adição de novos pontos de recarga atinge um ponto de saturação da cobertura, no qual o aumento deste parâmetro não produz ganhos adicionais de atendimento. Além disso, o aumento do número de facilidades abertas reduz, conseqüentemente, a necessidade do uso das estações, uma vez que os clientes passam a ser atendidos diretamente por facilidades mais próximas. Por fim, o desempenho do sistema está condicionado à combinação entre os parâmetros B , P e q , aliada às características espaciais do cenário.

Os experimentos foram divididos em dois cenários para o problema, o de Portland e o de São Paulo. Os conjuntos de valores dos parâmetros definidos foram testados igualmente para cada uma das cidades. A instância base possuía menor número de clientes e facilidades

do que a desenvolvida neste estudo. Sendo assim, Portland tinha distribuição espacial mais dispersa, diferentemente de São Paulo, que se caracterizou por uma alta concentração de pontos no espaço. Tais condições geográficas evidenciaram que conjuntos de dados diferentes, como estes, influenciam diretamente a dificuldade do modelo. Portanto, para cenários diferentes, o modelo demonstrou que a utilização de pontos de recarga varia, evidenciando que a contribuição das estações de recarga depende fortemente da distribuição espacial das demandas.

Em alguns poucos cenários testados, o *solver* não conseguiu encontrar a solução ótima do modelo no limite de tempo definido, evidenciando a natureza NP-Difícil do problema. O aumento do tamanho das instâncias e o crescimento do espaço de busca dificultam a obtenção da solução ótima para a instância testada. O elevado número de variáveis de roteamento, definidas sobre combinações entre clientes, facilidades e estações de recarga, provoca um crescimento expressivo da dimensão do modelo. Por isso, métricas como o *gap* de otimalidade conseguem exprimir ao menos o limite superior para a distância em relação à solução ótima. Esses resultados evidenciam a elevada complexidade computacional do problema, indicando que a resolução de instâncias de maior porte por métodos exatos torna-se progressivamente mais difícil à medida que aumenta a dimensão do modelo.

Os experimentos computacionais demonstraram que a utilização de estações de recarga pode ampliar significativamente o alcance operacional dos drones, embora a efetividade dessa infraestrutura dependa diretamente da autonomia energética do veículo, da quantidade de facilidades instaladas e da distribuição espacial das demandas. Essas observações, consolidadas pela comparação entre as diferentes distribuições espaciais das instâncias de Portland e São Paulo, evidenciam que o planejamento da infraestrutura de recarga não se resolve apenas com a inserção de novos pontos de apoio, mas exige uma análise integrada entre os parâmetros do sistema e a geografia da rede. Nesse contexto, o presente estudo contribui para a literatura da área ao estender as formulações clássicas de localização de facilidades, introduzindo uma modelagem matemática capaz de avaliar simultaneamente as relações entre cobertura das demandas, consumo energético e utilização de estações de recarga. Dessa forma, ao disponibilizar o modelo desenvolvido, uma nova instância baseada em dados reais da Região Metropolitana de São Paulo e um protocolo experimental, este trabalho consolida um referencial estruturado que constitui uma base para futuras investigações sobre localização de facilidades com drones, planejamento energético e logística aérea.

5.2 Trabalhos Futuros

Como os experimentos evidenciaram a elevada complexidade computacional da resolução do modelo exato, uma das principais direções para trabalhos futuros consiste no desenvolvimento de métodos capazes de reduzir o esforço computacional necessário para a obtenção das soluções. Nesse contexto, é possível investigar abordagens heurísticas, matheurísticas ou estratégias de

decomposição matemática que permitam contornar as limitações observadas pelo *solver*. Tais métodos poderão viabilizar a resolução de instâncias de maior porte e de cenários com um número mais elevado de clientes, facilidades e estações de recarga, ampliando a aplicabilidade do modelo proposto.

Do ponto de vista da modelagem matemática, o avanço mais natural e relevante reside na otimização da própria infraestrutura de recarga. A disposição de locais candidatos em grid regular pode ser substituída por processos estratégicos de geração de pontos, utilizando informações da distribuição espacial das demandas e técnicas de agrupamento (*clustering*). Somado a isso, o modelo pode ser aprimorado com a incorporação de características operacionais mais dinâmicas, tais como o tempo de espera e as filas nas estações de recarga, a utilização de frotas heterogêneas de drones (com variações de autonomia e capacidade de carga) e o tratamento da formulação sob uma perspectiva multiobjetivo, visando equilibrar simultaneamente consumo energético, custo financeiro e nível de serviço.

No que tange aos cenários experimentais, é possível avaliar a robustez do modelo em configurações geográficas que extrapolem as características espaciais de Portland e São Paulo. A aplicação da metodologia em regiões de baixa densidade (áreas rurais), em cenários com grandes variações de relevo ou em municípios com gargalos severos de mobilidade permitirá uma compreensão mais profunda sobre como diferentes distribuições espaciais limitam ou favorecem o emprego dos drones.

Por fim, a adaptação deste estudo para aplicações práticas de alta criticidade representa um horizonte promissor para a literatura da área. A utilização da ferramenta em contextos de logística hospitalar e entrega de medicamentos, por exemplo, evidenciará a utilidade prática da otimização energética em cenários onde a agilidade e a cobertura máxima da rede são vitais.

Referências

BAZARAA, M. S.; JARVIS, J. J.; SHERALI, H. D. *Linear Programming and Network Flows*. [S.l.]: Wiley-Interscience, 2004. ISBN 0471485993.

CHAUHAN, D.; UNNIKRISSNAN, A.; FIGLIOZZI, M. Maximum coverage capacitated facility location problem with range constrained drones. *Transportation Research Part C: Emerging Technologies*, Elsevier, v. 99, p. 1–18, 2019.

DANTZIG, G. *Linear Programming and Extensions*. [S.l.]: Princeton University Press, 1963.

DUKKANCI, O.; CAMPBELL, J. F.; KARA, B. Y. Facility location decisions for drone delivery: A literature review. *European Journal of Operational Research*, Elsevier, v. 316, n. 2, p. 397–418, 2024.

GENTILI, M.; MIRCHANDANI, P. B.; AGNETIS, A.; GHELICHI, Z. Locating platforms and scheduling a fleet of drones for emergency delivery of perishable items. *Computers & Industrial Engineering*, Elsevier, v. 168, p. 108057, 2022.

GHELICHI, Z.; GENTILI, M.; MIRCHANDANI, P. B. Logistics for a fleet of drones for medical item delivery: A case study for louisville, ky. *Computers & Operations Research*, Elsevier, v. 135, p. 105443, 2021.

GOMORY, R. E. Outline of an algorithm for integer solutions to linear programs. *Bulletin of the American Society*, v. 64, p. 275–278, 1958.

Gurobi Optimization, LLC. *Gurobi Optimizer Reference Manual*. [S.l.], 2024. Disponível em: <https://www.gurobi.com>.

iFood. *Como opera o drone do iFood?* 2026. <https://institucional.ifood.com.br/inovacao/drone-ifood/>. Accessed: 2026-07-13.

LAND, A. H.; DOIG, A. G. An automatic method of solving discrete programming problems. *Econometrica*, v. 28, n. 3, p. 497–520, 1960.

LI, J.; NI, X.; HUA, M.; WANG, Q.; WU, Q.; ZHAO, X.; XU, M. Energy-efficient large-scale low-altitude delivery: Integrating charging station location and uav route planning by a cascade optimization framework. *Aerospace Science and Technology*, v. 168, p. 111119, 2026. ISSN 1270-9638. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1270963825011824>.

LIU, Y. Routing battery-constrained delivery drones in a depot network: A business model and its optimization–simulation assessment. *Transportation Research Part C: Emerging Technologies*, v. 152, p. 104147, 2023. ISSN 0968-090X. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0968090X23001365>.

MEGIDDO, N.; ZEMEL, E.; HAKIMI, S. L. The maximum coverage location problem. *SIAM Journal on Algebraic Discrete Methods*, v. 4, n. 2, p. 253–261, 1983.

MOHSAN, S. A. H.; KHAN, M. A.; NOOR, F.; ULLAH, I.; ALSHARIF, M. H. Towards the unmanned aerial vehicles (uavs): A comprehensive review. *Drones*, Mdpi, v. 6, n. 6, p. 147, 2022.

PINTO, R.; LAGORIO, A. Point-to-point drone-based delivery network design with intermediate charging stations. *Transportation Research Part C: Emerging Technologies*, v. 135, p. 103506, 2022. ISSN 0968-090X.

SHAVARANI, S. M.; NEJAD, M. G.; RISMANCHIAN, F.; IZBIRAK, G. Application of hierarchical facility location problem for optimization of a drone delivery system: a case study of amazon prime air in the city of san francisco. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 95, n. 9, p. 3141–3153, 2018.

SILVA, B. N.; KHAN, M.; HAN, K. Towards sustainable smart cities: A review of trends, architectures, components, and open challenges in smart cities. *Sustainable cities and society*, Elsevier, v. 38, p. 697–713, 2018.

WOLSEY, L. *Integer Programming*. [S.l.]: John Wiley and Sons, 1998.

Zipline. *Drone Delivery for Food, Groceries, and Medicine*. 2026. <<https://www.zipline.com/>>. Accessed: 2026-07-13.

Apêndices

APÊNDICE A – Pontos de Facilidades - São Paulo

Latitude	Longitude	ID
-23.4924171	-46.8527977	0
-23.4980711	-46.8535962	1
-23.5101097	-46.4983227	2
-23.5096546	-46.7045382	3
-23.5387287	-46.7308134	4
-23.5393231	-46.6502774	5
-23.556997	-46.6343196	6
-23.589587	-46.5532079	7
-23.6020031	-46.5227739	8
-23.5893274	-46.5681963	9
-23.5985166	-46.5196761	10
-23.6088675	-46.7769422	11
-23.607035	-46.7528943	12
-23.6075118	-46.7569337	13
-23.6043817	-46.6255785	14
-23.5655827	-46.6380598	15
-23.7368956	-46.6912873	16
-23.7345824	-46.688931	17
-23.3652733	-46.7499121	18
-23.4731514	-46.54442	19
-23.549943	-46.5677243	20
-23.4480591	-46.7350159	21
-23.447754	-46.7346833	22
-23.4548813	-46.766332	23
-23.5672801	-46.7088495	24
-23.4742819	-46.489558	25
-23.5321027	-46.4863317	26
-23.5175678	-46.5681496	27
-23.6661765	-46.5868515	28
-23.6778163	-46.583892	29
-23.5514398	-46.3789629	30
-23.4239154	-46.3979555	31

-23.5343891	-46.4519583	32
-23.7379997	-46.7042287	33
-23.6417446	-46.5961296	34
-23.5454428	-46.6058092	35
-23.498712	-46.3137453	36
-23.665958	-46.7437387	37
-23.69296	-46.7598884	38
-23.6529542	-46.7370022	39
-23.4967358	-46.4414038	40
-23.5975297	-46.6215791	41
-23.5495338	-46.3143465	42
-23.5228266	-46.4282184	43
-23.5582087	-46.6604377	44
-23.5030347	-46.8307185	45
-23.46916	-46.5299506	46
-23.4710886	-46.537449	47
-23.5702543	-46.4796689	48
-23.5678841	-46.4697514	49
-23.5415005	-46.3682133	50
-23.5228545	-46.1812695	51
-23.5498351	-46.6464534	52
-23.5136432	-46.7918396	53
-23.5472993	-46.5318087	54
-23.7672391	-46.7174737	55
-23.5574036	-46.5788438	56
-23.5909235	-46.6087284	57
-23.517448	-46.476493	58
-23.5243407	-46.5485866	59
-23.6716743	-46.513144	60
-23.5300232	-46.6059152	61
-23.5287969	-46.5892337	62
-23.4805688	-46.4998277	63
-23.5550693	-46.6618038	64
-23.6737286	-46.6597278	65
-23.5159269	-46.17454	66
-23.5480208	-46.6315598	67
-23.5383963	-46.6348601	68
-23.5382641	-46.6358476	69
-23.5160597	-46.6299588	70

-23.5819762	-46.6748416	71
-23.4085291	-46.8694906	72
-23.6053055	-46.4012052	73
-23.4755608	-46.3518285	74
-23.7115861	-46.5505287	75
-23.4392061	-46.9106668	76
-23.6482528	-46.2395875	77
-23.5074075	-46.6643454	78
-23.534513	-46.1911467	79
-23.3353066	-46.8359731	80
-23.5324067	-46.2026619	81
-23.4014468	-46.3109948	82
-23.9119409	-46.5579214	83
-23.7759377	-46.6133892	84
-23.5087821	-46.1727552	85
-23.7298228	-46.7021337	86
-23.7357594	-46.5814292	87
-23.5308798	-45.8462396	88
-23.4900434	-46.4894236	89
-23.6051872	-46.9275644	90
-23.516286	-46.6248317	91
-23.5378486	-46.2245568	92
-23.7797372	-46.3016265	93
-23.7773243	-46.3010264	94
-23.667875	-46.5835686	95
-23.4491524	-46.4380191	96
-23.4452319	-46.9138478	97
-23.6465107	-46.4975906	98
-23.6707167	-46.5104927	99
-23.654727	-46.5716275	100
-23.6762467	-46.6596519	101
-23.6874638	-46.6250615	102
-23.6456361	-46.5943344	103
-23.6151454	-46.674951	104
-23.5281087	-46.8843583	105
-23.3533072	-46.7370483	106
-23.5239898	-46.3421368	107
-23.503222	-46.6165409	108
-23.4702255	-46.5245289	109

-23.3879449	-46.3258539	110
-23.4701222	-46.5244776	111
-23.7001959	-46.8688956	112
-23.6992761	-46.866588	113
-23.6123384	-46.7587583	114
-23.5284676	-46.9020941	115
-23.6535817	-46.6332439	116
-23.4249885	-46.4769917	117
-23.6254987	-46.6600826	118
-23.5920595	-46.8330047	119
-23.4258018	-46.4793491	120
-23.7778168	-46.5309533	121
-23.6973008	-46.5539276	122
-23.6970032	-46.554126	123
-23.5487829	-46.9378909	124
-23.5043691	-46.6161834	125
-23.5337666	-46.5856201	126
-23.6265837	-46.6445638	127
-23.5004508	-46.6488901	128
-23.5351424	-46.6438402	129
-23.5637073	-46.5023712	130
-23.6134322	-46.4887771	131
-23.613172	-46.4882721	132
-23.6429581	-46.71952	133
-23.6083619	-46.7361213	134
-23.6415965	-46.6286391	135
-23.5618442	-46.6563185	136
-23.55543	-46.65017	137
-23.5555311	-46.6719949	138
-23.6419755	-46.8367274	139
-23.6512472	-46.8550049	140
-23.6494272	-46.8524568	141
-23.5460717	-46.9442212	142
-23.6274311	-46.5980095	143
-23.9069853	-46.7091634	144
-23.6486663	-46.5559644	145
-23.5202411	-46.4115165	146
-23.5051043	-46.3967784	147
-23.5095833	-46.4463707	148

-23.6255492	-46.6467869	149
-23.5942087	-46.623435	150
-23.6101447	-46.6456302	151
-23.5925212	-46.6562476	152
-23.5933287	-46.6454417	153
-23.6037553	-46.5948631	154
-23.6324062	-46.728446	155
-23.601656	-46.5985091	156
-23.6044026	-46.6929262	157
-23.6330896	-46.7705904	158
-23.581828	-46.6744935	159
-23.6329041	-46.7704428	160
-23.6267186	-46.6628342	161
-23.6468383	-46.7074176	162
-23.6394747	-46.6436753	163
-23.7447298	-46.8008842	164
-23.8619179	-46.7123606	165
-23.8372617	-46.8247415	166
-23.7669016	-46.7168193	167
-23.8810782	-46.7413559	168
-23.8474582	-46.6972215	169
-23.8299178	-46.8181637	170
-23.8521964	-46.9400932	171
-23.8542945	-46.9462656	172
-23.9308737	-47.0669717	173
-23.9326389	-47.072532	174
-23.650043	-46.7488643	175
-23.6895974	-46.7732551	176
-23.7162174	-46.7672235	177
-23.6645116	-46.7831257	178
-23.658742	-46.7074999	179
-23.6540228	-46.7069447	180
-23.6475851	-46.7039634	181
-23.6515829	-46.7162046	182
-23.6827385	-46.7006994	183
-23.7432191	-46.6700873	184
-23.5448079	-46.7212637	185
-23.4690496	-46.6899231	186
-23.4692262	-46.6902027	187

-23.6236033	-46.4702228	188
-23.6083064	-46.5009436	189
-23.5519597	-46.4369149	190
-23.4894722	-46.4818396	191
-23.4586254	-46.5853419	192
-23.4043901	-46.73803	193
-23.4041156	-46.738085	194
-23.4100969	-46.8385918	195
-23.3919715	-46.7158026	196
-23.3919278	-46.7158006	197
-23.4972381	-46.7459523	198
-23.4974607	-46.7460985	199
-23.5177723	-46.584373	200
-23.5273446	-46.5925852	201
-23.580524	-46.6108019	202
-23.5483131	-46.6985518	203
-23.5912149	-46.6086205	204
-23.559147	-46.6248793	205
-23.4596334	-46.5811842	206
-23.5652463	-46.6391957	207
-23.5768204	-46.6383695	208
-23.5330547	-46.6452331	209
-23.5323846	-46.6456548	210
-23.5650177	-46.6387921	211
-23.5368873	-46.6649852	212
-23.4851481	-46.6203228	213
-23.4636245	-46.6267832	214
-23.4644607	-46.6172753	215
-23.6321737	-46.6362693	216
-23.4542958	-46.5798036	217
-23.4599956	-46.6241372	218
-23.4630837	-46.6252327	219
-23.4833225	-46.5900686	220
-23.4767324	-46.5653087	221
-23.5259169	-46.5009117	222
-23.595137	-46.6114605	223
-23.5970338	-46.6006649	224
-23.6230048	-46.6021884	225
-23.5295272	-46.6121213	226

-23.5784832	-46.547725	227
-23.5359921	-46.5876964	228
-23.5313183	-46.5697286	229
-23.5868346	-46.5832304	230
-23.570699	-46.5917636	231
-23.5733084	-46.5574085	232
-23.5169545	-46.468655	233
-23.4975278	-46.4606325	234
-23.4932344	-46.4403533	235
-23.5049627	-46.4804255	236
-23.5885719	-46.4071663	237
-23.5238333	-46.4137681	238
-23.5796091	-46.5174344	239
-23.6190093	-46.423845	240
-23.6116818	-46.4752475	241
-23.6078561	-46.4599987	242
-23.6889449	-46.5958868	243
-23.71921	-46.6272216	244
-23.5451456	-46.7710622	245
-23.5310851	-46.7749528	246
-23.5156253	-46.7898065	247
-23.5369223	-46.7750163	248
-23.5281628	-46.7685811	249
-23.5474052	-46.7949285	250
-23.4988768	-46.7701958	251
-23.5176283	-46.7723151	252
-23.4975879	-46.7898517	253
-23.4502257	-46.5178859	254
-23.4492044	-46.5411601	255
-23.4686827	-46.4654468	256
-23.4433154	-46.4682555	257
-23.4202377	-46.5013939	258
-23.4411109	-46.422181	259
-23.5630424	-46.8333459	260
-23.4962375	-46.8697198	261
-23.6052966	-46.9150812	262
-23.5171356	-46.8448793	263
-23.602758	-47.0232608	264
-23.6081856	-46.5710325	265

-23.315875	-46.2256278	266
-23.3233903	-46.222865	267
-23.5267081	-46.2017543	268
-23.6705144	-46.4610324	269
-23.4906878	-46.5660832	270
-23.524628	-46.3427211	271
-23.5459457	-46.3158585	272
-23.5496357	-46.2595843	273
-23.5580988	-46.3206469	274
-23.5361447	-46.2196899	275
-23.5501704	-46.314481	276
-23.5321636	-46.2036802	277
-23.5430884	-46.3669356	278
-23.5265986	-46.2040717	279
-23.5293122	-46.1990068	280
-23.5111897	-46.1900515	281
-23.55315	-46.3446874	282
-23.5219796	-46.1877033	283
-23.5551001	-46.3834909	284
-23.539749	-46.385103	285
-23.5921491	-46.4031246	286
-23.4964286	-46.4014263	287
-23.4836755	-46.3535338	288
-23.5181621	-46.3725011	289
-23.4828954	-46.3744467	290
-23.4936119	-46.4030592	291
-23.4884024	-46.4154919	292
-23.4946303	-46.4702815	293
-23.5224407	-46.1812924	294

APÊNDICE B – Pontos de demanda - São Paulo

cluster	Latitude	Longitude	Demand(kg)
0	-23.713151440597297	-46.531811645053594	5.75
1	-23.529874955477897	-46.65292602399338	5.75
2	-23.502430782543946	-46.29501803314207	2.25
3	-23.830189209557272	-46.83769395642787	3.25
4	-23.63002884126267	-46.75362255816416	4.75
5	-23.5218514796563	-46.45899947031817	2.5
6	-23.493091413149337	-46.801627547206664	3.75
7	-23.27565274313788	-46.710767774807266	1.75
8	-23.572450861397975	-46.9208467591158	2.75
9	-23.484116215049543	-46.19129125577359	2.25
10	-23.716589604658118	-46.688555175983474	4.75
11	-23.62767814441002	-46.579957651306934	5.75
12	-23.62980398141657	-46.465073546635644	2.75
13	-23.43543476449074	-46.711012233025095	3.5
14	-23.34023540659649	-46.22298239282248	4.75
15	-23.454730462525706	-46.613553868269165	3.75
16	-23.43024562301754	-46.54519283581796	2.25
17	-23.59895547953811	-46.63487799293697	4.25
18	-23.41427029947126	-46.37454717620225	5.5
19	-23.579460540727403	-46.80983003973907	2.75
20	-23.540045078412717	-46.40428367299193	3.5
21	-23.900783126576222	-47.07738303996034	3.75
22	-23.55525232549828	-46.55435761598368	4.5
23	-23.687075819677194	-46.767295048499435	4.5
24	-23.34175107449801	-46.56972341716991	5.75
25	-23.445641373743342	-46.036167020914846	2.75
26	-23.692536009014123	-46.45159977313373	5.75
27	-23.88870462453197	-46.61011621528867	3.25
28	-23.40487332219901	-46.845084652776926	3.75
29	-23.686475780267276	-46.59626363554203	1.5
30	-23.68984895567942	-46.9213785685978	1.25
31	-23.77191385444489	-46.70758953865051	2.75

32	-23.485577304690796	-46.68706445433787	2.5
33	-23.612463025713488	-46.24164238678729	5.25
34	-23.525299808367286	-46.84669142194033	2.5
35	-23.582413034826665	-46.75567844253317	3.5
36	-23.58579455660383	-45.815154909504656	2.5
37	-23.66979394917929	-46.635202191848926	4.75
38	-23.602123552217247	-46.49057309289461	5.75
39	-23.475856551676753	-46.382785486283254	5.75
40	-23.73024944553241	-46.57453695724909	2.25
41	-23.621524755685975	-46.946318811521344	2.75
42	-23.614668887898098	-46.013839581522525	5.75
43	-23.56359585994544	-46.482226971935766	1.75
44	-23.567861277111888	-46.412155566350435	4.5
45	-23.381756356169113	-46.7151399597575	4.75
46	-23.385137605496528	-46.471740280752485	3.5
47	-23.51422267598321	-46.770522868267	4.75
48	-23.652885967072493	-46.814859174717775	2.75
49	-23.70102147784228	-46.79684501425442	2.75
50	-23.55274913232347	-46.65138215094646	2.5
51	-23.49498898043777	-46.63090505837723	1.25
52	-23.48035707527453	-46.965443777937296	5.5
53	-23.719867608405107	-46.61838975117044	5.25
54	-23.578150197301696	-46.71975340247291	2.5
55	-23.485684044769755	-46.421839555538504	4.75
56	-23.860481441029002	-46.698689251536905	2.5
57	-23.516699734081552	-46.5536372564944	4.5
58	-23.718926249886625	-47.002141021185004	4.25
59	-23.55361068933558	-46.16990843862692	5.75
60	-23.64469601269645	-46.532475041554804	2.5
61	-23.53573225311025	-46.81172555076098	2.25
62	-23.565057193904494	-46.62349271024488	4.25
63	-23.55221707539719	-46.443057796188654	4.75
64	-23.59289076782532	-46.56394029390333	3.75
65	-23.847676684327702	-46.94908043380223	4.5
66	-23.365771214397554	-46.31614857835043	5.5
67	-23.76148610797705	-46.80436011030298	5.75
68	-23.68738126554309	-46.705942191805455	3.5
69	-23.52901241593641	-46.68721643340187	5.5
70	-23.533964421990227	-46.34309667092821	1.5

71	-23.438403688565256	-46.80141690661903	1.75
72	-23.343146966333446	-46.631597088294974	3.75
73	-23.505167221249618	-46.52012341438372	3.5
74	-23.322801334620785	-46.841062833223184	4.5
75	-23.469606601047523	-46.85116375610186	5.75
76	-23.599942659917623	-46.85749705073379	3.75
77	-23.426939375035342	-46.308066027626616	2.75
78	-23.326091766822724	-46.69923298555752	2.5
79	-23.94359421658418	-46.703588983882575	5.75
80	-23.71406411827384	-46.404276062636335	1.5
81	-23.7110562769674	-46.8542799043677	1.5
82	-23.660442572394906	-46.68657834707197	4.25
83	-23.288576189038665	-46.52806065540634	2.25
84	-23.766040590468098	-46.59733640062516	3.25
85	-23.41929968872624	-46.58449463748722	5.25
86	-23.4528608588792	-46.509400034440795	5.25
87	-23.55394795811895	-46.78416570239744	2.25
88	-23.70399558747675	-46.64435328121542	3.25
89	-23.39881792255595	-46.7703150967645	1.25
90	-23.68897095856133	-46.18653480487214	1.75
91	-23.627972557424997	-46.55499427841558	4.5
92	-23.282718082450238	-46.76895268953192	1.25
93	-23.79145897740798	-46.75077185493767	2.75
94	-23.288992707702356	-46.64420219604182	1.25
95	-23.60364243159371	-47.01518355006538	3.5
96	-23.53115771814526	-46.581561078595534	5.25
97	-23.8369744039499	-46.52173775266833	1.5
98	-23.459240325916195	-46.65027530993123	5.75
99	-23.651296635712068	-46.446689501465706	2.25
100	-23.55958929308879	-46.369473872951254	3.5
101	-23.54420891940461	-46.250728761441444	1.5
102	-23.533319091942257	-46.72379075405109	2.5
103	-23.44832232221935	-46.41444347380285	2.75
104	-23.61499801576384	-46.60318408109787	4.25
105	-23.51675916086332	-46.424112704385806	3.25
106	-23.547615457817226	-46.75432825986541	1.75
107	-23.502096605523896	-46.59679163210184	3.5
108	-23.8829403135846	-46.788691405392356	2.75
109	-23.579319516574305	-46.524703269949484	2.5

110	-23.61923451499138	-46.686625756700394	5.75
111	-23.367283937648835	-46.131135095499936	3.75
112	-23.9562412292303	-46.89511477777977	1.5
113	-23.611935003217194	-46.731039967061506	5.75
114	-23.65790960061744	-46.74087388719903	1.5
115	-23.53526069168251	-46.617031423244114	3.5
116	-23.47246360232744	-46.718279715273	2.25
117	-23.672070914207726	-46.48778928807248	3.75
118	-23.66208594583069	-46.40910532393689	2.5
119	-23.476428836471857	-46.541847087540866	3.75
120	-23.766556883140353	-46.38597199454983	1.75
121	-23.745733615795984	-46.66619823683417	3.5
122	-23.38203248688721	-46.41366959031696	2.25
123	-23.67739106423712	-46.528567516456945	1.25
124	-23.651883930353282	-46.607170022150676	1.5
125	-23.628059928236457	-46.63826219357767	5.75
126	-23.52856944186702	-46.91936435722653	5.25
127	-23.5422254461115	-46.98138359125951	4.5
128	-23.797604095290218	-46.65799949013821	1.25
129	-23.490470581654836	-46.460331299600156	5.25
130	-23.647280275678234	-46.65978456967843	2.25
131	-23.257098526222382	-46.20064419693987	3.75
132	-23.641486217523873	-46.71261136661895	1.25
133	-23.461891805708888	-46.33568542704598	2.75
134	-23.696594924389725	-46.56008481401423	2.25
135	-23.44358311233009	-46.68073466179896	1.5
136	-23.397329052777508	-46.51757464316	1.5
137	-23.681117439782252	-46.35424068560679	1.75
138	-23.488036369847606	-46.1209266623971	5.5
139	-23.595479485113845	-46.67142375095505	4.5
140	-23.492951393996	-46.492741146146344	3.5
141	-23.563905110344514	-45.94024506853424	3.75
142	-23.562270991951063	-46.6872160425151	5.5
143	-23.584906040283975	-46.32506894613461	2.25
144	-23.591555674295538	-46.45251788367688	3.5
145	-23.601075198943775	-46.779977846839316	2.5
146	-23.514672474296127	-46.38588646392478	2.75
147	-23.31517990962563	-46.44434729446259	3.5
148	-23.607166517843808	-46.90136858049308	1.5

149	-23.560926965396646	-46.844598503413245	4.25
150	-23.55621899811011	-46.950492469780926	2.5
151	-23.34882325861295	-46.931267443712116	2.5
152	-23.757507362134042	-46.46400087290292	1.75
153	-23.445696838014033	-46.24526241507777	3.5
154	-23.61968853937879	-46.818985007047395	2.75
155	-23.562400675095184	-46.58798288623373	1.75
156	-23.67450895984935	-46.80539806290303	3.25
157	-23.63761014466507	-46.09885554178487	5.75
158	-23.402818561253177	-46.99854326467049	1.75
159	-23.77094906129561	-46.89301701512137	2.5
160	-23.968384200790386	-47.00036962419196	4.75
161	-23.530735339055667	-46.489482436619575	3.5
162	-23.733429539821543	-46.766284991531265	3.75
163	-23.662390746228425	-46.56389631715165	5.25
164	-23.618077795447142	-46.41747706133239	4.75
165	-23.738059409335033	-46.71139654047507	1.75
166	-23.342973886382953	-46.77155984069195	1.75
167	-23.483499603652238	-46.75526528588306	4.75
168	-23.547230576000604	-46.88255971803928	5.75
169	-23.65268312345559	-46.858704156578185	1.75
170	-23.446127985116792	-46.74618721359231	4.5
171	-23.684635741083255	-46.665516660646055	4.25
172	-23.748096082308827	-46.53527220802724	4.75
173	-23.968690561908694	-47.138717367918524	1.25
174	-23.478979220341174	-46.5753128277116	5.75
175	-23.503039100094025	-46.71735086529199	4.25
176	-23.498298776902875	-46.35378472721362	3.5
177	-23.639844768160202	-46.50190807640272	5.75
178	-23.83035084711053	-46.718020130857845	4.5
179	-23.739970297664733	-46.29305309919489	5.5
180	-23.65289470299452	-46.7754037313955	3.25
181	-23.260421054778643	-46.59012613072372	1.25
182	-23.395347057900572	-46.643495001596946	5.5
183	-23.60555557577851	-46.37931097329725	4.5
184	-23.492762033430125	-46.894192249502076	3.25
185	-23.64417209032322	-47.00230510964039	3.5
186	-23.54455038777484	-46.522228447127866	4.75
187	-23.57385127415371	-46.20375181380885	1.25

188	-23.713973803629784	-46.502604654598734	3.75
189	-23.612260170677274	-46.524483010850716	3.25
190	-23.58698626102041	-46.604879599838036	4.75
191	-23.44706645334879	-46.46478596155028	5.75
192	-23.694801092667873	-46.7398167235809	1.25
193	-23.628847858559116	-46.787904561746814	5.75
194	-23.266140523778827	-46.29838101767306	4.75
195	-23.500795202461177	-46.6649035104929	4.5
196	-23.574498969524655	-46.65067222683389	3.25
197	-23.41672225663783	-46.90674414038675	2.25
198	-23.645041451603557	-46.30182636834751	5.25
199	-23.545479391084786	-46.298087278351396	4.75

APÊNDICE C – Resultados do modelo para instância de Portland

P	Q	B	Cobertura (%)	Energia	Energia média	Arcos	Média de arcos	Gap	Tempo
1	0	1	73,77%	48120	534,67	180	2,00	0,0000	15,76
1	3	1	91,80%	80946	722,73	260	2,32	0,0000	1231,01
1	6	1	96,72%	93737	794,38	288	2,44	0,0000	1128,78
1	9	1	100,00%	108307	887,76	317	2,60	0,0001	376,58
1	12	1	100,00%	101484	831,84	315	2,58	0,0000	27,79
1	15	1	100,00%	101407	831,20	311	2,55	0,0000	30,17
2	0	1	86,07%	61821	588,77	210	2,00	0,0000	13,22
2	3	1	96,72%	86702	734,76	266	2,25	0,0000	780,53
2	6	1	99,18%	83331	688,69	275	2,27	0,0000	462,81
2	9	1	100,00%	85038	697,03	282	2,31	0,0000	34,47
2	12	1	100,00%	84314	691,10	287	2,35	0,0000	27,99
2	15	1	100,00%	84252	690,59	282	2,31	0,0000	28,03
3	0	1	93,44%	69850	612,72	228	2,00	0,0000	15,01
3	3	1	99,18%	80558	665,77	258	2,13	0,0000	754,97
3	6	1	100,00%	75037	615,06	269	2,20	0,0001	254,24
3	9	1	100,00%	73737	604,40	269	2,20	0,0001	60,51
3	12	1	100,00%	73671	603,86	271	2,22	0,0001	52,02
3	15	1	100,00%	73655	603,73	271	2,22	0,0001	65,27
1	0	0,8	62,30%	33155	436,25	152	2,00	0,0000	11,57
1	3	0,8	82,79%	73484	727,56	252	2,50	0,0000	432,33
1	6	0,8	89,34%	80707	740,43	286	2,62	0,0000	596,71
1	9	0,8	92,62%	88846	786,25	309	2,73	0,0001	179,65
1	12	0,8	94,26%	89151	775,23	321	2,79	0,0000	25,63
1	15	0,8	94,26%	89151	775,23	319	2,77	0,0000	25,25
2	0	0,8	73,77%	40564	450,71	180	2,00	0,0000	11,02
2	3	0,8	89,34%	73981	678,72	248	2,28	0,0000	936,58
2	6	0,8	94,26%	80596	700,83	283	2,46	0,0000	322,71
2	9	0,8	97,54%	86097	723,50	300	2,52	0,0000	242,94
2	12	0,8	99,18%	89763	741,84	321	2,65	0,0000	30,24
2	15	0,8	99,18%	88430	730,83	319	2,64	0,0000	28,24
3	0	0,8	84,43%	48188	467,84	206	2,00	0,0000	11,33
3	3	0,8	93,44%	63007	552,69	251	2,20	0,0000	531,56
3	6	0,8	97,54%	77897	654,60	281	2,36	0,0000	379,16
3	9	0,8	99,18%	75439	623,46	294	2,43	0,0001	131,61
3	12	0,8	100,00%	76676	628,49	298	2,44	0,0000	32,23
3	15	0,8	100,00%	75312	617,31	296	2,43	0,0000	26,34
1	0	0,6	52,46%	21826	341,03	128	2,00	0,0000	9,89
1	3	0,6	68,03%	48482	584,12	210	2,53	0,0001	33,35
1	6	0,6	77,87%	64030	674,00	267	2,81	0,0000	14,18

1	9	0,6	80,33%	69315	707,30	287	2,93	0,0000	14,97
1	12	0,6	80,33%	69315	707,30	287	2,93	0,0000	14,12
1	15	0,6	80,33%	69315	707,30	287	2,93	0,0000	14,60
2	0	0,6	62,30%	27376	360,21	152	2,00	0,0000	9,95
2	3	0,6	77,05%	50990	542,45	225	2,39	0,0000	42,69
2	6	0,6	83,61%	62434	612,10	268	2,63	0,0000	54,70
2	9	0,6	87,70%	70953	663,11	297	2,78	0,0000	19,97
2	12	0,6	89,34%	81521	747,90	323	2,96	0,0000	21,79
2	15	0,6	90,16%	84174	765,22	333	3,03	0,0000	15,55
3	0	0,6	72,13%	35906	408,02	176	2,00	0,0000	9,68
3	3	0,6	83,61%	56194	550,92	249	2,44	0,0000	51,92
3	6	0,6	87,70%	62134	580,69	272	2,54	0,0000	55,66
3	9	0,6	91,80%	68502	611,63	286	2,55	0,0001	26,66
3	12	0,6	94,26%	73655	640,48	303	2,63	0,0000	15,40
3	15	0,6	94,26%	73182	636,37	302	2,63	0,0000	14,51
1	0	0,4	37,70%	11773	255,93	92	2,00	0,0000	8,46
1	3	0,4	46,72%	18217	319,60	129	2,26	0,0000	8,76
1	6	0,4	46,72%	18217	319,60	129	2,26	0,0000	8,72
1	9	0,4	46,72%	18217	319,60	129	2,26	0,0000	8,37
1	12	0,4	46,72%	18217	319,60	129	2,26	0,0000	9,41
1	15	0,4	46,72%	18217	319,60	129	2,26	0,0000	8,90
2	0	0,4	47,54%	15066	259,76	116	2,00	0,0000	8,23
2	3	0,4	56,56%	24911	361,03	164	2,38	0,0000	8,77
2	6	0,4	59,02%	27121	376,68	175	2,43	0,0000	8,72
2	9	0,4	59,02%	27121	376,68	175	2,43	0,0000	9,00
2	12	0,4	59,02%	27121	376,68	175	2,43	0,0000	8,83
2	15	0,4	59,02%	27121	376,68	175	2,43	0,0000	8,26
3	0	0,4	54,92%	17960	268,06	134	2,00	0,0000	8,26
3	3	0,4	62,30%	26986	355,08	178	2,34	0,0000	9,05
3	6	0,4	65,57%	28558	356,98	193	2,41	0,0000	8,90
3	9	0,4	65,57%	28558	356,98	193	2,41	0,0000	8,21
3	12	0,4	65,57%	28558	356,98	193	2,41	0,0000	8,58
3	15	0,4	65,57%	28558	356,98	193	2,41	0,0000	8,86

APÊNDICE D – Resultados do modelo para instância de São Paulo

P	Q	B	Cobertura	Energia	Energia média	Arcos	Média de arcos	Gap	Tempo
1	0	1	92,00%	95948	521,46	368	2,00	0,0000	101,02
1	3	1	100,00%	117348	586,74	425	2,13	0,0000	451,64
1	6	1	100,00%	117184	585,92	427	2,14	0,0000	355,31
1	9	1	100,00%	117177	585,89	429	2,15	0,0000	291,09
1	12	1	100,00%	117177	585,89	429	2,15	0,0000	315,31
1	15	1	100,00%	117177	585,89	422	2,11	0,0000	287,82
2	0	1	99,00%	93272	471,07	396	2,00	0,0000	86,71
2	3	1	100,00%	91227	456,14	405	2,03	0,0000	244,23
2	6	1	100,00%	91213	456,07	409	2,05	0,0000	238,73
2	9	1	100,00%	91213	456,07	410	2,05	0,0000	241,55
2	12	1	100,00%	91213	456,07	410	2,05	0,0000	226,89
2	15	1	100,00%	91213	456,07	428	2,14	0,0000	245,15
3	0	1	100,00%	77304	386,52	400	2,00	0,0000	86,16
3	3	1	100,00%	76561	382,81	404	2,02	0,0000	190,64
3	6	1	100,00%	76561	382,81	405	2,03	0,0000	186,34
3	9	1	100,00%	76561	382,81	408	2,04	0,0000	188,68
3	12	1	100,00%	76561	382,81	404	2,02	0,0000	192,36
3	15	1	100,00%	76561	382,81	405	2,03	0,0000	190,22
1	0	0,8	84,50%	81328	481,23	338	2,00	0,0000	68,85
1	3	0,8	98,00%	115380	588,67	434	2,21	0,0957	3682,53
1	6	0,8	100,00%	119292	596,46	450	2,25	0,0000	653,70
1	9	0,8	100,00%	117798	588,99	461	2,31	0,0000	261,75
1	12	0,8	100,00%	117763	588,82	461	2,31	0,0000	355,67
1	15	0,8	100,00%	117763	588,82	461	2,31	0,0000	302,36
2	0	0,8	94,50%	81344	430,39	378	2,00	0,0000	98,02
2	3	0,8	100,00%	94331	471,66	418	2,09	0,0001	468,33
2	6	0,8	100,00%	91653	458,27	423	2,12	0,0000	309,11
2	9	0,8	100,00%	91587	457,94	425	2,13	0,0000	296,89
2	12	0,8	100,00%	91587	457,94	437	2,19	0,0000	280,71
2	15	0,8	100,00%	91587	457,94	437	2,19	0,0000	260,33
3	0	0,8	99,50%	85262	428,45	398	2,00	0,0000	89,24
3	3	0,8	100,00%	77048	385,24	410	2,05	0,0000	347,24
3	6	0,8	100,00%	76784	383,92	413	2,07	0,0000	290,23
3	9	0,8	100,00%	76784	383,92	414	2,07	0,0000	234,93
3	12	0,8	100,00%	76784	383,92	413	2,07	0,0000	245,54
3	15	0,8	100,00%	76784	383,92	415	2,08	0,0000	206,38
1	0	0,6	66,50%	53479	402,10	266	2,00	0,0000	70,50
1	3	0,6	89,50%	96132	537,05	430	2,40	0,1852	3695,27
1	6	0,6	97,00%	118048	608,49	512	2,64	0,1325	3650,91

1	9	0,6	99,50%	123051	618,35	537	2,70	0,0513	3650,00
1	12	0,6	100,00%	120662	603,31	540	2,70	0,0000	137,72
1	15	0,6	100,00%	120470	602,35	539	2,70	0,0000	145,94
2	0	0,6	83,00%	61691	371,63	332	2,00	0,0000	53,48
2	3	0,6	96,00%	88796	462,48	430	2,24	0,1262	3651,57
2	6	0,6	99,50%	102147	513,30	466	2,34	0,0754	3653,04
2	9	0,6	100,00%	94176	470,88	478	2,39	0,0000	150,60
2	12	0,6	100,00%	93649	468,25	470	2,35	0,0001	180,75
2	15	0,6	100,00%	93357	466,79	487	2,44	0,0000	137,10
3	0	0,6	92,50%	67495	364,84	370	2,00	0,0000	53,50
3	3	0,6	98,50%	82206	417,29	421	2,14	0,0673	3652,01
3	6	0,6	100,00%	80047	400,24	437	2,19	0,0001	791,10
3	9	0,6	100,00%	78120	390,60	444	2,22	0,0000	215,54
3	12	0,6	100,00%	77754	388,77	440	2,20	0,0000	148,17
3	15	0,6	100,00%	77754	388,77	442	2,21	0,0000	134,77
1	0	0,4	38,00%	21693	285,43	152	2,00	0,0000	40,25
1	3	0,4	63,00%	53238	422,52	326	2,59	0,0000	611,94
1	6	0,4	76,50%	75786	495,33	456	2,98	0,0000	82,81
1	9	0,4	79,00%	81063	513,06	487	3,08	0,0000	74,06
1	12	0,4	79,00%	81063	513,06	487	3,08	0,0000	74,46
1	15	0,4	79,00%	81063	513,06	487	3,08	0,0000	79,50
2	0	0,4	57,50%	31306	272,23	230	2,00	0,0000	40,23
2	3	0,4	74,50%	61858	415,15	395	2,65	0,0000	643,71
2	6	0,4	83,00%	73891	445,13	465	2,80	0,0000	925,83
2	9	0,4	87,50%	81748	467,13	507	2,90	0,0001	126,32
2	12	0,4	89,50%	85288	476,47	526	2,94	0,0001	91,94
2	15	0,4	91,00%	88410	485,77	545	2,99	0,0000	103,26
3	0	0,4	71,50%	38093	266,38	286	2,00	0,0000	41,61
3	3	0,4	84,00%	57351	341,38	390	2,32	0,0000	374,68
3	6	0,4	89,50%	71241	397,99	456	2,55	0,0000	311,08
3	9	0,4	92,50%	74408	402,21	471	2,55	0,0000	347,84
3	12	0,4	94,00%	77729	413,45	489	2,60	0,0000	176,66
3	15	0,4	94,50%	76518	404,86	483	2,56	0,0001	96,56

Anexos

ANEXO A – Pontos de Facilidades - Portland

ID	Latitude	Longitude
0	45.8169	-122.7459
1	45.8625	-122.6605
2	45.7812	-122.5273
3	45.6920	-122.5452
4	45.6610	-122.6360
5	45.6259	-122.5361
6	45.6335	-122.6613
7	45.6431	-122.6255
8	45.5820	-122.3905
9	45.5797	-122.3542
10	45.6923	-121.8941
11	45.7380	-121.5386
12	45.4682	-123.1438
13	45.5987	-122.9961
14	45.2993	-122.9750
15	45.3046	-122.9365
16	45.0740	-123.6141
17	45.2125	-123.1940
18	45.2432	-123.1160
19	45.2753	-123.0136
20	45.2191	-123.0760
21	45.0979	-123.3960
22	45.0765	-123.4832
23	46.1034	-123.2021
24	46.0933	-122.9440
25	45.8626	-122.8090
26	45.8459	-122.8259
27	45.5372	-122.2658
28	45.2852	-122.3368
29	45.0424	-122.6677
30	45.1499	-122.5777
31	45.5346	-122.6247

32	45.5708	-122.6097
33	45.5537	-122.6759
34	45.5339	-122.6854
35	45.4831	-122.8041
36	45.5167	-122.6071
37	45.5625	-122.6666
38	45.5986	-122.7853
39	45.5662	-122.6746
40	45.5502	-122.6619
41	45.5076	-122.4215
42	45.5206	-123.1042
43	45.5051	-122.4856
44	45.4266	-122.6061
45	45.4312	-122.5822
46	45.4771	-122.7040
47	45.4913	-122.6014
48	45.3036	-122.7586
49	45.3828	-122.7321
50	45.3863	-122.7670
51	45.3856	-122.7605
52	45.4233	-122.7685
53	45.5368	-122.4358
54	45.5212	-123.0579
55	45.5368	-122.8343
56	45.3968	-122.2691
57	45.4450	-122.7952
58	45.5290	-122.8065
59	45.2525	-122.6865
60	45.5987	-122.9961
61	45.3525	-122.5980
62	45.3816	-122.5923
63	45.4461	-122.6192
64	45.2852	-122.3368
65	45.3838	-122.5976
66	45.5976	-123.0012
67	45.5623	-122.6676
68	45.4666	-122.7535
69	45.5229	-122.9820
70	45.3608	-122.8451

71	45.4316	-122.7151
72	45.3535	-122.8665
73	45.4091	-122.7963
74	45.4824	-122.5887
75	45.4401	-122.8366
76	45.5074	-122.7971
77	45.5696	-122.6736
78	45.4682	-122.7100
79	45.4946	-122.6305
80	45.5085	-122.7179
81	45.1500	-122.5778
82	45.5199	-122.6246
83	45.5503	-122.6857
84	45.5422	-122.6649
85	45.4758	-122.7221
86	45.4487	-122.8064
87	45.5618	-122.6819
88	45.3549	-122.6060
89	45.5154	-122.9748
90	45.4710	-122.6790
91	45.5147	-122.9769
92	45.5278	-122.7097
93	45.5877	-122.7114
94	45.5158	-122.5532
95	45.5268	-122.5785
96	45.4648	-122.6513
97	45.5922	-122.7522
98	45.4798	-122.6188
99	45.4262	-122.6679
100	45.3699	-122.6488
101	45.4798	-122.8040
102	45.5396	-122.9626
103	45.3102	-122.7982

ANEXO B – Pontos de demandas - Portland

ZCTA	Latitude	Longitude	Demand(kg)
97014	45.5829	-122.0168	4.50
97019	45.5156	-122.2427	4.00
97024	45.5466	-122.4424	3.25
97030	45.5092	-122.4336	1.75
97060	45.5313	-122.3691	2.75
97080	45.4783	-122.3907	3.75
97201	45.5079	-122.6908	2.00
97202	45.4827	-122.6444	4.50
97203	45.6035	-122.7379	4.75
97204	45.5184	-122.6739	2.25
97205	45.5206	-122.7102	3.25
97206	45.4824	-122.5986	3.75
97208	45.5287	-122.6790	3.25
97209	45.5311	-122.6839	2.25
97210	45.5442	-122.7267	4.75
97211	45.5811	-122.6373	4.25
97212	45.5442	-122.6435	3.50
97213	45.5382	-122.6000	1.25
97214	45.5147	-122.6430	2.50
97215	45.5151	-122.6006	2.75
97216	45.5139	-122.5584	2.75
97217	45.6018	-122.7008	1.75
97218	45.5763	-122.6009	3.25
97219	45.4542	-122.6985	1.25
97220	45.5500	-122.5593	3.25
97221	45.4983	-122.7288	2.50
97227	45.5434	-122.6781	4.50
97230	45.5578	-122.5053	1.25
97231	45.6876	-122.8242	3.25
97232	45.5289	-122.6439	3.50
97233	45.5151	-122.5033	2.00
97236	45.4829	-122.5098	5.00

97239	45.4924	-122.6925	3.25
97266	45.4830	-122.5582	5.00
97004	45.2550	-122.4494	4.75
97009	45.4230	-122.3328	1.75
97011	45.3871	-122.0264	1.25
97013	45.2208	-122.6683	2.00
97015	45.4135	-122.5368	1.25
97017	45.1765	-122.3897	1.50
97022	45.3467	-122.3200	2.25
97056	45.7720	-122.9694	4.50
97064	45.8591	-123.2355	4.00
97101	45.0902	-123.2287	4.25
97111	45.2845	-123.1952	3.75
97114	45.1879	-123.0766	3.75
97115	45.2752	-123.0395	3.50
97127	45.2461	-123.1114	4.25
97128	45.2119	-123.2822	4.25
97132	45.3242	-122.9873	5.00
97148	45.3584	-123.2485	3.75
97347	45.0771	-123.6564	1.50
97396	45.1040	-123.5490	3.75
97005	45.4910	-122.8036	3.25
97006	45.5170	-122.8598	3.25
97007	45.4543	-122.8796	2.00
97008	45.4602	-122.8042	2.25
97062	45.3693	-122.7623	1.75
97106	45.6657	-123.1190	3.75
97109	45.7378	-123.1812	3.00
97113	45.4972	-123.0443	1.50
97023	45.2785	-122.3232	3.75
97027	45.3856	-122.5928	4.50
97028	45.2884	-121.8074	4.75
97034	45.4094	-122.6835	1.50
97035	45.4135	-122.7252	2.75
97038	45.0954	-122.5590	2.25
97042	45.2052	-122.5398	4.25
97045	45.3203	-122.5365	2.25
97049	45.3464	-121.8624	2.25
97055	45.3888	-122.1552	1.25

97067	45.2978	-122.0544	3.25
97068	45.3523	-122.6686	5.00
97070	45.3061	-122.7731	2.25
97086	45.4452	-122.5281	5.00
97089	45.4266	-122.4431	3.00
97222	45.4409	-122.6181	1.25
97267	45.4084	-122.6129	2.00
98601	45.9434	-122.3625	1.75
98604	45.8057	-122.5108	4.00
98606	45.7297	-122.4564	3.75
98607	45.6422	-122.3800	3.00
98629	45.8766	-122.6192	1.75
98642	45.8077	-122.6939	1.75
98660	45.6790	-122.7205	1.50
98661	45.6401	-122.6250	3.75
98662	45.6885	-122.5778	3.00
98663	45.6574	-122.6632	3.00
98664	45.6195	-122.5772	4.00
98665	45.6795	-122.6606	1.50
98675	45.8285	-122.3429	2.50
98682	45.6732	-122.4817	4.50
98683	45.6033	-122.5102	3.25
98684	45.6306	-122.5148	4.00
98685	45.7152	-122.6931	4.75
98686	45.7234	-122.6244	1.25
97016	46.0603	-123.2670	1.75
97018	45.8971	-122.8106	2.75
97048	46.0448	-122.9820	2.75
97051	45.8793	-122.9500	3.75
97053	45.8280	-122.8833	2.75
97054	45.9422	-122.9496	1.25
97116	45.5808	-123.1657	2.00
97117	45.6314	-123.2884	3.00
97119	45.4689	-123.2002	3.25
97123	45.4402	-122.9801	2.75
97124	45.5698	-122.9496	2.25
97125	45.6711	-123.1969	1.75
97133	45.6861	-123.0227	3.50
97140	45.3531	-122.8659	4.50

97144	45.7416	-123.3002	2.25
97223	45.4403	-122.7766	3.75
97224	45.4055	-122.7951	1.75
97225	45.5016	-122.7700	2.00
97229	45.5510	-122.8093	2.00
98605	45.7769	-121.6655	4.25
98610	45.8659	-122.0652	4.75
98616	46.1933	-122.1329	4.75
98639	45.6699	-121.9897	1.75
98648	45.7063	-121.9563	2.75
98651	45.7399	-121.5835	3.50
98671	45.6144	-122.2384	1.50

ANEXO C – Parâmetros referentes aos drones

Parameter	Value
Power transfer efficiency	0.66
Lift to drag ratio	3.5
Tare weight (kg)	10.1
Maximum payload (kg)	5
Battery capacity (W/h)	777
Battery safety factor (80% of Maximum Battery Capacity)	1.25

Declaração de Uso de Inteligência Artificial Generativa

Durante a preparação deste documento, eu, João Pedro Silva Bicalho, estudante de graduação em Ciência da Computação da Universidade Federal de Ouro Preto, declaro o uso de IAGen «Gemini versão 3.1 Pro» para revisão textual e geração de códigos LaTeX.

Após o uso desta ferramenta/modelo/serviço, eu revisei e editei o conteúdo em conformidade com os princípios éticos para uso de IAGen (Resolução CONPEP nº 144) e com os acordos estabelecidos com o(a) orientador(a) desta pesquisa. Dessa forma, assumo total responsabilidade pelo conteúdo da publicação.