



CENTRO FEDERAL DE EDUCAÇÃO  
TECNOLÓGICA DE MINAS GERAIS

Diretoria de Pesquisa e Pós-Graduação

Programa de Pós-Graduação em Modelagem  
Matemática e Computacional

ALGORITMOS HEURÍSTICOS  
PARA OS PROBLEMAS DE  
LOCALIZAÇÃO-ALOCAÇÃO DE  
MAMÓGRAFOS E ROTEAMENTO DE  
UNIDADES MÓVEIS DE MAMOGRAFIA

Dissertação de Mestrado, submetida ao Programa de Pós-Graduação em Modelagem Matemática e Computacional, como parte dos requisitos para a obtenção do título de Mestre em Modelagem Matemática e Computacional.

**Aluno** : Romário dos Santos Lopes de Assis

**Orientador** : Prof. Dr. Marccone Jamilson F. Souza (UFOP)

**Coorientadora** : Profa. Dra. Maria Amélia Lopes Silva (UFV)

**Coorientador** : Prof. Dr. Eduardo Camargo de Siqueira (IFB)

Belo Horizonte - MG  
Julho de 2023

A848a Assis, Romário dos Santos Lopes de  
Algoritmos heurísticos para os problemas de localização-alocação de mamógrafos e roteamento de unidades móveis de mamografia / Romário dos Santos Lopes de Assis. – 2023.  
xii, 52 f.

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Modelagem Matemática e Computacional.

Orientador: Marcone Jamilson F. Souza.

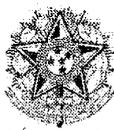
Coorientadora: Maria Amélia Lopes Silva.

Coorientador: Eduardo Camargo de Siqueira

Dissertação (mestrado) – Centro Federal de Educação Tecnológica de Minas Gerais.

1. Sistema Único de Saúde (Brasil). Unidade Móvel de Mamografia – Modelos matemáticos – Teses. 2. Problema de roteamento de veículos – Teses. 3. Instalações de saúde – Administração – Teses. 4. Metaheurísticas – Teses. 5. Integrais múltiplas – Teses. 6. Pesquisa geral de vizinhança variável – Teses. I. Souza, Marcone Jamilson Freitas. II. Silva, Maria Amélia Lopes. III. Siqueira, Eduardo Camargo de. IV. Centro Federal de Educação Tecnológica de Minas Gerais. V. Título.

CDD 519.5



SERVIÇO PÚBLICO FEDERAL  
MINISTÉRIO DA EDUCAÇÃO  
CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS  
COORDENAÇÃO DO CURSO DE MESTRADO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL

**“ALGORITMOS HEURÍSTICOS PARA OS PROBLEMAS DE LOCALIZAÇÃO-ALOCAÇÃO DE MAMÓGRAFOS E ROTEAMENTO DE UNIDADES MÓVEIS DE MAMOGRAFIA”**

Dissertação de Mestrado apresentada por **Romário dos Santos Lopes de Assis**, em 11 de julho de 2023, ao Programa de Pós-Graduação em Modelagem Matemática e Computacional do CEFET-MG, e aprovada pela banca examinadora constituída pelos professores:

Prof. Dr. Marcone Jamilson Freitas Souza  
Universidade Federal de Ouro Preto

Prof. Dr. Eduardo Camargo de Siqueira  
Instituto Federal de Brasília

Prof.<sup>a</sup> Dr.<sup>a</sup> Maria Amélia Lopes Silva  
Universidade Federal de Viçosa

Prof.<sup>a</sup> Dr.<sup>a</sup> Tatiana Alves Costa  
Universidade Federal de Ouro Preto

Prof.<sup>a</sup> Dr.<sup>a</sup> Elisangela Martins de Sá  
Centro Federal de Educação Tecnológica de Minas Gerais

Prof. Dr. Sérgio Ricardo de Souza  
Centro Federal de Educação Tecnológica de Minas Gerais

Visto e permitida a impressão,

Prof. Dr. Thiago de Souza Rodrigues  
Coordenador do Programa de Pós-Graduação em  
Modelagem Matemática e Computacional

Aos meus pais, José e Divina, pelo exemplo e apoio incondicional.

# Agradecimentos

Agradeço primeiramente a DEUS pelo dom da vida e a graça da sabedoria concedida a nós, meros transeuntes. Depois Dele, agradeço à minha noiva Geaine, pelo companheirismo durante toda essa etapa da minha vida, incentivo, apoio e compreensão pelo tempo ausente. A meus pais, José e Divina, irmãs, Júnia e Natália e demais familiares que sempre me incentivaram e acreditaram na minha capacidade de superar os obstáculos da vida.

Aos professores Marcone Jamilson Freitas Souza, Sérgio Ricardo de Souza, Maria Amélia Lopes Silva e Eduardo Camargo de Siqueira pela orientação, conhecimentos transmitidos e a confiança em mim depositada. Aos demais professores, pela sabedoria e conhecimentos transmitidos. Não poderia deixar de agradecer, também, aos amigos Marcos e Jardell, por todo o auxílio que me prestaram.

À administração da UFV e aos amigos de trabalho, Afrânio de Castro, Adilson Lopes, Antônio de Pádua (vulgo Liu), Lilian Beatriz, Santiago Gaudêncio e Wellington Simões pela parceria, incentivo e apoio. Enfim, a todos que me auxiliaram de alguma forma nesta importante etapa da minha vida, o meu muito obrigado.

*“Não se preocupe com suas falhas, no que tentou fazer, mas no que ainda é possível realizar.”*

# Resumo

Esta dissertação tem seu foco no problema de cobertura de exames de mamografia no Sistema Único de Saúde do Brasil. Este problema foi decomposto em dois subproblemas que são resolvidos sequencialmente: o Problema de Localização e Alocação de Mamógrafos fixos (PLAM) e o de Roteirização das Unidades Móveis de Mamografia (MMURP). No primeiro problema, o objetivo é determinar a localização de mamógrafos fixos e as cidades por ele atendidas satisfazendo a um conjunto de restrições, entre as quais a limitação da distância de atendimento. Dado que cidades sem infraestrutura hospitalar para sediar um mamógrafo fixo e distantes de outras com infraestrutura não podem ser atendidas por mamógrafos fixos, então, para cobri-las são utilizadas Unidades Móveis de Mamografia (MMUs). A roteirização das MMUs dá origem ao segundo subproblema. Para resolver o PLAM foram desenvolvidos dois algoritmos de otimização baseados nas meta-heurísticas *Iterated Greedy Search* (IGS) e *General Variable Neighborhood Search* (GVNS), nomeados IGS-PLAM e GVNS-PLAM, respectivamente. Esses algoritmos utilizam uma nova representação de solução que permite identificar individualmente cada equipamento instalado em uma cidade. Além disso, eles usam novas estruturas de vizinhança. Para testá-los foram utilizadas instâncias da literatura referente a dados reais de estados brasileiros. Os resultados desses algoritmos foram comparados com aqueles produzidos por um algoritmo da literatura e com os do resolvedor CPLEX. Em seguida, para cada instância, o conjunto de cidades não atendidas integralmente pelos mamógrafos fixos na melhor solução gerada pelos algoritmos propostos é utilizado como instância para a solução do MMURP. Esse segundo subproblema é resolvido por meio de um algoritmo heurístico construtivo que determina o número de MMUs e suas respectivas rotas de forma a atender toda a demanda existente. Esta metodologia foi utilizada para gerar soluções para sete estados da federação brasileira.

**Palavras-chaves:** Problema de Localização e Alocação de Mamógrafos. Problema de Roteamento de Veículos. Unidades Móveis de Mamografia. Metaheurísticas. *Iterated Greedy Search*. *General Variable Neighborhood Search*.

# Abstract

This dissertation focuses on the mammography unit coverage problem in the Brazilian Unified Health System. This problem was decomposed into two sub-problems that are solved sequentially: the Mammography Location-Allocation Problem (MLAP) and the Mammography Mobile Unit Routing Problem (MMURP). In the first problem, the objective is to determine the location of fixed mammography units and the cities they serve, satisfying a set of constraints, among which is the limitation of the service distance. Since cities without hospital infrastructure to host a fixed mammography unit and far from other cities with infrastructure can not be served by fixed mammography units, mobile mammography units (MMUs) are used to cover them. The routing of MMUs gives rise to the second subproblem. To solve the MLAP, two optimization algorithms based on Iterated Greedy Search (IGS) and General Variable Neighborhood Search (GVNS) metaheuristics were developed, named IGS-MLAP and GVNS-MLAP, respectively. These algorithms use a new solution representation that allows for the individual identification of each mammography unit installed in a city. In addition, they use new neighborhood structures. Instances from the literature referring to real data from Brazilian states were used to test them. The results of these algorithms were compared with those produced by an algorithm from the literature and with those of the CPLEX solver. Then, for each instance, the set of cities not fully served by the fixed mammography devices in the best solution generated by the proposed algorithms is used as an instance for the MMURP solution. This second sub-problem is solved by a constructive heuristic algorithm that determines the number of MMUs and their routes to meet the existing demand. This methodology was used to generate solutions for seven states of the Brazilian Federation.

**Keywords:** Mammography Location-Allocation Problem. Vehicle Routing Problem. Mobile Mammography Units. Metaheuristics. *Iterated Greedy Search*. *General Variable Neighborhood Search*.

# Sumário

Lista de Acrônimos . . . . .	x
Lista de Tabelas . . . . .	x
Lista de Figuras . . . . .	xi
Lista de Algoritmos . . . . .	xii
<b>1 Introdução</b>	<b>1</b>
1.1 Contextualização . . . . .	1
1.2 Justificativa . . . . .	2
1.3 Objetivo Geral . . . . .	3
1.4 Objetivos Específicos . . . . .	3
1.5 Estrutura da Dissertação . . . . .	3
<b>2 Descrição dos Problemas de Localização e Alocação de Mamógrafos e de Roteamento de Unidades Móveis de Mamografia</b>	<b>5</b>
2.1 Problema de Localização e Alocação de Mamógrafos . . . . .	5
2.2 Problema de Roteamento de Unidades Móveis de Mamografia . . . . .	8
<b>3 Revisão de Literatura</b>	<b>12</b>
3.1 Revisão de trabalhos sobre o PLAM . . . . .	12
3.2 Trabalhos Correlatos ao PLAM . . . . .	14
3.3 Revisão de trabalhos correlatos ao MMURP . . . . .	17
3.4 Meta-heurísticas . . . . .	18
<b>4 Métodos de solução propostos</b>	<b>21</b>
4.1 IGS para o PLAM . . . . .	21
4.1.1 Representação da Solução . . . . .	21
4.1.2 Função de Avaliação . . . . .	22
4.1.3 Construção da Solução Inicial . . . . .	22
4.1.4 Estruturas de Vizinhança . . . . .	23
4.1.5 Algoritmo IGS Proposto . . . . .	25
4.2 GVNS para o PLAM . . . . .	27
4.2.1 Representação da solução . . . . .	27
4.2.2 Funções de Avaliação . . . . .	27
4.2.3 Construção da Solução Inicial . . . . .	28
4.2.4 Busca Local Utilizada . . . . .	29
4.2.5 Estruturas de Vizinhança . . . . .	29
4.2.6 Algoritmo GVNS Proposto . . . . .	32
4.3 Método construtivo para o MMURP . . . . .	33

4.3.1	Representação da Solução . . . . .	33
4.3.2	Construção da Solução . . . . .	34
<b>5</b>	<b>Experimentos Computacionais</b>	<b>37</b>
5.1	Ambiente de desenvolvimento . . . . .	37
5.2	Resultados para o PLAM . . . . .	37
5.2.1	Instâncias para o PLAM . . . . .	37
5.2.2	Resultados da aplicação do algoritmo IGS-PLAM . . . . .	38
5.2.3	Resultados da aplicação do algoritmo GVNS-PLAM . . . . .	39
5.3	Resultados para o MMURP . . . . .	41
5.3.1	Instâncias para o MMURP . . . . .	41
5.3.2	Resultados do algoritmo construtivo ao MMURP . . . . .	42
<b>6</b>	<b>Considerações Finais e Direções Futuras</b>	<b>45</b>
6.1	Considerações Finais . . . . .	45
6.2	Publicações derivadas desta pesquisa . . . . .	46
6.3	Direções Futuras . . . . .	47
	<b>Referências Bibliográficas</b>	<b>48</b>

# Lista de Siglas

**GRASP** *Greedy Randomized Adaptive Search Procedures*

**GVNS** *General Variable Neighborhood Search*

**IGS** *Iterated Greedy Search*

**INCA** Instituto Nacional do Câncer

**LC** Lista de Candidatos

**LRC** Lista Restrita de Candidatos

**MMU** Unidade Móvel de Mamografia

**MMURP** Problema de Roteamento de Unidades Móveis de Mamografia

**OVRP** Problema de Roteamento Aberto de Veículos

**PLAM** Problema de Localização e Alocação de Mamógrafos

**PLMC** Problema de Localização de Máxima Cobertura

**PRV** Problema de Roteamento de Veículos

**SA** *Simulated Annealing*

**VND** *Variable Neighborhood Descent*

**VNS** *Variable Neighborhood Search*

# Lista de Tabelas

2.1	Descrição dos parâmetros e variáveis de decisão do PLAM . . . . .	6
3.1	Trabalhos - Problema de Localização de Mamógrafos . . . . .	15
3.2	Trabalhos correlatos - MMURP . . . . .	18
5.1	Resultados gerados pelo CPLEX . . . . .	39
5.2	Comparação entre os resultados dos métodos <i>Simulated Annealing</i> e IGS	39
5.3	Valores dos parâmetros testados e retornados pelo Irace . . . . .	40
5.4	Comparação entre os resultados dos métodos <i>Simulated Annealing</i> e GVNS aplicados ao PLAM . . . . .	40
5.5	Resultados obtidos pelos algoritmos IGS-PLAM e GVNS-PLAM. . . . .	41
5.6	Resultados do algoritmo construtivo aplicado ao MMURP . . . . .	42
5.7	Solução MMURP - Instância MMURP-PI-IGS . . . . .	44

# Lista de Figuras

2.1	Exemplo de alocação. . . . .	8
2.2	Exemplo de roteirização para o Estado de Rondônia, Brasil. . . . .	10
2.3	Detalhamento das rotas da Figura 2.2. . . . .	10
4.1	Representação da solução. . . . .	22
4.2	Um exemplo da estrutura de vizinhança Realoca Mamógrafo. . . . .	24
4.3	Um exemplo da estrutura de vizinhança Realoca Atendimento Intra Mamógrafo. . . . .	25
4.4	Representação da solução. . . . .	27
4.5	Exemplo das estruturas de vizinhança Realoca Mamógrafo e Realoca Atendimento Intra Mamógrafo. . . . .	30
4.6	Exemplo da estrutura de vizinhança Realoca Atendimento Intra Mamógrafo . . . . .	31
4.7	Exemplo da estrutura de vizinhança Realoca Atendimento Inter Mamógrafo . . . . .	32
4.8	Exemplo da estrutura de vizinhança Busca Atendimento . . . . .	32
4.9	Exemplo de solução MMURP. . . . .	34
5.1	Rotas MMURP - Instância MMURP-PI-IGS . . . . .	43

# Lista de Algoritmos

1	IGS-Basico()	19
2	GRASP-Basico()	20
3	GVNS-Basico()	20
4	solucaoInicial( <i>dados</i> )	23
5	IGS( <i>dados</i> , <i>parada</i> , <i>nivel</i> <sub>max</sub> , <i>k</i> <sub>max</sub> )	26
6	VND( <i>k</i> <sub>max</sub> , <i>s</i> )	26
7	constroiSolucaoInicial( <i>s</i> , $\alpha$ )	28
8	VND_PLAM( <i>k</i> <sub>max</sub> , <i>iter</i> <sub>max</sub> , <i>s</i> )	29
9	GVNS-PLAM( <i>k</i> <sub>max</sub> , <i>iter</i> <sub>max</sub> , <i>s</i> )	33
10	constroiSolucaoMMURP( <i>LC</i> , $\alpha$ )	34
11	IniciaNovaRota ( <i>j</i> , <i>R</i> , <i>s</i> , <i>LC</i> , <i>novaRota</i> )	36

# Capítulo 1

## Introdução

Este Capítulo introduz a presente dissertação. A Seção 1.1 contextualiza os problemas objeto de investigação. Na Seção 1.2 são apresentadas as justificativas para realização desta pesquisa. A Seção 1.3 descreve o objetivo geral desta pesquisa e, na Seção 1.4, são apresentados seus objetivos específicos. A estrutura deste trabalho é apresentada na Seção 1.5.

### 1.1 Contextualização

O câncer de mama está entre as causas mais comuns de morte entre mulheres. Estudos apontam que, no ano de 2017, este tipo de câncer apresentou a terceira maior incidência em todo o mundo (Mohammadian-Hafshejani, 2019). Os estudos de Azamjah et al. (2019) mostram a evolução das taxas de incidência e mortalidade entre os anos de 1990 e 2015, sendo que os países da América Latina e Caribe apresentaram maior taxa crescente de mortalidade em razão da doença. O Instituto Nacional do Câncer (INCA) mostra que, no Brasil, a doença representou 16,3% dos óbitos por câncer no período de 2016 a 2020, ocupando o primeiro lugar no país (INCA, 2022b).

O rastreamento por mamografia é o principal meio de diagnóstico precoce da doença nos casos de neoplasia malignas (Xavier et al., 2016). Um estudo realizado na Suécia apontou que mulheres que realizaram rastreamento mamográfico reduziram em 41% a possibilidade de morte em 10 anos e em 25% nos casos avançados da doença (Duffy et al., 2020). Azamjah et al. (2019) e Ginsburg et al. (2020) afirmam que uma proporção significativa dos casos de câncer de mama em países de baixa e média renda é detectada em seu estágio avançado. dos Santos Silva et al. (2019) estima que 7500 mortes poderiam ter sido evitadas no Brasil, no ano de 2012, caso o diagnóstico fosse feito no estágio precoce da doença.

A mamografia de rastreamento é recomendada bianualmente para mulheres da faixa etária entre 50 e 69 anos (INCA, 2022a; Migowski, 2018). Em mulheres com idades entre 40 e 49 anos, os efeitos negativos do rastreamento mamográfico superam os benefícios. Deve-se alertar que as taxas de falso positivo causam danos psicológicos, além de trazer falsa segurança, nos casos em que o diagnóstico é negativo quando, de fato, há presença do nódulo (Migowski, 2018).

No Brasil há disponibilidade suficiente de equipamentos para atender todo o público alvo; contudo, a distribuição espacial destes equipamentos é ineficiente (Amaral et al., 2017). Isto é, algumas regiões são sobrecobertas e outras descobertas pelo

número insuficiente de equipamentos. O Problema de Localização e Alocação de Mamógrafos (Problema de Localização e Alocação de Mamógrafos (PLAM)) surge, portanto, como parte dos esforços para melhorar a distribuição e localização destes equipamentos. Este problema consiste em definir a localização mais adequada de equipamentos de mamografia e sua rede de atendimento, de forma a ampliar a cobertura de exames. Nos últimos anos, autores como Souza et al. (2019), Sá et al. (2019), Rosa et al. (2020), de Campos (2020), dentre outros, apresentaram soluções baseadas em modelagem matemática e meta-heurísticas para o PLAM. No entanto, apesar de as soluções apresentadas serem eficientes, ainda restam lacunas a serem preenchidas, pois há, em muitos casos, insuficiência no número de equipamentos. Nessas situações, é necessário decidir aonde localizar os novos equipamentos a serem adquiridos, bem como a rede de atendimento deles. Além disso, muitas cidades não contam com infraestrutura hospitalar para sediar um mamógrafo e estão distantes de cidades com equipamentos instalados, impedindo de serem cobertas por mamógrafos fixos.

Autores como Vang et al. (2018) e Renck et al. (2014) mostram que a utilização de Unidade Móvel de Mamografia (MMU) pode contribuir para o aumento da cobertura dos exames de mamografia. Entretanto, os trabalhos citados não abordam a questão das geração de rotas para as MMUs, problema introduzido por Rosa et al. (2020).

Assim, esta dissertação propõe, inicialmente, solucionar o Problema de Localização e Alocação de Mamógrafos (PLAM) utilizando algoritmos baseados nas meta-heurísticas *General Variable Neighborhood Search (GVNS)* (Hansen et al., 2017) e *Iterated Greedy Search (IGS)* (Ruiz e Stützle, 2008). Para ampliar a cobertura que é provida pelas unidades fixas e cobrir a demanda remanescente, são utilizadas as MMUs. Para tratar o problema decorrente de roteirização dessas unidades móveis, conhecido como Problema de Roteamento de Unidades Móveis de Mamografia (Problema de Roteamento de Unidades Móveis de Mamografia (MMURP)), é proposto um algoritmo heurístico construtivo.

As principais contribuições desta dissertação são:

- (i) Desenvolvimento de uma nova representação de solução para o PLAM, permitindo identificar cada equipamento instalado em uma cidade;
- (ii) Inclusão de novas estruturas de vizinhança, permitindo melhor explorar o espaço de soluções do PLAM;
- (iii) Determinação da quantidade de MMUs necessárias ao atendimento da demanda remanescente do PLAM;
- (iv) Apresentação de uma proposta de roteirização das MMUs.

## 1.2 Justificativa

Sendo o câncer de mama a principal causa de morte entre a população feminina, no Brasil e no mundo, é necessário o empreendimento de esforços, por parte da comunidade científica e autoridades públicas, na busca de medidas que possam prevenir e amenizar seus efeitos neste público. O rastreamento mamográfico é o principal meio de detecção precoce da doença e é fator de elevado índice de sucesso em seu tratamento. Estes fatores, além do aspecto humanitário, que permite salvar vidas, gera

também economia, tanto aos cofres públicos, quanto aos pacientes acometidos pela doença.

Contudo, a localização geográfica dos equipamentos de mamografia nem sempre contribui para que as mulheres realizem o exame. Neste contexto, a adoção de algoritmos de otimização para a solução deste problema pode contribuir para uma melhor distribuição dos equipamentos de mamografia de forma a maximizar o número de exames realizados, trazendo economia aos cofres públicos e qualidade de vida às mulheres beneficiadas. Adicionalmente, o roteamento de [MMUs](#) permitirá atender principalmente às demandas da população feminina de cidades isoladas, que, devido à restrições de distância e porte para sediar novos equipamentos, não seriam atendidas na solução do [PLAM](#).

### 1.3 Objetivo Geral

A presente dissertação tem, como objetivo geral, desenvolver algoritmos heurísticos, baseados nas meta-heurísticas [GVNS](#) e [IGS](#), para a solução do [PLAM](#), e um algoritmo heurístico construtivo para a solução do [MMURP](#), de forma a cobrir a demanda remanescente porventura existente na solução do [PLAM](#).

### 1.4 Objetivos Específicos

Para alcançar o objetivo geral desta dissertação, são necessários os seguintes objetivos específicos:

- (i) Realizar pesquisa bibliográfica concernente aos principais temas abordados nesta dissertação. A pesquisa consiste em investigar os principais avanços no [PLAM](#), revisar as principais variantes do Problema de Roteamento de Veículos ([PRV](#)) e as meta-heurísticas a serem utilizadas no desenvolvimento;
- (ii) Identificar novas estruturas de vizinhança que permitam explorar melhor o espaço de solução do problema, alcançando assim melhores resultados;
- (iii) Desenvolver e implementar algoritmos heurísticos na linguagem `C++` baseados nas meta-heurísticas [GVNS](#) e [IGS](#) para a solução do [PLAM](#), e uma heurística construtiva para a solução do [MMURP](#);
- (iv) Calibrar os parâmetros dos algoritmos implementados utilizando a ferramenta *IRACE* ([López-Ibáñez et al., 2016](#)) com o objetivo de encontrar as melhores configurações para as instâncias utilizadas nesta dissertação;
- (v) Realizar testes computacionais de tal modo a garantir a integridade, confiabilidade e consistência dos resultados alcançados.

### 1.5 Estrutura da Dissertação

O restante deste trabalho está organizado como segue. No [Capítulo 2](#) são descritos os problemas de localização e alocação de mamógrafos e de roteirização de unidades

---

móveis de mamografia. No Capítulo 3 é feita a revisão bibliográfica acerca do PLAM e dos problemas de roteamento de veículos cujas características se assemelham às do MMURP, além das meta-heurísticas utilizadas nesta pesquisa. Já no Capítulo 4 são apresentados os métodos de solução desenvolvidos para o PLAM e para o MMURP. Os experimentos computacionais realizados com os métodos de solução desenvolvidos são descritos no Capítulo 5. Por fim, no Capítulo 6, são feitas as considerações finais e apresentadas as direções futuras para esta pesquisa.

# Capítulo 2

## Descrição dos Problemas de Localização e Alocação de Mamógrafos e de Roteamento de Unidades Móveis de Mamografia

Este capítulo está organizado como segue. Na Seção 2.1 descreve-se o problema de localização e alocação de mamógrafos, enquanto na Seção 2.2 descreve-se o problema de Roteamento de Unidades Móveis de Mamografia.

### 2.1 Problema de Localização e Alocação de Mamógrafos

Problemas de localização referem-se a métodos de modelagem, formulação e solução de uma classe de problemas relacionados à localização de facilidades em um determinado espaço, afirmam [Ahmadi-Javid et al. \(2017\)](#). Em seu trabalho, [ReVelle et al. \(2008\)](#) classificaram os problemas de localização em quatro classes básicas, sendo elas: (i) analítico; (ii) contínuo; (iii) de rede; e (iv) discreto. De modo geral, os problemas postos como contínuos são aqueles em que a facilidade pode estar localizada em qualquer lugar da região viável; já os classificados como discretos são aqueles em que a facilidade só pode ser instalada em um local candidato, podendo incluir os pontos de demanda ([Eiselt, 2011](#)). Os problemas de localização discretos são mais frequentemente abordados na área de saúde.

Entre os problemas de localização discretos, [Daskin \(2008\)](#) sugere três categorias: (i) baseados em cobertura; (ii) baseados em mediana e (iii) demais problemas. Os modelos baseados em cobertura consistem em estabelecer a quantidade e a localização de facilidades necessárias para o atendimento de uma demanda pré estabelecida. Os modelos baseados em medianas consistem em localizar um conjunto de facilidades de forma a minimizar a média ponderada da distância entre os pontos de demanda e as facilidades instaladas. Já aqueles que não se enquadram em nenhuma das duas categorias anteriores foram categorizados como outros problemas.

Dentre as categorias descritas por [Daskin \(2008\)](#), a mais frequentemente utilizada nos problemas de saúde é a do tipo cobertura. O problema de máxima cobertura,

Tabela 2.1: Descrição dos parâmetros e variáveis de decisão do PLAM	
Parâmetros	
$N$	Conjunto de cidades candidatas.
$S_i$	Conjunto de cidades cuja distância em relação à cidade $i$ seja menor ou igual a $R$ km, isto é, $S_i = \{j \in N \mid d_{ij} \leq R \text{ e } d_{ji} \leq R\}$ .
$d_{ij}$	Distância da cidade $i$ para a cidade $j$ .
$dem_j$	Demanda de mamografias da cidade $j$ .
$cap$	Capacidade anual de realização de exames de cada mamógrafo.
$p$	Número de mamógrafos a serem alocados.
$R$	Distância máxima que as mulheres devem viajar para realizar uma mamografia.
$demMin$	Quantidade mínima de exames, por ano, que uma cidade precisa para que seja candidata a sediar um equipamento de mamografia.
Variáveis de Decisão	
$x_{ij}$	Variável contínua no intervalo $[0, 1]$ , que indica a fração da demanda da cidade $j$ que é atendida por mamógrafos instalados na cidade $i$ .
$y_i$	Variável inteira que representa a quantidade de equipamentos instalados na cidade $i$ .
$z_i$	Variável binária que assume o valor 1 se $i$ é sede de um equipamento e 0, caso contrário.
$t_i$	Variável binária que assume o valor 1 se a demanda da cidade $i$ é totalmente coberta por mamógrafos instalados nela mesma e 0, caso contrário.

formulado inicialmente por [Church e Velle \(1974\)](#), consiste em obter uma configuração para a localização de um conjunto de  $p$  facilidades, definidas previamente, de modo a atender o maior número possível de indivíduos de uma população, considerando uma distância máxima ou um tempo limite entre o ponto de demanda e a localização da facilidade. A solução não consiste, necessariamente, em atender toda a população, mas em atender à maior demanda possível, considerando o número  $p$  de facilidades disponíveis.

No escopo do Problema de Localização de Mamógrafos, o trabalho de [Amaral et al. \(2017\)](#) destaca que, por determinação do Ministério da Saúde, conforme [Brasil \(2017\)](#), a distância entre a paciente e o mamógrafo deve ser de, no máximo, 60 km. Considerando, então, a limitação de distância, a restrição de cidades candidatas a sediarem um ou mais mamógrafos, a disponibilidade de equipamentos e um número pre-estabelecido de demandas, o problema de localização de mamógrafos pode ser tratado como um problema de localização de máxima cobertura.

Para apresentar o Problema de Localização e Alocação de Mamógrafos (PLAM), considere a Tabela 2.1, que identifica os parâmetros e as variáveis de decisão envolvidos em sua definição.

O PLAM é descrito em [de Campos \(2020\)](#) usando uma formulação de programação linear inteira mista, conforme a seguir:

$$\max \sum_{i \in N} \sum_{j \in S_i} dem_j \cdot x_{ij} \quad (2.1)$$

$$s.a \sum_{i \in S_j} x_{ij} \leq 1 \quad \forall j \in N \quad (2.2)$$

$$\sum_{i \in N} y_i = p \quad (2.3)$$

$$\sum_{j \in S_i} dem_j \cdot x_{ij} \leq cap \cdot y_i \quad \forall i \in N \quad (2.4)$$

$$z_i \geq y_i/p \quad \forall i \in N \quad (2.5)$$

$$z_i \leq y_i \quad \forall i \in N \quad (2.6)$$

$$t_i \leq z_i \quad \forall i \in N \quad (2.7)$$

$$t_i \geq dem_i \cdot x_{ii} - dem_i + 1 \quad \forall i \in N \quad (2.8)$$

$$t_i \leq x_{ii} \quad \forall i \in N \quad (2.9)$$

$$t_i \geq x_{ij} \quad \forall i, \forall j \in N \mid i \neq j \quad (2.10)$$

$$y_i = 0 \quad \forall i \in N \mid dem_i < demMin \quad (2.11)$$

$$x_{ij} \in [0, 1] \quad \forall i, \forall j \in N \quad (2.12)$$

$$y_i \in \mathbb{Z} \quad \forall i \in N \quad (2.13)$$

$$z_i \in \{0, 1\} \quad \forall i \in N \quad (2.14)$$

$$t_i \in \{0, 1\} \quad \forall i \in N \quad (2.15)$$

A função objetivo expressa na Expressão (2.1) visa maximizar a demanda de mamografias. O conjunto das restrições (2.2) garante que a demanda da cidade  $j$  seja atendida em no máximo 100%. As restrições (2.3) garantem que sejam instalados no máximo  $p$  mamógrafos. As restrições (2.4), por sua vez, impedem que os mamógrafos instalados na cidade atendam mais que a capacidade máxima de realização de exames. Já as restrições (2.5) e (2.6) fazem com que a variável de decisão  $z_i$  seja 1 no caso de existir pelo menos um mamógrafo instalado na cidade  $i$  e 0, caso contrário. As restrições (2.7), (2.8) e (2.9) definem  $t_i$  igual a 1 quando a demanda da cidade  $i$  é coberta integralmente com aqueles mamógrafos nela instalados, e igual a 0, caso contrário, isto garante que um mamógrafo instalado em uma cidade  $i$  atenda a demanda de uma cidade  $j$  somente se a demanda da cidade  $i$  for completamente coberta. Além disso, as restrições garantem que uma cidade  $j$  seja atendida por uma cidade  $i$  somente se houver mamógrafo instalado nesta última. As restrições (2.10) definem que uma cidade  $i$  só fornece exames para uma cidade  $j$  quando sua demanda é completamente coberta. As restrições (2.11) estabelecem uma demanda mínima para que uma cidade  $i$  possa sediar um equipamento. Por fim, as restrições (2.12), (2.13), (2.14) e (2.15) definem o domínio das variáveis de decisão.

Para ilustrar o PLAM, seja a Figura 2.1, que apresenta um cenário hipotético no qual há disponibilidade de três mamógrafos que, juntos, oferecem 3000 exames anuais. Neste cenário, há uma demanda anual de 3000 exames. O problema consiste em, respeitando a distância de 60 km entre o ponto de demanda e a localização do mamógrafo, distribuir os equipamentos, de forma que esta configuração atenda o maior número possível de mulheres. A Figura 2.1 ilustra o PLAM em um cenário

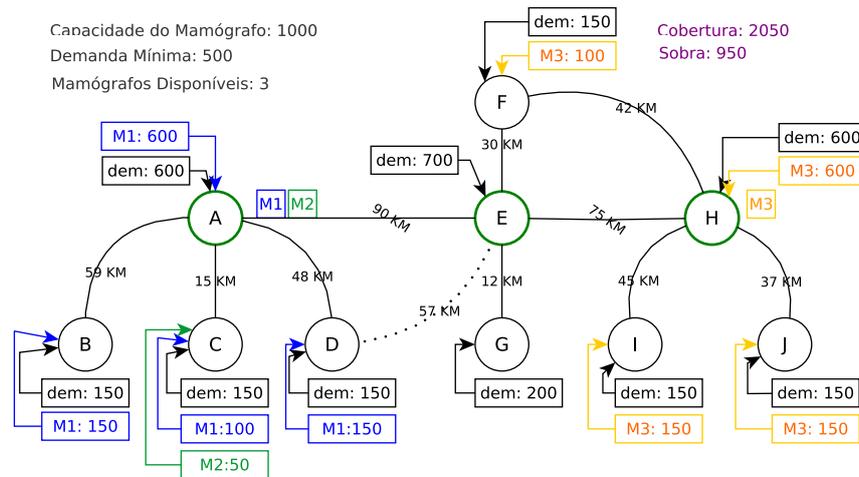


Figura 2.1: Exemplo de alocação.

hipotético formado por dez cidades (A, B, C, D, E, F, G, H, I e J) e três mamógrafos disponíveis para alocação.

Na Figura 2.1, cada cidade tem uma demanda cujo valor é indicado como *dem*. Aquelas cidades com demanda igual ou superior a 500 exames são candidatas a receber um mamógrafo. No cenário ilustrado, há disponibilidade de três mamógrafos, cada um deles tendo a capacidade para realizar 1000 exames anuais. Os mamógrafos M1 e M2 são instalados na cidade A, atendendo integralmente à demanda da cidade sede, restando um excedente de 1400 exames. O excedente do mamógrafo M1 atende integralmente à demanda das cidades B e D, e parcialmente à demanda da cidade C, cujo atendimento integral é alcançado por meio do mamógrafo M2. Já o mamógrafo M3 é instalado na cidade H, atendendo toda a demanda da cidade sede. O excedente de exames do mamógrafo M3 é usado para atender integralmente as demandas das cidades I e J e parte da demanda da cidade F. Neste exemplo, o excedente do mamógrafo M2 é suficiente para atender o deficit da cidade E; contudo, a distância entre as cidades A e E excede ao máximo permitido.

## 2.2 Problema de Roteamento de Unidades Móveis de Mamografia

A Seção 2.1 apresentou o PLAM, problema que consiste em localizar e alocar equipamentos fixos de mamografia de forma a maximizar a cobertura destes equipamentos. Os trabalhos disponíveis na literatura mostram que, mesmo com a otimização da localização de tais equipamentos, a taxa de cobertura não alcança a totalidade do público alvo deste exame. Esse *deficit* de cobertura se deve a fatores como a distância entre o ponto de demanda e a localização do equipamento ser superior à distância máxima estabelecida pelo Ministério da Saúde (60 km) ou ao fato do ponto de demanda não ter infraestrutura mínima para instalação de um novo equipamento.

Amaral et al. (2017) mostram que um dos principais fatores que desestimulam a realização do exame de mamografia é o deslocamento realizado pela paciente. Neste

contexto, para atender aquele público não contemplado por equipamentos fixos, são utilizadas as Unidades Móveis de Mamografia (MMUs). Elas percorrem as cidades que não são atendidas integralmente por equipamentos fixos, cobrindo esta demanda. Neste contexto, a presente pesquisa propõe, a partir da solução do PLAM, determinar o número de MMUs necessárias para cobrir, no prazo de um ano, a demanda não atendida pelo PLAM.

O Problema de Roteamento de Unidades Móveis de Mamografia (MMURP, da sigla em inglês *Mobile Mammography Unit Routing Problem*), introduzido por Rosa et al. (2020), consiste em, dada a demanda por exames de mamografia de um conjunto de cidades e um conjunto de possíveis cidades sedes, as quais são pontos de partida de MMUs, determinar suas rotas de forma a atender toda a demanda minimizando a distância total percorrida.

Embora uma MMU opere mais comumente com um equipamento de mamografia, há casos em que nelas são instalados dois equipamentos. Neste sentido, o problema pode ser tratado como sendo de frota heterogênea. Além disso, podem haver diferentes pontos de saída para as unidades, caracterizando-o assim como multi-depósito. Li et al. (2007) descrevem o Problema de Roteamento Aberto de Veículos (OVRP), uma variante do PRV na qual não há obrigatoriedade de o veículo prestador do serviço retornar à base sede da frota de veículos, mas mantém características do PRV, uma vez que busca-se estabelecer o número mínimo de veículos necessários para atender toda a rota, e, ao mesmo tempo, minimizar a distância total percorrida. No caso das MMUs, a distância de retorno à sede da MMU não precisa ser considerada.

Para a solução proposta nesta pesquisa, considera-se a lista de cidades com demanda remanescente do PLAM, e como possíveis sedes das MMUs, a lista de cidades com infraestrutura hospitalar definidas para o PLAM.

Na construção das rotas das MMUs, é adicionada, a partir da sede, a cidade com a menor distância em relação à última cidade inserida, respeitando-se o limite de 180 km. A imposição desse limite de distância permite que, ao iniciar o deslocamento entre duas cidades no começo da manhã, chegue-se ao destino três horas depois, no máximo, considerando uma velocidade de 60 km/h. Como há um tempo de preparação da MMU de uma hora, então ela estará preparada para iniciar sua operação no mesmo dia, quatro horas após o início da viagem. Caso o deslocamento se inicie no começo da tarde, com o deslocamento e o seu tempo de preparação, o equipamento móvel estará disponível para operação no início do dia seguinte. Não havendo mais cidades que se adêquem a esta restrição, a rota é fechada.

Além da distância máxima entre uma cidade e outra, outra restrição que deve ser observada é a que finaliza a rota. Para finalizar uma rota é necessário verificar a capacidade máxima de realização de exames anuais por uma MMU. Para isso, leva-se em consideração que com um mamógrafo é possível realizar 4 exames/hora. O tempo limite de uma rota é calculado dividindo-se a demanda das cidades atendidas por quatro, acrescido do tempo de viagem entre uma cidade e outra mais o tempo de preparo da MMU ao chegar a cada cidade.

Para ilustrar o MMURP, considere a Figura 2.2, que apresenta a situação existente no Estado de Rondônia após a aplicação do PLAM. As cidades na cor verde mais intensa foram atendidas integralmente pelos aparelhos fixos, já as demais não foram contempladas integralmente. O conjunto de cidades  $\{A,B,C,D,E,F,G\}$  são as cidades com demanda não atendida pelo PLAM e o conjunto  $\{1,2,3,4\}$  de cidades com

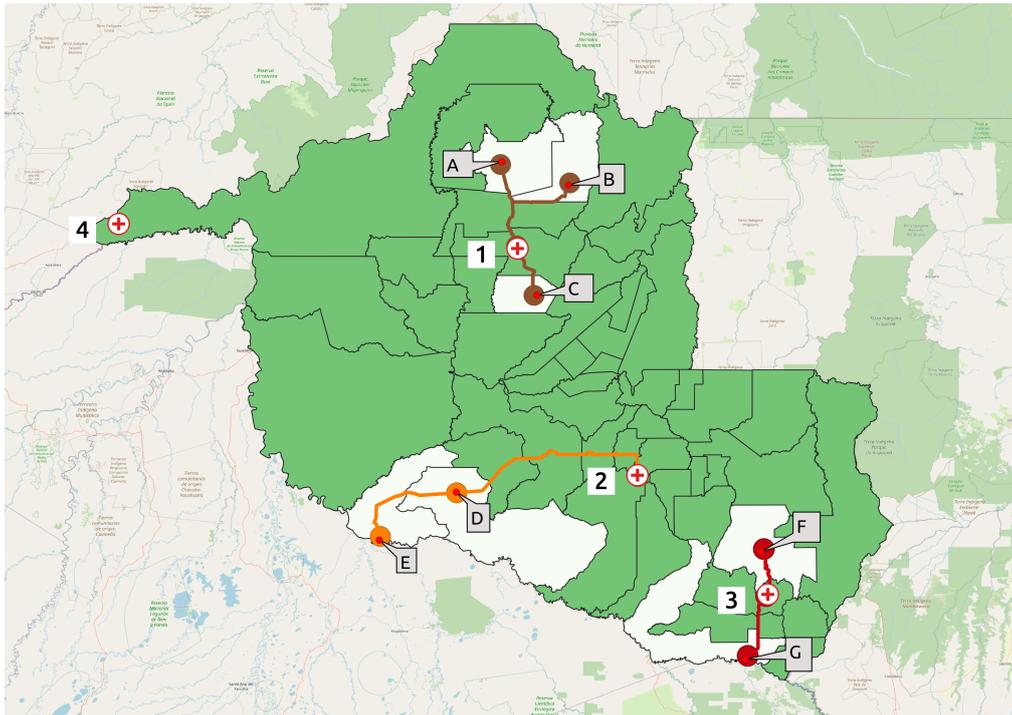


Figura 2.2: Exemplo de roteirização para o Estado de Rondônia, Brasil.

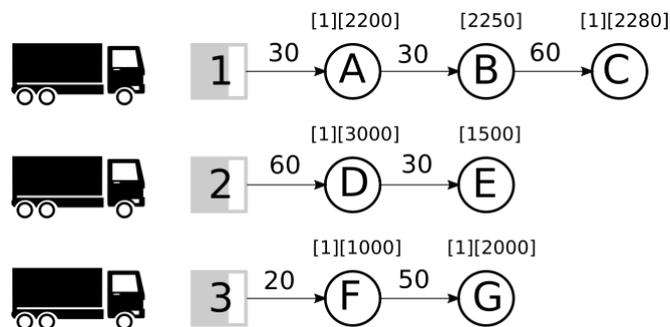


Figura 2.3: Detalhamento das rotas da Figura 2.2.

infraestrutura hospitalar. Neste caso, o problema consiste em definir um conjunto de **MMUs** capaz de atender as demandas das cidades A, B, C, D, E, F e G, partindo-se das cidades 1, 2, 3 e/ou 4, percorrendo a menor distância em cada rota aberta.

No cenário representado pela Figura 2.2, detalhada na Figura 2.3, são abertas 3 rotas para cobrir a demanda das cidades com demanda não atendida pelos mamógrafos fixos, identificadas pela cor branca. Há uma rota saindo da cidade 1 e percorrendo as cidades A, B e C; outra rota partindo da cidade 2 e percorrendo as cidades D e E; e, por fim, a terceira rota, iniciando na cidade 3 e passando pelas cidades F e G.

Para ilustrar o tempo de término de cada rota, considere na Figura 2.3 que cada **MMU** é capaz de realizar 6758 exames anualmente. Além disso, considere que o número acima da seta entre a base de uma **MMU** e uma cidade ou entre duas cidades represente o tempo de deslocamento. Também considere que o primeiro número entre colchetes acima de cada cidade represente o tempo de preparo e o segundo, o tempo

---

necessário para realizar todos os exames da cidade considerada. O valor 0 indica que não há tempo de preparo, situação que ocorre quando a [MMU](#) chega ao final do dia. Na rota 1, por exemplo, o tempo é calculado somando-se 2 horas (30+30+60) de viagem entre as cidades, 2 horas de preparo nas cidades A e C, mais 1682,5 horas necessárias para o atendimento da demanda das cidades A, B e C.

# Capítulo 3

## Revisão de Literatura

O presente Capítulo apresenta uma revisão de literatura, contextualizando os problemas objetos de estudo nesta dissertação. A Seção 3.1 apresenta um panorama dos principais trabalhos desenvolvidos relativos ao PLAM. A Seção 3.2 identifica trabalhos que apresentam correlação com o PLAM. A Seção 3.3, por sua vez, apresenta uma revisão de trabalhos relacionados ao roteamento de MMUs. Por fim, na Seção 3.4, é feita uma descrição das meta-heurísticas utilizadas neste trabalho para tratar os dois problemas.

### 3.1 Revisão de trabalhos sobre o PLAM

A localização e alocação de mamógrafos, sendo um problema de saúde pública e alvo de preocupação por parte das autoridades públicas e do meio científico, tem sido objeto de importantes estudos, como os apresentados a seguir.

Corrêa et al. (2018) analisaram a distribuição de mamógrafos em 12 regiões de saúde do Estado de Minas Gerais. Neste trabalho foram desenvolvidas quatro formulações de programação linear inteira, baseadas no problema das  $p$ -medianas. Na primeira formulação, é considerada uma distância máxima entre a unidade de atendimento e cada localidade de demanda. Na segunda formulação, a distância máxima pode ser violada, porém a violação é minimizada na função-objetivo. Já as terceira e quarta formulações são similares à primeira e segunda, respectivamente, contudo, em suas funções-objetivo, é incluído o número de mulheres que se deslocam para realizar o exame. Com base nos resultados obtidos, os autores concluíram que é possível cobrir a demanda da região com os equipamentos existentes, desde que seja possível a redistribuição dos mesmos.

Souza et al. (2019) analisaram o problema de localização de mamógrafos no estado de Rondônia. Nesta análise, são propostas duas formulações matemáticas baseadas no problema de máxima cobertura, nas quais é maximizado o número de mulheres atendidas, respeitando a distância máxima entre elas e o ponto de atendimento. Em uma das formulações, uma cidade só é atendida caso sua demanda seja coberta integralmente; na outra, é permitido o atendimento parcial da demanda da cidade. Os testes realizados apontaram que, aplicando ambas as formulações, se houvesse viabilidade de redistribuição dos mamógrafos, o número de mulheres atendidas seria maior do que aquele apresentado pela Secretaria de Estado de Saúde.

Sá et al. (2019) tratam o Problema de Localização de Mamógrafos no estado do Espírito Santo, aplicando a primeira formulação de Souza et al. (2019). Neste trabalho são utilizados dados de demanda e número de mamógrafos dos anos de 2015 e de 2019. São considerados dois cenários, um no qual há possibilidade de realocação dos equipamentos de mamografia e outro em que não há possibilidade de realocação, sendo que em ambos é analisada a aquisição gradativa de equipamentos até suprir a demanda do Estado. Os resultados obtidos no trabalho mostram que, caso exista a possibilidade de realocação de equipamentos, o número de mulheres atendidas aumentaria significativamente, se comparado ao cenário de atendimento existente.

Souza et al. (2020) tratam o Problema de Localização de Mamógrafos utilizando dois métodos de solução. O primeiro método aplica a primeira formulação de programação matemática de Souza et al. (2019). O segundo apresenta um algoritmo, baseado na meta-heurística *Variable Neighborhood Search (VNS)*, para tratar instâncias de maior dimensão do problema. A utilização de meta-heurísticas é justificada por se tratar de um problema NP-Difícil. Neste trabalho, os autores utilizam 8 instâncias do problema associadas ao estado de Minas Gerais, contendo dados referentes à população feminina no ano de 2010. Os autores consideram o atendimento integral da demanda de uma cidade, ou seja, uma cidade só recebe atendimento se tiver toda a sua demanda atendida. Os resultados obtidos, tanto com a aplicação da formulação de programação matemática, quanto com o algoritmo heurístico, apresentaram soluções melhores que aquela permitida pela distribuição existente dos mamógrafos.

Em uma extensão das duas formulações anteriores, Rosa et al. (2020) adiciona uma restrição na qual as mulheres só podem ser atendidas por mamógrafos instalados na região de saúde em que residem. Além disso, os autores modificaram o algoritmo baseado na meta-heurística *Variable Neighborhood Search (VNS)*, proposto por Souza et al. (2020), para permitir que os atendimentos estejam vinculados às microrregiões de saúde. Os autores analisaram dois cenários distintos para uma instância do Estado de Minas Gerais, com dados relativos ao ano de 2020. Um dos cenários considera a microrregião de saúde, enquanto o outro ignora a microrregião de saúde. No primeiro cenário obteve-se uma cobertura de 1.587.792 exames, enquanto que, no segundo cenário, a cobertura foi de 1.633.358 exames. Os autores constataram que essa diferença no número de exames é um indicativo de que a atual divisão das microrregiões de saúde do Estado de Minas Gerais pode não ser a ideal.

Os trabalhos de de Campos et al. (2020) e de Campos (2020) propõem uma formulação matemática para o PLAM e propõem um algoritmo heurístico baseado na meta-heurística *Simulated Annealing (SA)*, respectivamente. Nos dois trabalhos é considerado o atendimento parcial de uma cidade. Nestes trabalhos, os autores consideram dois cenários: um no qual um mamógrafo pode ser realocado de uma cidade para outra; e outro em que o mamógrafo não pode ser realocado. São tratados também os tipos de gestão do equipamento: gestão municipal e gestão estadual. Além destes fatores, são realizados experimentos nos quais são consideradas as microrregiões de saúde. Os resultados alcançados mostraram que o algoritmo proposto é capaz de obter soluções de boa qualidade em menor tempo de processamento, quando comparados com os das soluções geradas pelo resolvidor de programação matemática. Considerando a hipótese de aquisição de novos equipamentos, os resultados mostraram que, adquirindo 78 novos equipamentos, seria possível cobrir até 99,78%

demanda.

Paiva et al. (2023) tratam o PLAM no Sistema Público de Saúde do Estado de Rondônia. Três objetivos, agrupados em uma função mono-objetivo ponderada, foram considerados. O primeiro visa a maximização da cobertura de exames. O segundo busca minimizar o número de equipamentos a serem adquiridos, penalizando a aquisição de equipamentos que não atendam a uma taxa mínima de utilização que justifique economicamente, ou mesmo socialmente, a sua instalação. O terceiro objetivo, por sua vez, busca minimizar a distância entre os locais indicados a sediar mamógrafos e os que são atendidos por esses equipamentos. Os autores propuseram duas formulações de programação matemática que diferem entre si pelo tipo de atendimento prestado em uma localidade, podendo ser ele parcial ou integral. Foram analisados vários cenários e os resultados mostraram que, com os modelos propostos, as soluções obtidas possibilitam uma distribuição espacial dos equipamentos mais equilibrada e acessível. Além disso, eles sugerem que a distância máxima de atendimento pode ser aumentada para 90 km, uma vez que há um acréscimo expressivo na cobertura de exames e apenas 22% das localidades atendidas superam os 60 km.

A Tabela 3.1 apresenta um resumo dos trabalhos apresentados e que foram desenvolvidos com o objetivo de solucionar o PLAM.

## 3.2 Trabalhos Correlatos ao PLAM

Os trabalhos descritos a seguir abordam problemas correlatos ao PLAM.

Zhang et al. (2016) fazem uma abordagem multiobjetivo do problema de localização de instalações de saúde em cidades altamente povoadas, como *Hong Kong*. Em seu trabalho, os autores examinam o problema de onde instalar novas unidades de saúde considerando quatro objetivos conflitantes, sendo eles: maximizar a acessibilidade da população, minimizar a desigualdade de acessibilidade, minimizar o número de pessoas que estão fora de uma distância aceitável de viagem e minimizar o custo de construção de novas instalações. Para a solução do problema, os autores utilizaram o algoritmo genético. Os resultados mostram que a abordagem multiobjetivo utilizando algoritmos genéticos permite uma compensação entre objetivos conflitantes e pode ser usada em outras cidades com objetivos diferentes.

Ahmadi-Javid et al. (2017) apresentam uma revisão de literatura voltada para a classificação dos diferentes tipos de problemas de localização de unidades de saúde. Os autores agrupam problemas de localização de saúde em dois grandes conjuntos de facilidade de saúde: não-emergenciais e emergenciais. No primeiro grupo estão presentes as localizações de clínicas e hospitais, centros de transplantes de órgãos, dentre outros. Já o segundo conjunto compreende a localização de centros de emergência e traumatologia, posicionamento de ambulâncias, etc. O estudo sistematiza os trabalhos da literatura conforme dez dimensões descritivas, das quais destacam-se, como pontos de convergência com o presente trabalho, as seguintes: função objetivo, variáveis de decisão, abordagem de modelagem matemática, métodos de solução e inclusão de estudos de caso

Sathler et al. (2017) tratam o problema de localização e alocação de centros de especialidades médicas, no Estado de Minas Gerais, utilizando um modelo matemático de maximização de demanda atendida. O trabalho busca definir 51 municípios

Tabela 3.1: Trabalhos - Problema de Localização de Mamógrafos

Referência	Formulação Problema	Características Destacadas	Método de Solução	Principais Conclusões
(Corrêa et al., 2018)	Própria	$p$ -medianas -	Programação Inteira	Linear Os resultados mostram que é possível atender toda a demanda das regiões do estado de Minas Gerais analisadas com equipamentos existentes mediante a redistribuição.
(Souza et al., 2019)	Própria	Máxima Cobertura	Possibilidade de atendimento parcial	de Programação Inteira Linear Os resultados mostram que, havendo possibilidade de redistribuição dos aparelhos existentes no estado de Rondônia, a cobertura seria maior que aquela atendida pela Secretaria de Estado de Saúde.
(Sá et al., 2019)	(Souza et al., 2019)	Máxima Cobertura	Aquisição Gradativa de equipamentos	Programação Inteira Linear Os resultados mostram que, havendo possibilidade de redistribuir os equipamentos existentes no estado do Espírito Santo, o aumento da cobertura seria significativo se comparado à distribuição atual.
(Souza et al., 2020)	(Souza et al., 2019)	Máxima Cobertura	Utilização de algoritmo heurístico	Programação Inteira e <i>Variable Neighborhood Search</i> Linear Tanto a formulação matemática quanto o algoritmo heurístico apresentaram resultados com cobertura melhor que a distribuição existente dos equipamentos, para as instâncias testadas, relativas ao estado de Minas Gerais.
(Rosa et al., 2020)	(Souza et al., 2019)	Máxima Cobertura	Introduz a restrição de microrregião de saúde.	<i>Variable Neighborhood Search</i> adaptado de Souza et al. (2020) Linear Os resultados alcançados indicam que a divisão atual de microrregiões de saúde no Estado de Minas gerais pode não ser a ideal.
(de Campos et al., 2020)	(Souza et al., 2019)	Máxima Cobertura	Inclusão da restrição de impossibilidade de realocação de equipamentos. Atendimento parcial.	Programação Inteira e <i>Simulated Annealing</i> Linear Os resultados mostram que, não havendo possibilidade de redistribuição de equipamentos, é possível alcançar uma cobertura máxima de 99,97% adquirindo 78 novos equipamentos.
(Paiva et al., 2023)	(Souza et al., 2019)	Máxima Cobertura	Inclusão de funções objetivo que consideram o número mínimo de equipamentos a serem adquiridos e a distância de atendimento.	Programação Inteira e Programação Linear Mista Linear Apresenta-se uma proposta de localização para novos equipamentos a serem adquiridos considerando a permanência dos equipamentos atuais em seus respectivos locais de instalação.

candidatos a receberem unidades de atendimentos. O trabalho considera quatro limitadores de distância (400km, 300km, 200km e 100km), um em que qualquer município pode sediar unidades e outros dois cenários onde são estabelecidos critérios para que um município possa sediar uma unidade. Para solucionar o problema, os autores utilizam um modelo matemático de otimização linear inteira. Assim como na presente dissertação, o trabalho considera instâncias nas quais há restrições de infraestrutura mínima para instalação de unidades e define limitadores de deslocamento dos pacientes. Os autores concluíram que há uma escassez na literatura, com atuação na área

de saúde e no Brasil, de trabalhos que tratam a localização/alocação utilizando a pesquisa operacional. O modelo sugerido apontou que pode haver diminuição dos custos reduzindo o número de centros de especialidades médicas, sem haver diminuição de cobertura.

[Almeida et al. \(2019\)](#) propõem um modelo matemático para tratar o problema de localização de centros médicos, especialidades e equipamentos hospitalares. O trabalho, assim como aquele realizado pelos autores [Sathler et al. \(2017\)](#), faz um estudo de caso do estado de Minas Gerais, em que são levados em consideração fatores como deslocamento dos pacientes e a disponibilidade orçamentária. Os autores solucionam o problema utilizando um modelo de otimização linear inteira mista, cujo objetivo é minimizar os custos globais anuais, os quais envolvem custos de manutenção, aquisição de novos equipamentos para os centros existentes e aqueles a serem implantados. O trabalho considera cenários baseados no deslocamento de pacientes, dotação orçamentária e deslocamento de pacientes sem infraestrutura fixa. Os autores concluíram que, nos cenários que consideram o deslocamento, é possível atender um paciente com um deslocamento de no máximo uma hora e meia. Já no cenário no qual é considerada a disponibilidade orçamentária, observaram que é possível aumentar o nível de serviço, contudo, aumenta-se o tempo de deslocamento.

Já em [Almeida e Campos \(2021\)](#), os autores propõem um método de otimização em duas etapas para determinar a localização de centros médicos e a alocação de equipamentos para a atenção secundária à saúde. No primeiro modelo é tratada a localização ideal dos centros médicos conforme a demanda pelas especialidades médicas, já o segundo modelo estabeleceu a alocação dos equipamentos aos centros médicos. Assim como em [Almeida et al. \(2019\)](#), os autores tratam o problema utilizando otimização linear inteira mista, introduzindo um processo em duas etapas, no qual a primeira define a localização das instalações e a segunda determina alocação de equipamentos. No trabalho, a demanda é atribuída primeiramente aos equipamentos com capacidade ociosa e, para aquela demanda não coberta, é considerada a aquisição de uma quantidade mínima de equipamentos necessários para o atendimento. O trabalho revela que a estratégia de localização proposta cobre 834 municípios do Estado de Minas Gerais, com um deslocamento médio dos pacientes de 58,7km. O menor número hora/especialidade foi estipulado para o município de Frutal, para a especialidade de mastologia, enquanto a maior demanda hora/especialidade é do município de Belo Horizonte, para a pediatria. Quanto à distribuição de equipamentos de saúde, o estudo mostrou que a capacidade ociosa de equipamentos ressonância magnética poderia cobrir quase três quartos da demanda do estado e a aquisição de mais 20 aparelhos de ressonância magnética, 10 tomógrafos, 1 mamógrafo, 330 ultrassom e 5 ultrassom Doppler cobriria a demanda com um deslocamento máximo de 200km.

Os trabalhos citados nesta seção tratam problemas de máxima cobertura na área de saúde. Nestes trabalhos os autores mostram que a distribuição de equipamentos e instalações de saúde nem sempre contribuem para o acesso igualitário da população aos recursos de saúde pública. É possível observar que é característico destes trabalhos a tentativa de prover um acesso mais equânime da população aos recursos de saúde, diminuindo o deslocamento dos pacientes provendo qualidade de vida e saúde, além de otimizar os recursos públicos destinados à saúde da população.

### 3.3 Revisão de trabalhos correlatos ao MMURP

Os trabalhos apresentados até o momento mostram que, mesmo com a aplicação de algoritmos meta-heurísticos para otimizar a localização e alocação de mamógrafos fixos existentes, a cobertura de exames de mamografia não alcança a totalidade da demanda. Em [Souza et al. \(2019\)](#), por exemplo, observa-se que, mesmo realocando os equipamentos fixos, não é possível cobrir toda a demanda do Estado de Rondônia. Isto acontece pois muitas cidades não têm infraestrutura hospitalar para receber um mamógrafo fixo e estão localizadas a mais de 60 km de uma cidade contemplada com o equipamento, ou, por outro lado, o Estado não dispõe de equipamentos para cobrir sua demanda. [Sá et al. \(2019\)](#), por sua vez, sugerem a aquisição gradativa de equipamentos fixos para atender à demanda do Estado do Espírito Santo. O trabalho mostra que, mantendo-se aqueles já existentes, sem realocação, seriam necessários 18 novos equipamentos; contudo, a ocupação dos equipamentos seria em torno de 74,8%.

[Jewett et al. \(2018\)](#) mostram que, à medida que o deslocamento aumenta, diminui-se a taxa de procura pelo exame. Para [De Mil et al. 2019](#), o uso de MMUs torna o exame mais acessível para mulheres que residem em regiões remotas e onde a instalação de um equipamento fixo é onerosa. [Renck et al. \(2014\)](#) mostram que não há equidade de acesso ao exame de mamografia e que a utilização de MMUs é uma alternativa viável e melhora significativamente o acesso ao exame. O estudo foi realizado no Estado do Rio Grande do Sul.

Diante do exposto, a presente dissertação propõe a utilização de MMUs para cobrir a demanda remanescente da solução encontrada para o PLAM. Desta forma, é necessária a roteirização destas unidades, o que leva ao MMURP, uma variante do PRV, classificada como NP-difícil por [Lenstra e Kan \(1981\)](#).

[Benslimane e Benadada \(2013\)](#) apresentam um modelo matemático e um método de solução baseado no algoritmo de colônia de formigas para solucionar o problema de distribuição de um determinado produto a um conjunto de clientes utilizando uma frota heterogênea, cujo objetivo é reduzir o custo com o transporte e racionalizar a utilização dos veículos.

[López-Sánchez et al. \(2014\)](#) propuseram um algoritmo *Multi-Start* para solucionar um problema de roteamento de veículos aberto cujo objetivo é minimizar o *makespan*, o seja, a distância da rota mais longa ao invés do custo total. O algoritmo foi testado em uma instâncias do mundo real proposta por uma empresa de ônibus que opera na Espanha. Os resultados obtidos apresentaram economia comparado com as rotas utilizadas pela empresa no passado.

[Brandão \(2018\)](#) trata o problema de roteirização aberta de veículos com janela de tempo utilizando um algoritmo baseado na meta-heurística *Iterated Local Search*. A eficiência do algoritmo proposto no trabalho reside no *movimento cadeia de ejeção*, que é utilizado como procedimento de perturbação e, também, com objetivo de eliminar rotas e, assim, reduzir o número de veículos necessários.

Tabela 3.2: Trabalhos correlatos - MMURP

Referência	Problema	Método de Solução	Objetivo	Aplicação
<a href="#">Benslimane e Bena-dada (2013)</a>	Problema de Roteamento de Veículos com frota heterogênea	Colônia de Formigas	Reduzir os custos com transporte e racionalizar a utilização de veículos	Setor de logística, distribuição de produtos.
<a href="#">López-Sánchez et al. (2014)</a>	Problema de Roteamento de Veículos Aberto	<i>Multi-start</i>	Minimizar o <i>makespan</i>	Transporte público na Espanha
<a href="#">Brandão (2018)</a>	Problema de Roteamento de Veículos aberto com janela de tempo	<i>Iterated Local Search</i>	Redução de rotas / minimização do número de veículos	Setor de logística
<a href="#">Rosa et al. (2020)</a>	Problema de Roteamento de Veículos aberto	Algoritmo construtivo	Maximizar a demanda atendida e minimizar a distância total percorrida	Área da saúde. Roteamento de Unidades Móveis de Mamografia
<a href="#">Rosa et al. (2021)</a>	Problema de Roteamento de Veículos aberto	<i>Iterated Greedy Search</i>	Maximizar a demanda atendida e minimizar a distância total percorrida	Área da saúde. Roteamento de Unidades Móveis de Mamografia

[Rosa et al. \(2020\)](#) propõem um algoritmo heurístico construtivo para tratar o MMURP. Neste trabalho são roteirizadas MMUs para atender um grupo de 444 localidades, tendo como objetivo maximizar a demanda atendida e minimizar a distância total percorrida. Já os autores [Rosa et al. \(2021\)](#) sugerem um algoritmo IGS para tratar o problema, considerando dois depósitos, até 56 MMUs e 579 localidades a serem atendidas. Neste trabalho, os autores conseguem definir a quantidade de MMUs necessárias para atender a demanda e a roteirização das unidades. Embora estes últimos trabalhos tratem o MMURP, ambos não estão vinculados às soluções geradas pelo PLAM, principal diferencial desta dissertação.

A Tabela 3.2 resume a revisão de trabalhos correlatos ao MMURP.

### 3.4 Meta-heurísticas

Os problemas que envolvem localização de serviços de saúde geralmente são da classe de problemas de cobertura. [Ahmadi-Javid et al. \(2017\)](#) definem três subdivisões desta categoria de problemas, dentre elas o Problema de Localização de Máxima Cobertura (PLMC) é a que melhor se identifica com o objeto desta pesquisa.

Este problema é considerado NP-difícil ([Garey e Johnson, 1979](#)). A utilização de métodos exatos na solução de problemas desta categoria representa custos elevados em termos de tempo computacional e em relação ao armazenamento. Nos casos de problemas desta complexidade, encontrar uma boa solução já é satisfatório. Neste contexto, boa parte das pesquisas buscam resolver estes problemas por meio da utilização de heurísticas e meta-heurísticas, que, em termos computacionais, são mais baratas e alcançam soluções satisfatórias. Com estas características, as heurísticas conseguem alcançar boas soluções com tempo computacional reduzido; contudo, sem garantia de otimalidade, nem mesmo da distância ao valor ótimo.

As heurísticas se dividem em construtivas e de refinamento. As heurísticas construtivas consistem em construir uma solução elemento a elemento, respeitando uma função avaliação característica de cada problema a ser tratado. As heurísticas de

**Algoritmo 1: IGS-Basico()**


---

```

1  $s_0 \leftarrow SolucaoInicial()$ 
2  $s \leftarrow BuscaLocal(s_0)$ 
3 enquanto (Critério de parada não satisfeito) faça
4    $nivel \leftarrow 1$ 
5   enquanto ( $nivel \leq nivel_{max}$ ) faça
6      $s' \leftarrow destroi(s, nivel)$ 
7      $s'' \leftarrow reconstroi(s', nivel)$ 
8      $s''' \leftarrow BuscaLocal(s'', k_{max})$ 
9     se  $f(s) < f(s''')$  então
10       $s \leftarrow s'''$ 
11       $nivel \leftarrow 1$ 
12     senão
13       $nivel \leftarrow nivel + 1$ 
14     fim
15   fim
16 fim

```

---

refinamento buscam melhorar uma solução corrente, explorando o espaço de solução por meio de estruturas de vizinhança.

Entretanto, as heurísticas são específicas em relação aos problemas tratados, estando limitadas às suas características. Sendo assim, surge a necessidade de métodos mais genéricos, que possam ser aplicados a qualquer classe de problema. Neste contexto, surge o conceito de meta-heurísticas, que se constituem em métodos mais flexíveis, capazes de realizar a busca de forma inteligente. Estes métodos definem mecanismos para que a busca por soluções melhores não fiquem presas a ótimos locais.

Dentre as mais variadas meta-heurísticas presentes na literatura, este trabalho destaca três delas: IGS (Ruiz e Stützle, 2008), *Greedy Randomized Adaptive Search Procedures (GRASP)* (Feo e Resende, 1995) e GVNS (Hansen et al., 2017).

A meta-heurística IGS, descrita em Ruiz e Stützle (2008), consiste no seguinte processo: uma solução inicial é construída, em seguida, enquanto um critério de parada não é atingido, uma solução parcial é obtida, removendo-se aleatoriamente um elemento da solução, a solução é reconstruída, inserindo, de forma gulosa, os elementos removidos anteriormente. Antes da próxima iteração, um critério de aceitação é aplicado na solução para decidir se esta será ou não a nova solução corrente. Esta meta-heurística está descrita no Algoritmo 1.

A meta-heurística GRASP, proposta por Feo e Resende (1995), é um método de busca local iterativa, composta por duas etapas. Na primeira delas, fase de construção, uma solução inicial é construída iterativamente. A cada iteração do processo de construção da solução, uma lista de candidatos a entrar na solução é criada e ordenada conforme o benefício preestabelecido de cada elemento. Derivado desta lista, forma-se um subconjunto dos melhores elementos a entrar na solução; do qual, a cada iteração, um elemento é selecionado aleatoriamente e incorporado à solução. Em seguida, o subconjunto é atualizado, e o processo de construção continua en-

quanto houver candidatos. Este método de seleção permite a construção de soluções diversificadas. A segunda etapa consiste no refinamento da solução em busca de um ótimo local. Este processo é repetido até que uma condição de parada seja atingida. O Algoritmo 2 apresenta o pseudocódigo da meta-heurística [GRASP](#).

---

**Algoritmo 2:** GRASP-Basico()
 

---

```

1 enquanto (Critério de parada não for satisfeito) faça
2   | Construa uma solução  $s$  com procedimento guloso aleatório
3   |  $s' \leftarrow BuscaLocal(s, k_{max})$ 
4   |  $s^* \leftarrow MelhorSolucao(s, s')$ 
5 fim

```

---



---

**Algoritmo 3:** GVNS-Basico()
 

---

```

1  $s \leftarrow ConstroiSolucaoInicial()$ 
2 enquanto (Critério de parada não for satisfeito) faça
3   |  $k \leftarrow 1$ 
4   | enquanto ( $k < k_{max}$ ) faça
5     |  $s' \leftarrow Shaking(s, k)$ 
6     |  $s' \leftarrow BuscaLocal(s')$ 
7     | se  $f(s) < f(s')$  então
8       |    $s \leftarrow s'$ 
9       |    $k \leftarrow 1$ 
10    |   senão
11    |      $k \leftarrow k + 1$ 
12    |   fim
13  | fim
14 fim
15 retorna  $s$ 

```

---

A meta-heurística [GVNS](#) ([Hansen et al., 2017](#)) é uma variante da meta-heurística [VNS](#) ([Mladenović e Hansen, 1997](#)). O [VNS](#) explora o espaço de soluções utilizando-se de trocas sistemáticas de estruturas de vizinhança, explorando vizinhanças gradativamente mais distantes. Sua estrutura é composta de quatro componentes, são eles: construção da solução inicial; procedimento de *shaking*, responsável por gerar uma perturbação na  $k$ -ésima vizinhança da solução corrente; busca local que, nesta variante, aplica o *Variable Neighborhood Descent* ([VND](#)); e um procedimento de troca de vizinhança responsável por definir qual será a próxima vizinhança explorada.

# Capítulo 4

## Métodos de solução propostos

Este capítulo apresenta os métodos de solução desenvolvidos para tratar o **PLAM**, os quais estão descritos nas seções 4.1 e 4.2, bem como o método construtivo para tratar o **MMURP**, descrito na Seção 4.3.

Na Subseção 4.1 mostra-se como uma solução para o **PLAM** é representada e na Subseção 4.1.2 como ela é avaliada. Na Subseção 4.1.3 mostra-se como uma solução inicial é construída e, na Subseção 4.1.4, mostra-se as duas estruturas de vizinhança usadas para explorar o espaço de soluções do **PLAM**. Na Subseção 4.1.5 mostra-se o pseudocódigo do IGS-**PLAM** proposto. A Seção 4.2, por sua vez, apresenta o algoritmo **GVNS** desenvolvido para tratar o **PLAM**, incluindo uma nova representação da solução, as funções de avaliação, um novo método de construção de uma solução inicial, o método de busca local, as estruturas de vizinhança e o pseudocódigo do **GVNS-PLAM** proposto.

Por fim, a Seção 4.3 descreve os detalhes do algoritmo construtivo para gerar uma solução para o **MMURP**.

### 4.1 IGS para o PLAM

Esta seção descreve um algoritmo baseado na meta-heurística **IGS** para tratar o **PLAM**. Ele utiliza duas estruturas de vizinhança e a representação da solução adotadas por [de Campos \(2020\)](#).

#### 4.1.1 Representação da Solução

Uma solução do **PLAM** é representada por um par  $s = (x, y)$ , no qual  $x$  é uma matriz de tamanho  $n \times n$  e  $y$  é um vetor de tamanho  $n$ . O vetor  $y$  armazena o número de mamógrafos alocados em cada cidade  $i$  e a matriz  $x$  armazena a fração da demanda de exames da cidade  $j$  cobertos pela cidade  $i$ .

A Figura 4.1 ilustra uma instância da solução descrita na Figura 2.1. A Figura 4.1(a) representa a matriz  $x$ , a qual é preenchida por valores compreendidos entre 0 e 1. Estes valores indicam a fração da demanda da cidade  $j$  atendida pela cidade  $i$ . Observe que na quinta coluna (referente à cidade E) e linha 0 (referente à cidade A) é atribuído o valor 0, indicando que a cidade A não atende nenhuma demanda da cidade E. A Figura 4.1(b), por sua vez, representa o vetor  $y$ . Este vetor é preenchido por valores correspondentes ao número de mamógrafos alocados na cidade  $i$ . Note

	A	B	C	D	E
A	1	1	1	0,69	0
B	0	0	0	0	0
C	0	0	0	0	0
D	0	0	0	0	0
E	0	0	0	0	0

A	B	C	D	E
1	0	0	0	0

(a) Representação da Matriz  $x$ .(b) Representação do Vetor  $y$ .

Figura 4.1: Representação da solução.

que o índice 0, correspondente à cidade A, possui valor 1, indicando que a cidade A possui um mamógrafo.

### 4.1.2 Função de Avaliação

Uma solução é avaliada com base na função objetivo expressa pela Equação (4.1). Nesta expressão é avaliada a cobertura de exames, dada pelo somatório da demanda atendida na solução.

$$\max \sum_{i \in N} \sum_{j \in S_i} dem_j \cdot x_{ij} \quad (4.1)$$

Nesta Equação,  $N$  é o conjunto de cidades candidatas a sediarem um equipamento de mamografia,  $S_i$  é o conjunto das cidades  $j$  cuja distância em relação à cidade candidata  $i$  é menor ou igual a 60 km,  $dem_j$  é a demanda de exames da cidade  $j$  e  $x_{ij}$  é a fração de atendimento da cidade  $j$  pela cidade  $i$ .

### 4.1.3 Construção da Solução Inicial

A solução inicial é determinada conforme descrito pelo Algoritmo 4.

Na linha 2 do Algoritmo 4 é escolhida uma cidade para atendimento, tendo como critério a maior demanda regional. A demanda regional é definida aqui como a soma das demandas das cidades pertencentes à região da cidade escolhida. Uma região é o conjunto das cidades com distância máxima de 60 km em relação a uma dada cidade. As linhas 3 e 5 certificam se ainda há cidades com infraestrutura hospitalar para sediar um mamógrafo. Quando não houver mais cidades a serem escolhidas, a função *escolheCidade()* retorna o valor -1. Satisfeitos os critérios para alocar um mamógrafo, nas linhas 6 a 8, caso a cidade  $i$  esteja sendo atendida por alguma cidade, ou seja, a sua demanda residual (demanda ainda não atendida) é menor que a sua demanda total, este vínculo é desfeito, gerando uma lista de cidades que atendiam a cidade  $i$ . Em seguida, nas linhas 9 a 12, é definida, com base na demanda regional, a quantidade de mamógrafos a serem alocados à cidade  $i$  suficiente para atender essa

**Algoritmo 4:** *solucaoInicial(dados)*


---

```

1 enquanto ( $p > 0$ ) faça
2    $i \leftarrow escolheCidade()$ 
3   se  $i < 0$  então
4     break
5   fim
6   se  $demandaResidual(i) < demanda(i)$  então
7      $desatende(i)$ 
8   fim
9    $quantidade = defineQuantidadeMamografos()$ 
10   $p \leftarrow p - quantidade$ 
11   $atualizaQuantidadeMamografos(i, quantidade)$ 
12   $atualizaDemandaResidual(i)$ 
13  se  $demandaResidual(i) == 0$  então
14     $removeCandidata(i)$ 
15     $atendeRegiao(i)$ 
16  senão
17     $atualizaAtendimento(i)$ 
18  fim
19 fim

```

---

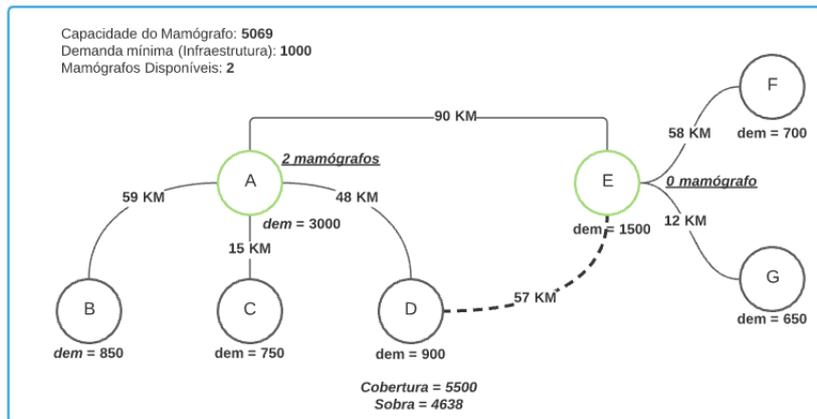
demanda, e por consequência, atualiza-se a quantidade de mamógrafos disponíveis, a quantidade de mamógrafos alocada na cidade  $i$  e sua demanda residual. Caso sua demanda tenha sido completamente coberta, a cidade  $i$  é removida da lista de cidades candidatas na linha 14 e a demanda da região de  $i$  é atendida, caso contrário, na linha 17 o atendimento de  $i$  é atualizado, adicionando na matriz  $x_{ii}$  a fração correspondente ao atendimento da cidade  $i$ .

#### 4.1.4 Estruturas de Vizinhança

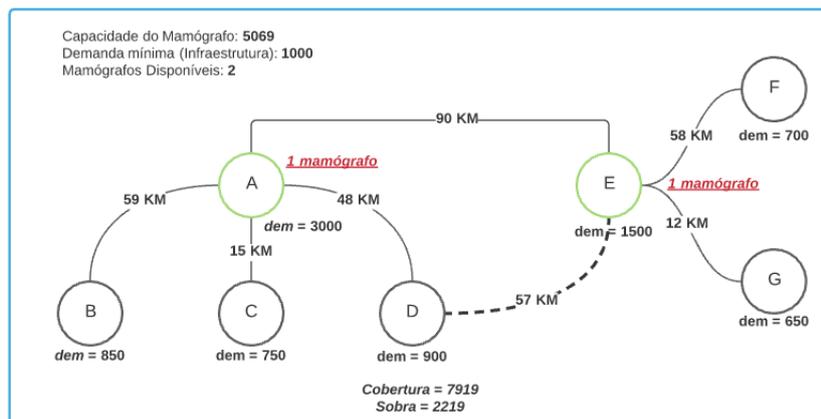
O espaço de soluções do PLAM é explorado por meio de duas estruturas de vizinhança: Realoca Mamógrafo e Realoca Exames Atendidos. A primeira estrutura de vizinhança é obtida a partir do movimento realocar mamógrafo, que retira um mamógrafo de uma cidade e o coloca em outra cidade. A segunda estrutura de vizinhança consiste em realocar exames atendidos por uma cidade para outra cidade que tenha capacidade de atendimento disponível. As Figuras 4.2 e 4.3 ilustram estes dois movimentos.

A Figura 4.2(a) representa um cenário hipotético composto por 7 cidades, identificadas pelas letras A, B, C, D, E, F e G, e pela demanda ( $dem$ ) por exames de mamografia de cada cidade. Esta figura ilustra uma solução antes da aplicação das estruturas de vizinhança. Observe que as cidades A e E possuem infraestrutura para sediarem um mamógrafo (aqui consideradas as cidades que têm demanda mínima de pelo menos 1000 exames). Neste exemplo, 2 aparelhos de mamografia estão disponíveis para atender a demanda e estes estão alocados na cidade A. As cidades atendidas pelos mamógrafos alocados em A são A, B e C, e a cobertura alcançada,

nesta solução, é de 5500 exames.



(a) Representação da solução antes da aplicação da estrutura de vizinhança Realoca Mamógrafo.



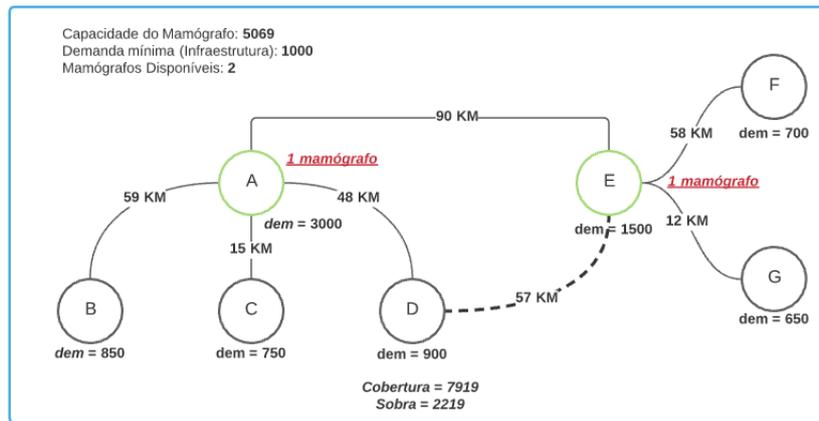
(b) Representação da solução após a aplicação da estrutura de vizinhança Realoca Mamógrafo.

Figura 4.2: Um exemplo da estrutura de vizinhança Realoca Mamógrafo.

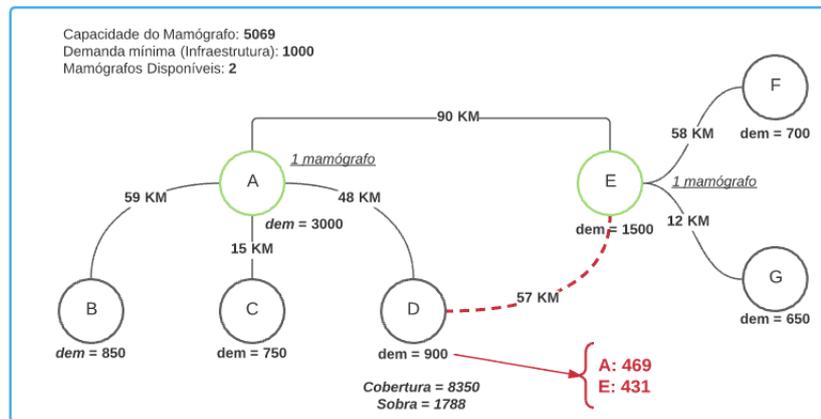
Aplicando a primeira estrutura de vizinhança no cenário apresentado, um mamógrafo é realocado da cidade A para a cidade E, gerando a solução vizinha apresentada na Figura 4.2(b). Com o mamógrafo alocado em E é possível atender as cidades E, F e G integralmente. Sendo assim, a cobertura gerada é de 7919 exames, o que amplia a cobertura em 2419 exames após a aplicação do movimento.

A segunda estrutura de vizinhança consiste em realocar exames atendidos de uma cidade para outra. Para tal, é necessário que a cidade atendida tenha uma segunda opção de atendimento (parcial ou integral), ou seja, ela deve estar a no máximo 60 km de pelo menos duas cidades com ofertas de exames.

A Figura 4.3(b) ilustra a solução após a aplicação do movimento Realocar Exames Atendidos na solução da Figura 4.3(a). Observe que parte da demanda da cidade D (431 exames) passa a ser atendida pela cidade E. Sendo assim, a cidade D, que na solução da Figura 4.2 era atendida parcialmente pela cidade A (469 exames), passa a ser integralmente atendida pelas cidades A e E, ampliando a cobertura da solução de 7919 para 8350 exames.



(a) Representação da solução antes da aplicação da estrutura de vizinhança Realoca Exames Atendidos.



(b) Representação da solução após a aplicação da estrutura de vizinhança Realoca Exames Atendidos.

Figura 4.3: Um exemplo da estrutura de vizinhança Realoca Atendimento Intra Mamógrafo.

#### 4.1.5 Algoritmo IGS Proposto

Para tratar o problema foi desenvolvido um algoritmo baseado na meta-heurística IGS. Seu pseudocódigo é apresentado no Algoritmo 5.

Inicialmente, na linha 1 do Algoritmo 5, é gerada a solução inicial conforme descrito na Seção 4.1.3. Na linha 2, a solução é refinada utilizando o Método de Descida em Vizinhança Variável VND com a estratégia *First Improvement*, descrito pelo pseudocódigo do Algoritmo 6.

O método VND explora o espaço de soluções pela troca sistemática de vizinhanças. As vizinhanças utilizadas são as apresentadas na Seção 4.1.4, na ordem em que elas são apresentadas, isto é, Realoca Mamógrafo e Realoca Exames Atendidos. Assim,  $k_{\max} = 2$ . Para cada vizinhança selecionada pelo VND, uma busca local é executada na solução atual; se a solução encontrada é melhor do que a atual, a primeira função de vizinhança é novamente usada, caso contrário, a próxima vizinhança é usada, até que não haja mais vizinhanças disponíveis.

**Algoritmo 5:** IGS( $dados, parada, nivel_{max}, k_{max}$ )

---

```

1  $s_0 \leftarrow GeraSolucaoInicial()$ 
2  $s \leftarrow VND(k_{max}, s_0)$ 
3 enquanto (Critério de parada não satisfeito) faça
4    $nivel \leftarrow 1$ 
5   enquanto ( $nivel \leq nivel_{max}$ ) faça
6      $s' \leftarrow destroi(s, nivel)$ 
7      $s'' \leftarrow reconstroi(s', nivel)$ 
8      $s''' \leftarrow VND(k_{max}, s'')$ 
9     se  $f(s) < f(s''')$  então
10      |  $s \leftarrow s'''$ 
11      |  $nivel \leftarrow 1$ 
12     senão
13      |  $nivel \leftarrow nivel + 1$ 
14     fim
15   fim
16 fim

```

---

**Algoritmo 6:** VND( $k_{max}, s$ )

---

```

1  $k \leftarrow 1$ 
2 enquanto ( $k < k_{max}$ ) faça
3   Encontre o melhor vizinho  $s' \in \mathbb{N}^{(k)}(s)$ 
4   se  $f(s) < f(s')$  então
5     |  $s \leftarrow s'$ 
6     |  $k \leftarrow 1$ 
7   senão
8     |  $k \leftarrow k + 1$ 
9   fim
10 fim
11 retorna  $s$ 

```

---

As linhas de 3 a 16 correspondem aos processos de destruir, reconstruir e avaliar a solução até que um critério de parada seja atendido. A destruição consiste em retirar aleatoriamente  $nivel$  mamógrafos de  $nivel$  cidades escolhidas aleatoriamente. Já na reconstrução, os  $nivel$  equipamentos removidos são distribuídos de forma gulosa, considerando o critério de maior demanda regional, na nova solução. Em seguida, a solução gerada é refinada. Logo após o refinamento, a solução obtida é avaliada, sendo que, se a solução gerada for melhor do que a solução atual  $s$ , esta solução é atualizada. A execução do algoritmo é encerrada com base no tempo demandado pelo algoritmo SA proposto por de Campos (2020).

## 4.2 GVNS para o PLAM

Esta seção descreve o algoritmo baseado na meta-heurística **GVNS** para tratar o PLAM. Uma nova forma de representação computacional da solução é apresentada e são utilizadas quatro estruturas de vizinhança.

### 4.2.1 Representação da solução

Ao contrário de [de Campos et al. \(2020\)](#), que agrupa todos os mamógrafos sediados em uma mesma cidade, na presente proposta é utilizada uma nova forma de representação da solução para o PLAM com atendimento parcial. Nesta representação, uma solução é composta por um par  $s = (x, y)$ , sendo  $x$  uma matriz de dimensão  $p \times n$ ,  $y$  um vetor de dimensão  $p$ ,  $p$  o número de mamógrafos disponíveis e  $n$  o número de cidades a serem atendidas. O vetor  $y_k$  registra a cidade  $j$  em que cada mamógrafo  $k$  está alocado e a matriz  $x_{jk}$  armazena a quantidade de exames da cidade  $j$  atendidos pelo mamógrafo  $k$ . Com esta representação é possível individualizar os atendimentos realizados por cada mamógrafo sediado em uma cidade.

	A	B	C	D	E	F	G	H	I	J
M1	600	150	100	150	0	0	0	0	0	0
M2	0	0	50	0	0	0	0	0	0	0
M3	0	0	0	0	0	100	0	600	150	150

M1	M2	M3
A	A	H

(a) Representação da matriz  $x$ .

(b) Representação do vetor  $y$ .

Figura 4.4: Representação da solução.

A Figura 4.4 ilustra uma instância da solução apresentada na Figura 2.1. A Figura 4.4(a), por sua vez, mostra a matriz  $x$ , na qual cada coluna é preenchida com a quantidade de exames atendidos pelo mamógrafo em cada cidade. Neste exemplo, a cidade C é atendida parcialmente em 100 exames pelo mamógrafo M1 e em 50 exames pelo mamógrafo M2. A cidade F tem parte de sua demanda atendida pelo mamógrafo M3. A cidade E não tem nenhuma demanda atendida pois sua distância em relação às cidades A e H, sedes dos mamógrafos M1, M2 e M3, excede a distância máxima de 60km. Finalmente, a Figura 4.4(b) mostra o vetor  $y$ . Este vetor é preenchido com os identificadores das cidades onde cada mamógrafo está alocado.

### 4.2.2 Funções de Avaliação

São definidas duas funções de avaliação da solução, que são tratadas hierarquicamente: a primeira com base na função objetivo propriamente dita do problema, expressa pela Equação (4.2); e a segunda, a partir de uma função de avaliação expressa pela Equação (4.3). Na primeira equação é avaliada a cobertura de exames, dada pelo somatório da demanda atendida na solução. A segunda equação, por sua vez, é aplicada apenas se houver empate entre duas soluções. Ela considera um peso  $peso_j$ , atribuído a cada cidade. O  $peso_j$  é definido de acordo com uma classificação

das cidades com base na prioridade de atendimento. As cidades são classificadas conforme o número de cidades que podem atendê-la, tendo melhor classificação as cidades atendidas que possuem um número menor de cidades que podem atendê-la. Ambas as funções são atualizadas a cada vez que um exame é designado a uma cidade ou um atendimento é desfeito.

$$\max \sum_{k \in P} \sum_{j \in N} x_{kj} \quad (4.2)$$

$$\max \sum_{k \in P} \sum_{j \in N} peso_j \cdot x_{kj} \quad (4.3)$$

Nas Equações (4.2) e (4.3),  $P$  é o conjunto de mamógrafos a serem alocados,  $N$  é o conjunto de cidades que demandam atendimento,  $peso$  é a classificação de prioridade de atendimento atribuída a cada cidade, conforme o número de cidades que podem atendê-la.

### 4.2.3 Construção da Solução Inicial

A construção da solução inicial é baseada na fase de construção da meta-heurística **GRASP**. Na fase de construção do **GRASP** é utilizada uma estratégia gulosa aleatória, na qual são escolhidos os  $\alpha$  melhores elementos de uma Lista de Candidatos (**LC**), formando uma Lista Restrita de Candidatos (**LRC**).

---

**Algoritmo 7:** *constroiSolucaoInicial*( $s, \alpha$ )

---

```

1  $LC \leftarrow cidadesComInfraestrutura$ 
2  $LRC \leftarrow gereListaRestritaDeCandidatos(LC, \alpha)$ 
3 enquanto (houverMamografo) faça
4    $i \leftarrow seleccioneUmaCidadeAleatoria(LRC)$ 
5   aloqueMamografo( $s, i$ )
6   atualizeLRC( $LC$ )
7 fim
8 enquanto (houverMamografo) faça
9    $LC \leftarrow cidadesRegiaoSedeMamografo$ 
10   $RCL \leftarrow gereListaRestritaDeCandidatos(LC, \alpha)$ 
11  enquanto houverExameDisponivel faça
12     $i \leftarrow seleccioneUmaCidadeAleatoria(LRC)$ 
13    atendaDemanda( $s, i$ )
14    atualizeLRC( $LC$ )
15  fim
16 fim

```

---

A construção da solução é realizada em duas etapas: (i) distribuição dos mamógrafos entre as cidades com infraestrutura hospitalar; e (ii) atendimento das demandas de exames das cidades a partir dos mamógrafos alocados. A solução inicial é construída conforme descrito no Algoritmo 7. Na primeira etapa do processo de construção, a lista de candidatos **LC** é carregada com todas as cidades que possuem infraestrutura

para receber mamógrafos. Em seguida, na linha 2, os  $\alpha$  candidatos da LC com maior demanda regional são colocados na LRC. Na sequência, enquanto houver mamógrafos a serem alocados, uma cidade  $i$  é selecionada aleatoriamente da LRC, o mamógrafo é alocado nesta cidade e a LRC é atualizada (linhas 3 a 7). Após alocar todos os mamógrafos, os exames destes mamógrafos são distribuídos na segunda etapa da construção. Para tal, para cada mamógrafo, uma nova LC, de cidades candidatas localizadas na região da cidade sede, é gerada e os exames são distribuídos seguindo o mesmo princípio da primeira etapa. A LRC é definida a partir dos  $\alpha$  melhores candidatos dessa LC. Da mesma forma, nas linhas de 11 a 15, enquanto houver exames a serem distribuídos, uma cidade é selecionada da LRC, a demanda é atendida e a LRC é atualizada.

#### 4.2.4 Busca Local Utilizada

A busca local é feita por meio do método VND (Hansen et al., 2017). Seu pseudocódigo é descrito pelo Algoritmo VND-PLAM.

---

**Algoritmo 8:** VND\_PLAM( $k_{\max}, iter_{\max}, s$ )

---

```

1  $k \leftarrow 1$ 
2 enquanto ( $k < k_{\max}$ ) faça
3   | Encontre o melhor vizinho  $s' \in \mathcal{N}^{(k)}(s)$ 
4   | se  $f(s) < f(s')$  então
5   |   |  $s \leftarrow s'$ 
6   |   |  $k \leftarrow 1$ 
7   | senão
8   |   |  $k \leftarrow k + 1$ 
9   | fim
10 fim
11 retorna  $s$ 

```

---

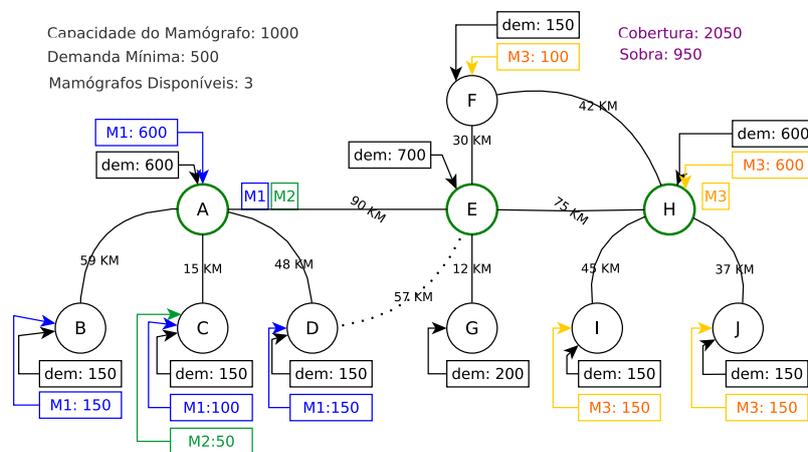
O Algoritmo VND-PLAM inicia sua busca com uma solução inicial recebida como parâmetro de entrada. Em seguida, são aplicadas heurísticas de refinamento com estruturas de vizinhanças variadas, descritas na Seção 4.2.5, enquanto  $k_{\max}$  não for alcançado (linhas 2 a 10). Na linha 3,  $k$  é a estrutura de vizinhança corrente aplicada para encontrar o melhor vizinho. Nas linhas 4 a 9, o vizinho encontrado é avaliado. Se houver melhora, a solução corrente é atualizada e  $k$  retorna ao seu valor inicial; caso contrário, a solução corrente é mantida e o valor de  $k$  é incrementado. Este procedimento é aplicado enquanto houver melhora na solução.

#### 4.2.5 Estruturas de Vizinhança

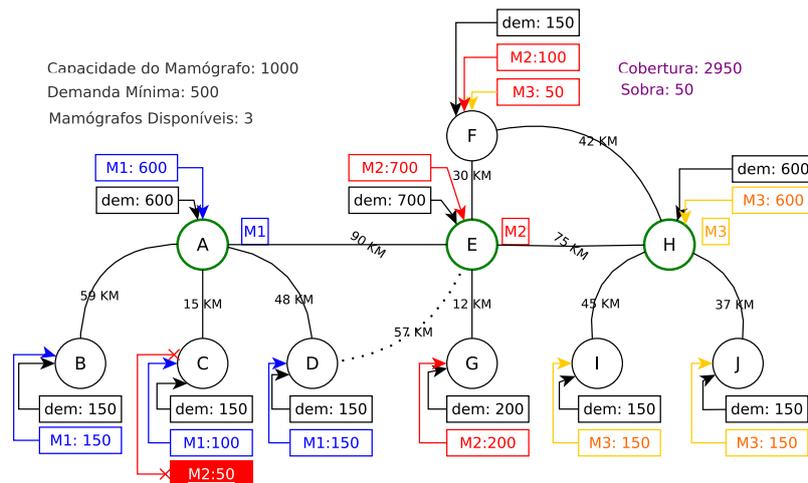
O espaço de soluções do PLAM com atendimento parcial é explorado por meio de quatro estruturas de vizinhança. São elas: Realoca Mamógrafo, Realoca Atendimento Inter Mamógrafo, Realoca Atendimento Intra Mamógrafo e Busca Atendimento.

A estrutura de vizinhança Realoca Mamógrafo é obtida pela aplicação do movimento de realocação de um mamógrafo, que consiste em retirar um mamógrafo de uma cidade e alocá-lo a outra.

A Figura 4.5(a) ilustra um cenário hipotético composto por um conjunto de 10 cidades com demanda de exames. Dentre as 10 cidades, três delas, A, E e H, possuem infraestrutura para receber um equipamento de mamografia. No cenário apresentado há disponibilidade de três aparelhos, sendo que, inicialmente, dois deles são alocados na cidade A, atendendo integralmente a cidade sede e as cidades B, C e D, e o terceiro é instalado na cidade H, atendendo as cidades I e J integralmente e parte da demanda da cidade F. Com esta disposição são realizados 2050 exames. Aplicando-se o movimento Realoca Mamógrafo na solução da Figura 4.5(a), um mamógrafo é realocado da cidade A para a cidade E. Após o movimento, a cidade E é atendida integralmente e o excedente de exames do mamógrafo nela instalado cobre toda a demanda da cidade G e parte da demanda da cidade F, com base na maior demanda não coberta.



(a) Solução anterior à aplicação da estrutura de vizinhança Realoca Mamógrafo.



(b) Solução posterior à aplicação da estrutura de vizinhança Realoca Mamógrafo.

Figura 4.5: Exemplo das estruturas de vizinhança Realoca Mamógrafo e Realoca Atendimento Intra Mamógrafo.

A segunda estrutura de vizinhança é gerada por meio do movimento Realoca Atendimento Intra Mamógrafo. Neste movimento, atendimentos são removidos de uma cidade e disponibilizados para outra cidade pelo mesmo mamógrafo. O número de atendimentos realocados é um parâmetro, que foi definido usando a ferramenta *irace*, como apresentado na Seção 5.2.3. Como pode ser observado na Figura 4.6, ao aplicar o movimento Realoca Atendimento Intra Mamógrafo sobre o cenário apresentado na Figura 4.5(b), 50 atendimentos são realocados da cidade D para a cidade C. Neste movimento, a realocação de atendimentos ocorre somente entre cidades atendidas pelo mesmo mamógrafo. No caso da estrutura de vizinhança Realoca Atendimento Intra Mamógrafo, a cobertura não é alterada durante a aplicação do movimento. Sendo assim, a melhora ou não da solução é avaliada pela função de avaliação da Equação (4.3). A cidade atendida que possuir o menor número de opções de atendimento é beneficiada na função de avaliação. Desta forma, o algoritmo consegue explorar regiões do espaço de busca que poderiam não ser percorridas, se utilizada apenas a função objetivo propriamente dita.

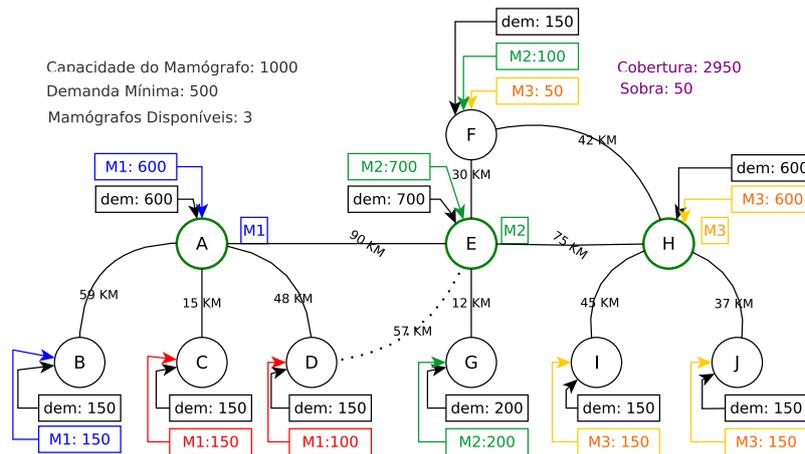


Figura 4.6: Exemplo da estrutura de vizinhança Realoca Atendimento Intra Mamógrafo

A terceira estrutura, por sua vez, é obtida com o movimento Realoca Atendimento Inter Mamógrafo, que retira atendimentos de uma cidade de um mamógrafo e os disponibiliza para outra cidade com outro mamógrafo. De forma análoga ao movimento Realoca Atendimento Intra Mamógrafo, o número de atendimentos realocados a cada movimento (parâmetro  $E\_INTER$ , apresentado na Tabela 5.3) foi definido utilizando a ferramenta *irace*. A Figura 4.7 mostra o resultado da aplicação do movimento Realoca Atendimento Inter Mamógrafo sobre a Figura 4.6, na qual 50 atendimentos da cidade F são realocados para a cidade D. Neste caso, o movimento realoca atendimentos entre duas cidades atendidas por dois mamógrafos distintos. Da mesma forma, a cobertura não é alterada durante a aplicação do movimento Realoca Atendimento Inter Mamógrafo e a avaliação da solução é realizada pela função apresentada na Equação (4.3).

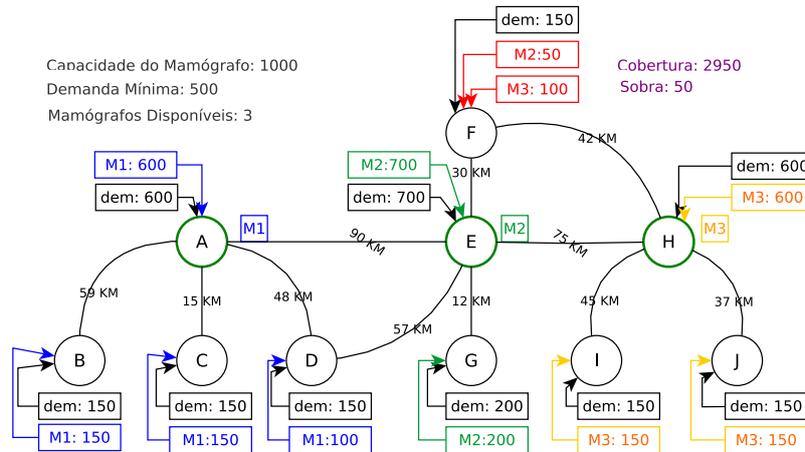


Figura 4.7: Exemplo da estrutura de vizinhança Realoca Atendimento Inter Mamógrafo

Por fim, a quarta estrutura de vizinhança é gerada com o movimento Busca Atendimento, que consiste em buscar alguma demanda ainda não atendida que pode ser atendida por algum mamógrafo com sobras de exames. Aplicando-se o movimento Busca Atendimento sobre a Figura 4.7, obtemos o grafo representado pela Figura 4.8, na qual 50 atendimentos da cidade D passam a ser feitos pelo mamógrafo 2, elevando a função objetivo de 2950 para 3000 atendimentos.

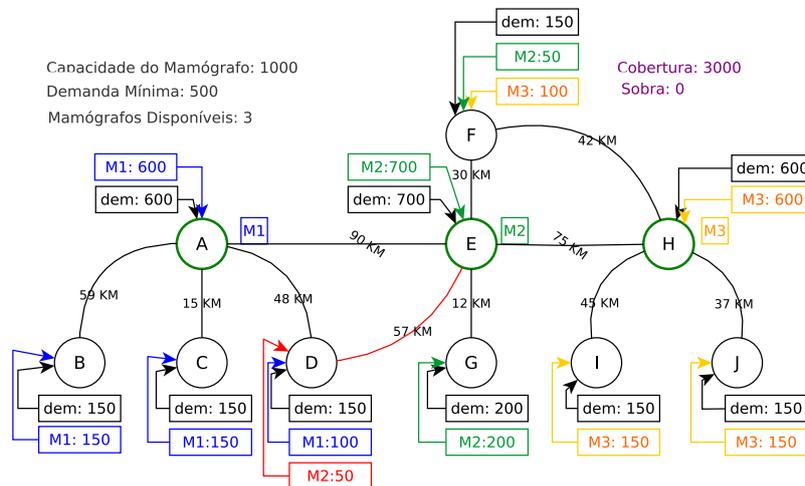


Figura 4.8: Exemplo da estrutura de vizinhança Busca Atendimento

#### 4.2.6 Algoritmo GVNS Proposto

Para tratar o problema, foi proposto um algoritmo baseado na meta-heurística *GVNS*, cujo pseudocódigo é apresentado no Algoritmo 9.

**Algoritmo 9:** GVNS-PLAM( $k_{\max}, iter_{\max}, s$ )

---

```

1  $iter \leftarrow 0$ 
2 enquanto ( $iter < iter_{\max}$ ) faça
3    $k \leftarrow 1$ 
4   enquanto ( $k < k_{\max}$ ) faça
5      $s' \leftarrow shake(s)$ 
6      $s'' \leftarrow VND\_PLAM(s')$ 
7     se  $f(s) < f(s'')$  então
8        $s \leftarrow s''$ 
9        $k \leftarrow 1$ 
10       $iter \leftarrow 0$ 
11     senão
12        $k \leftarrow k + 1$ 
13     fim
14   fim
15    $iter \leftarrow iter + 1$ 
16 fim
17 retorna  $s$ 

```

---

O algoritmo GVNS-PLAM inicia sua busca a partir de uma solução inicial recebida como parâmetro de entrada. Em seguida, um conjunto de vizinhanças é explorado iterativamente até que a condição de parada seja alcançada (linhas 4 a 14). Este processo é realizado da seguinte forma: uma nova solução aleatória da  $k$ -ésima vizinhança é gerada (*shake* - 5), sendo esta solução perturbada refinada, em seguida, pelo procedimento de busca local (linha 6). Na sequência, a solução corrente é avaliada. Se houver melhora, a solução corrente é atualizada e  $k$  retorna ao seu valor inicial; caso contrário, a solução corrente é mantida e o valor de  $k$  é incrementado. Este procedimento é aplicado por  $iter_{\max}$  iterações (linhas 2 a 16).

### 4.3 Método construtivo para o MMURP

Esta seção é dedicada a descrever a heurísticas utilizada na solução do MMURP. Na Subseção 4.3.1, é apresentada a representação computacional do MMURP e, na Subseção 4.3, o algoritmo construtivo desenvolvido para solucioná-lo.

#### 4.3.1 Representação da Solução

A solução do MMURP é representada por um conjunto de  $r$  vetores de tamanho  $n$ , sendo  $r$  o conjunto de rotas criadas e  $n$  o número de cidades inseridas em cada rota. A Figura 4.9 ilustra a solução do problema representado pela Figura 2.2. Nesse cenário há um conjunto  $\{A, B, C, D, E, F, G\}$  de  $n = 7$  cidades a serem atendidas por MMUs e um conjunto  $\{1, 2, 3, 4\}$  de  $m = 4$  cidades com infraestrutura hospitalar.

Como pode ser observado na Figura 4.9, para atender a demanda apresentada na Figura 2.2 são criadas três rotas. A rota R1 atende as cidades C, A e B, nesta ordem. A rota R2 atende as cidades D e E, nesta sequência e, por fim, a rota R3 atende as cidades F e G, nesta ordem.

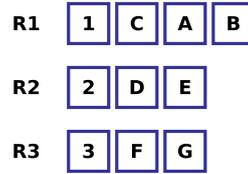


Figura 4.9: Exemplo de solução MMURP.

---

**Algoritmo 10:** `constroiSolucaoMMURP(LC,  $\alpha$ )`

---

```

1  $s \leftarrow \emptyset$  /* Solução a ser gerada */
2  $j \leftarrow 1$  /* Contador de rotas */
3  $R_1 \leftarrow \emptyset$  /* Rota inicial */
4  $novaRota \leftarrow TRUE$ 
5 enquanto ( $LC \neq \emptyset$ ) faça
6   se  $novaRota$  então
7     IniciaNovaRota( $j, R, s, LC, novaRota$ ) /* Inicia nova rota. */
8   senão
9      $LRC \leftarrow gereListaRestritaDeCandidatos(LC, \alpha)$ 
10     $i \leftarrow$  Cidade aleatoriamente escolhida da  $LRC$ 
11     $R_j \leftarrow$  Adicione a cidade  $i$  à rota  $R_j$ 
12    Atualize o tempo da rota  $R_j$ 
13    Atualize a demanda da cidade  $i$ 
14    se Tempo de  $R_j$  atingiu o limite então
15       $s \leftarrow$  Adicione a rota  $R_j$  à solução  $s$ 
16       $j \leftarrow j + 1$ 
17       $novaRota \leftarrow TRUE$ 
18    senão
19       $novaRota \leftarrow FALSE$ 
20    fim
21    se  $i$  não tiver demanda então
22       $LC \leftarrow LC \setminus \{i\}$ 
23    fim
24  fim
25 fim
26 retorna  $s$ 

```

---

### 4.3.2 Construção da Solução

A solução para o MMURP proposta nesta pesquisa foi desenvolvida baseada na fase de construção da meta-heurística GRASP. Nela, um elemento é selecionado aleatoriamente em uma lista restrita dos  $\alpha$  melhores candidatos e inserido na solução. O método desenvolvido é descrito pelos Algoritmos 10 e 11.

As linhas 1 a 4 do Algoritmo 10 criam uma solução vazia, iniciam o contador  $j$  de rotas, definem uma rota inicial e estabelecem uma *flag novaRota* para identificar o início e o fim de uma rota, respectivamente. As linhas 5 a 25, criam novas rotas

adicionando-as à solução enquanto houver cidades em *LC* a serem atendidas na solução. A linha 7 cria uma nova rota a ser adicionada à solução, sendo este procedimento descrito pelo Algoritmo 11. Nas linhas 8 a 24, cidades são adicionados à rota corrente enquanto houver disponibilidade para realização de exames. Para isto, na linha 9, é gerada uma *LRC* com as  $\alpha$  cidades de *LC* mais próximas da última cidade inserida na rota. Na linha 10, uma cidade é selecionada aleatoriamente da *LRC* e, nas linhas 11 a 13, esta cidade é adicionada à rota, o tempo da rota é atualizado e a demanda dessa cidade é atualizada. Nas linhas 14 a 20, verifica-se se, ao adicionar uma nova cidade à rota, a capacidade de atendimento da *MMU* se esgotou. Em caso positivo, a rota é adicionada à solução  $s$ , o contador  $j$  do número de rotas é incrementado e a *flag rotaNova* é setada como *TRUE*; caso negativo, seta-se a *flag rotaNova* como *FALSE*. Por fim, nas linhas 21 a 23, a cidade selecionada, caso sua demanda tenha sido coberta, é removida de *LC*.

O Algoritmo 11 descreve o procedimento de abertura de novas rotas. O algoritmo recebe, do Algoritmo 10, a rota referente a  $j$ , a solução  $s$ , a *LC* e a *flag novaRota*. Na Linha 1, seleciona-se a primeira cidade de *LC*, na linha 2, seleciona-se o depósito mais próximo dela. Os passos descritos nas linhas 3 a 28 são executados caso o depósito esteja em *LC*. Nas linhas 4 a 6, o depósito  $D$  selecionado é adicionado à rota, atualiza-se o tempo da rota  $R_j$  e a demanda de  $D$ . Da linha 7 até 13, caso a capacidade da *MMU* (tempo da rota) tenha se esgotado, a rota é adicionada à solução,  $j$  é incrementado e a *flag novaRota* recebe *TRUE*, e, caso a demanda do depósito  $D$  tenha sido integralmente coberta,  $D$  é removida de *LC*. Caso contrário, entre as linhas 14 e 28, a cidade  $i$  é adicionada em  $R_j$ , sua demanda e o tempo de  $R_j$  são atualizados. Na sequência, caso o tempo de  $R_j$  tenha atingido seu limite,  $R_j$  é adicionada à solução,  $j$  é incrementado, *novaRota* recebe *TRUE* e, caso a demanda de  $i$  tenha sido completamente coberta,  $i$  é removida de *LC*. Por fim, nas linhas 29 a 44, caso o depósito não esteja em *LC*, o depósito é adicionado à rota  $R_j$  seguido da cidade  $i$ , primeira a ser atendida, o tempo de  $R_j$  e a demanda de  $i$  são atualizados. Na sequência, é verificado se a capacidade da *MMU* atingiu o limite, caso afirmativo,  $R_j$  é adicionada à solução, o contador  $j$  é incrementado e *novaRota* recebe *TRUE*, caso negativo, *novaRota* recebe *FALSE*. Por fim, verifica-se se a demanda da cidade  $i$  foi integralmente coberta; caso positivo, ela é removida da *LC*.

**Algoritmo 11:** IniciaNovaRota ( $j, R, s, LC, novaRota$ )

---

```

1  $i \leftarrow$  primeiro elemento de  $LC$ 
2  $D \leftarrow$  depósito mais próximo de  $i$ 
3 se  $D \in LC$  então
4    $R_j \leftarrow$  Adicione o depósito  $D$  à rota  $R_j$ 
5   Atualize o tempo de  $R_j$ 
6   Atualize a demanda de  $D$ 
7   se Tempo de  $R_j$  atingiu o limite então
8      $s \leftarrow$  Adicione a rota  $R_j$  à solução  $s$ 
9      $j \leftarrow j + 1$ 
10     $novaRota \leftarrow TRUE$ 
11    se  $D$  não tiver demanda então
12       $LC \leftarrow LC \setminus \{D\}$ 
13    fim
14  senão
15     $R_j \leftarrow$  Adicione a cidade  $i$  à rota  $R_j$ 
16    Atualize o tempo de  $R_j$ 
17    Atualize a demanda de  $i$ 
18    se Tempo de  $R_j$  atingiu o limite então
19       $s \leftarrow$  Adicione a rota  $R_j$  à solução  $s$ 
20       $j \leftarrow j + 1$ 
21       $novaRota \leftarrow TRUE$ 
22    senão
23       $novaRota \leftarrow FALSE$ 
24    fim
25    se  $i$  não tiver demanda então
26       $LC \leftarrow LC \setminus \{i\}$ 
27    fim
28  fim
29 senão
30    $R_j \leftarrow$  Adicione o depósito  $D$  à rota  $R_j$ 
31    $R_j \leftarrow$  Adicione a cidade  $i$  à rota  $R_j$ 
32   Atualize o tempo de  $R_j$ 
33   Atualize a demanda de  $i$ 
34   se Tempo de  $R_j$  atingiu o limite então
35      $s \leftarrow$  Adicione a rota  $R_j$  à solução  $s$ 
36      $j \leftarrow j + 1$ 
37      $novaRota \leftarrow TRUE$ 
38   senão
39      $novaRota \leftarrow FALSE$ 
40   fim
41   se  $i$  não tiver demanda então
42      $LC \leftarrow LC \setminus \{i\}$ 
43   fim
44 fim
45 retorna  $novaRota$ 

```

---

# Capítulo 5

## Experimentos Computacionais

Este capítulo está organizado como segue. A Seção 5.1 mostra o ambiente de desenvolvimento. Na Seção 5.2 são apresentados as instâncias e os resultados obtidos com a aplicação dos algoritmos desenvolvidos para solução do PLAM. Por fim, na Seção 5.3, são descritas as instâncias utilizadas nos testes do algoritmo construtivo desenvolvido para o MMURP e os resultados obtidos com a sua aplicação.

### 5.1 Ambiente de desenvolvimento

O algoritmo IGS-PLAM proposto foi implementado em C++. Os resultados foram obtidos usando um computador com processador Core i5-6200U, 2.30GHz, 4 GB de RAM, com Sistema Operacional Ubuntu 20.04. Os resultados encontrados pelos algoritmos propostos foram comparados com aqueles obtidos pelo *Cplex* 12.7.1 e pelo algoritmo proposto por de Campos et al. (2020), utilizando o método SA. Os algoritmos propostos IGS-PLAM e GVNS-PLAM foram implementados em C++. Os testes foram realizados em uma máquina virtual com as seguintes configurações: processador de 16 núcleos e 8 GB de RAM, Sistema Operacional Ubuntu 20.04, virtualizada em um servidor com processador Xeon(R) v3 2.30 GHz, 110 GB de RAM.

Para uma comparação justa, todos os métodos de solução foram testados no mesmo computador.

### 5.2 Resultados para o PLAM

Nesta Seção são apresentadas, na Subseção 5.2.1, as instâncias utilizadas nos testes dos algoritmos para o PLAM. A Subseção 5.2.2 apresenta os resultados obtidos pelo algoritmo IGS-PLAM e a Subseção 5.2.3, os resultados obtidos pelo algoritmo GVNS-PLAM.

#### 5.2.1 Instâncias para o PLAM

As instâncias utilizadas nos testes do algoritmo IGS-PLAM são as de de Campos et al. (2020), que estudou a demanda por exames do estado de Minas Gerais em 2020. Nas instâncias MG\_258\_375\_6758, MG\_324\_375\_6758 e MG\_344\_375\_6758, - considera-se que a capacidade dos equipamentos é de 6758 exames anuais; enquanto

que nas demais, essa capacidade é de 5069 exames. Nas instâncias MG\_324\_375\_5069 e MG\_324\_375\_6758, considera-se 324 equipamentos, correspondente à disponibilidade em agosto de 2019, segundo dados do DATASUS. As instâncias MG\_258\_375\_6758, MG\_344\_375\_5069 e MG\_344\_375\_6758 são artificiais em relação ao número de equipamentos disponíveis. Destas, na primeira considera-se que há menos equipamentos que a disponibilidade atual, enquanto nas duas seguintes, simula-se a existência de mais equipamentos que os atualmente existentes.

Para o algoritmo GVNS-PLAM foram utilizadas cinco instâncias, das quais quatro foram propostas em de Campos et al. (2020). Dessas quatro, as duas primeiras (MG\_324\_0\_5069 e MG\_324\_0\_6758), consideram a disponibilidade de 324 aparelhos de mamografia, qualquer cidade pode sediar um equipamento e os aparelhos de mamografia possuem capacidade para realização de 5069 e 6758 exames anuais, respectivamente. As outras duas instâncias, MG\_344\_375\_5069 e MG\_324\_375\_6758, consideram como cidade candidata a sediar um equipamento aquela que possui demanda mínima de 375 exames, consideram também a disponibilidade de 344 e 324 equipamentos de mamografia, respectivamente. Estas quantidades de equipamentos são suficientes para cobrir toda a demanda do estado considerando a capacidade anual de realização de exames, para cada instância, de 5069 e 6758, respectivamente. Além daquelas utilizadas por de Campos et al. (2020), foi utilizada também uma instância de Minas Gerais, denominada MG\_353\_375\_6758, relativa a dados do mês de outubro de 2021. Nesta instância foi considerada a disponibilidade de 353 equipamentos de mamografia, a capacidade de realização de 6758 exames anuais, e atualizadas as demandas por exames no período.

## 5.2.2 Resultados da aplicação do algoritmo IGS-PLAM

A Tabela 5.1 apresenta os resultados obtidos pelo CPLEX aplicado à solução da formulação de programação matemática descrita na Seção 2.1. A Tabela 5.2 compara os resultados encontrados pelo algoritmo proposto com aqueles obtidos pelo método SA (de Campos et al., 2020). Para uma comparação justa, inicialmente o algoritmo SA foi executado com os mesmos valores de parâmetros usados por de Campos et al. (2020). O tempo demandado pelo algoritmo SA foi, então, usado como critério de parada do algoritmo IGS. O nível máximo de destruição  $k_{\max}$  foi definido em testes preliminares pelo valor 10. A primeira coluna desta tabela identifica as instâncias. As cinco próximas colunas reportam o melhor valor da função objetivo  $fo$ , seu valor médio em 10 execuções do método SA, o  $gap$  do melhor valor de  $fo$  e o  $gap$  do valor médio, calculados conforme Eq. (5.1), e o tempo demandado por esse algoritmo, em segundos. A quinta e sexta colunas reportam o melhor valor de  $fo$  e o seu valor médio encontrado em 10 execuções do algoritmo IGS no mesmo tempo de execução do SA. Por fim, as duas últimas colunas registram os  $gaps$  do melhor valor e do valor médio encontrado pelo IGS. Os melhores resultados são destacados em negrito na tabela.

$$gap_i^{Alg} = \frac{UB_i - fo_i^{Alg}}{UB_i} \quad (5.1)$$

Na Equação (5.1),  $fo_i^{Alg}$  é o valor de demanda total retornado pelo algoritmo  $Alg$  (que pode ser o SA ou o IGS) na instância  $i$  e  $UB_i$  é o limite superior retornado pelo CPLEX na instância  $i$ .

Tabela 5.1: Resultados gerados pelo CPLEX

CPLEX				
Instância	Upper Bound	$fo$	$gap$ (%)	Tempo
MG_258_375_6758	1.695.967	1.695.966	0,00	1562
MG_324_375_5069	1.642.356	1.641.625	0,40	3600
MG_324_375_6758	1.738.872	1.738.872	0,00	4
MG_344_375_5069	1.709.447	1.706.132	0,10	3600
MG_344_375_6758	1.738.872	1.738.872	0,00	4.9

Tabela 5.2: Comparação entre os resultados dos métodos *Simulated Annealing* e IGS

Instância	SA		GAP		Tempo	IGS		GAP	
	Melhor	Media	Melhor (%)	Média (%)		Melhor	Media	Melhor (%)	Média (%)
MG_358_375_6758	<b>1681226</b>	<b>1677661</b>	0.87%	1.08%	194	1675517	1672720	1.21%	1.37%
MG_324_375_5069	<b>1639845</b>	<b>1639049</b>	0.15%	0.20%	188	1634390	1632064	0.49%	0.63%
MG_324_375_6758	<b>1738872</b>	<b>1738736</b>	0.00%	0.01%	149	1738350	1736889	0.03%	0.11%
MG_344_375_5069	<b>1696348</b>	<b>1694042</b>	0.77%	0.90%	210	1689674	1686674	1.16%	1.33%
MG_344_375_6758	<b>1738872</b>	<b>1738872</b>	0.00%	0.00%	166	1738349	1737762	0.03%	0.06%

Como pode ser observado na Tabela 5.2, os resultados obtidos pelo IGS ficaram ligeiramente abaixo daqueles obtidos usando o SA (de Campos et al., 2020). Da mesma forma, para todas as instâncias testadas, os  $gaps$  se mantiveram baixos e próximos dos valores obtidos pelo método exato (Tabela 5.1). Destaca-se aqui as instâncias MG\_324\_375\_6758 e MG\_344\_375\_6758, nas quais tanto os  $gaps$  da melhor execução, como os  $gaps$  da média das execuções aproximam-se de zero, o que pode ser entendido como uma solução de qualidade no contexto do problema. O melhor desempenho do IGS foi obtido com a instância fictícia MG\_344\_375\_6758. Embora não tenha atingido o valor ótimo como os outros dois métodos, o algoritmo IGS-PLAM apresentou um  $gap$  de apenas 0,03% no melhor caso e 0,06% na média.

### 5.2.3 Resultados da aplicação do algoritmo GVNS-PLAM

Dado seu caráter estocástico, o algoritmo GVNS-PLAM foi executado 30 vezes em cada uma das instâncias. Os resultados do algoritmo proposto foram comparados com os obtidos pela aplicação do CPLEX à formulação descrita em de Campos et al. (2020), assim como com os resultados do algoritmo SA, denotado por SA-PLAM, desses autores. Para uma comparação justa, todos os métodos de solução foram testados na mesma máquina.

Para calibração dos parâmetros do algoritmo GVNS-PLAM foi utilizada a ferramenta *Irace* (López-Ibáñez et al., 2016). Dado um conjunto de instâncias do problema, a ferramenta disponibiliza, de forma automática, o conjunto de valores dos parâmetros mais adequados para a execução de um algoritmo. Os valores dos parâmetros testados e retornados pelo *Irace* são apresentados na Tabela 5.3. Nesta tabela,  $\alpha$  representa o tamanho da lista restrita de candidatos utilizada no Algoritmo 7,  $ITER\_MAX$  indica o número máximo de iterações sem melhora do Algoritmo 9 e  $E\_INTRA$  e  $E\_INTER$  indicam, respectivamente, o número de exames realocados nos movimentos Realoca Atendimento Intra Mamógrafo e Realoca Atendimento Inter Mamógrafo.

Tabela 5.3: Valores dos parâmetros testados e retornados pelo Irace

Parâmetros	Valores Testados	Valores Retornados
$\alpha$	[2, 5]	4
<i>ITER_MAX</i>	[20, 50]	39
<i>E_INTER</i>	[1, 10]	5
<i>E_INTRA</i>	[1, 10]	2

A Tabela 5.4 reporta a comparação de resultados entre os métodos CPLEX, SA (de Campos et al., 2020) e o proposto neste trabalho aplicados ao PLAM. Na primeira coluna são identificadas as instâncias do problema. A segunda coluna mostra o resultado do CPLEX em uma hora de processamento, no máximo. Da terceira à sétima coluna são apresentados os resultados alcançados pelo algoritmo SA, sendo apresentados, nesta ordem, o melhor resultado, a média dos resultados das execuções, o GAP do melhor resultado e da média dos resultados das execuções em relação ao resultado do CPLEX conforme Equação (5.2), e o tempo de processamento consumido em cada instância, em segundos. Os resultados alcançados pelo algoritmo GVNS-PLAM são exibidos da oitava à décima segunda coluna e seguem a mesma ordem de apresentação do algoritmo SA-PLAM. Os melhores resultados são destacados em negrito. Os valores de GAP são calculados com base na Equação (5.2), na qual  $fo_i^{Alg}$  é o valor da maior cobertura (no caso do gap do melhor resultado) ou cobertura média (no caso do gap do resultado médio) retornada pelo algoritmo *Alg* (que pode ser o SA-PLAM ou o GVNS-PLAM) na instância *i* e  $CPLEX_i$  é o resultado retornado pelo resolvidor CPLEX na instância *i* em no máximo uma hora de processamento.

$$gap_i^{Alg} = \frac{CPLEX_i - fo_i^{Alg}}{CPLEX_i} \quad (5.2)$$

Tabela 5.4: Comparação entre os resultados dos métodos *Simulated Annealing* e GVNS aplicados ao PLAM

Instância	CPLEX	SA-PLAM					GVNS-PLAM				
		Melhor	Média	GAP (%)		Tempo (s)	Melhor	Média	GAP (%)		Tempo (s)
MG_324_0_5069	<b>1642034</b>	1641261	1640187	0,05	0,11	59	1640872	1639503	0,07	0,15	4483
MG_344_375_5069	<b>1706321</b>	1698418	1693794	0,46	0,73	59	1703829	1696074	0,15	0,60	6040
MG_324_0_6758	<b>1739432</b> <sup>(1)</sup>	<b>1739432</b>	1738794	0,00	0,04	52	<b>1739432</b>	1738997	0,00	0,03	2249
MG_324_375_6758	<b>1738872</b> <sup>(2)</sup>	1738063	1736403	0,05	0,14	51	1737890	1735553	0,06	0,19	1610
MG_353_375_6758	<b>1733024</b> <sup>(3)</sup>	1731325	1729810	0,10	0,19	45	1729414	1727835	0,21	0,30	222

<sup>(1)</sup> Obtido em 14 segundos; <sup>(2)</sup> Obtido em 9 segundos; <sup>(3)</sup> Obtido em 10 segundos

Como pode ser observado na Tabela 5.4, o algoritmo proposto neste trabalho supera os resultados do algoritmo apresentado em de Campos et al. (2020), tanto com relação ao melhor resultado quanto em relação à média dos resultados na instância MG\_344\_375\_5069. Na instância MG\_324\_0\_6758, o algoritmo proposto encontrou a solução ótima e seu resultado médio supera o do algoritmo SA-PLAM. Destaca-se que em todas as instâncias, para as melhores execuções do GVNS-PLAM, o GAP se manteve igual ou abaixo de 0,21%. Para a média das execuções, o pior desempenho do algoritmo ocorreu na instância MG\_344\_375\_5069; contudo, este resultado médio é melhor do que aquele obtido pelo SA. Os tempos computacionais demandados pelo algoritmo proposto são, no entanto, bem maiores do que os dos outros métodos de solução.

## 5.3 Resultados para o MMURP

Nesta seção, na Subseção 5.3.1 são descritas as instâncias utilizadas nos testes do algoritmo construtivo para o MMURP e, na Subseção 5.3.2, são apresentados os resultados obtidos com a aplicação do algoritmo construtivo para o MMURP.

### 5.3.1 Instâncias para o MMURP

Para gerar as instâncias do MMURP, foram aplicados os algoritmos IGS-PLAM e GVNS-PLAM a sete instâncias do PLAM. O algoritmo IGS-PLAM foi reimplementado utilizando-se a nova representação de solução, bem como as novas estruturas de vizinhança decorrentes dessa nova representação. Dessa forma, a comparação de desempenho entre os algoritmos IGS-PLAM e GVNS-PLAM é mais justa, porque ambos utilizam a mesma representação e o mesmo conjunto de estruturas de vizinhança.

Para cada instância do PLAM, consideramos como instância do MMURP correspondente, a melhor solução apresentada pelos dois algoritmos.

A Tabela 5.5 mostra os resultados obtidos com a aplicação dos algoritmos mencionados às sete instâncias do PLAM. A primeira coluna dessa tabela identifica as instâncias utilizadas, a segunda coluna reporta a demanda total de exames de cada instância, a terceira e quarta colunas reportam o melhor valor alcançado e o deficit de exames após a execução do IGS-PLAM. Por fim, a quinta e sexta colunas reportam o melhor valor alcançado e o deficit de exames após a execução do GVNS-PLAM. Os valores destacados em negrito mostram os valores das melhores soluções encontradas.

Tabela 5.5: Resultados obtidos pelos algoritmos IGS-PLAM e GVNS-PLAM.

Instância	Demanda	IGS-PLAM		GVNS-PLAM	
		Atendido	Não atendido	Atendido	Não atendido
AP	40916	<b>35646</b>	5270	<b>35646</b>	5270
CE	659229	587943	71286	<b>587946</b>	71283
MA	437638	<b>305776</b>	131862	304064	133574
PA	494894	<b>415580</b>	79314	409480	85414
PI	240218	<b>212349</b>	27869	<b>212349</b>	27869
RJ	1544794	<b>1243472</b>	301322	<b>1243472</b>	301322
TO	96592	<b>69711</b>	26881	<b>69711</b>	26881

Como podemos observar pela Tabela 5.5, o algoritmo GVNS-PLAM gerou a melhor solução apenas para a instância CE. Nas demais instâncias, o IGS-PLAM foi o melhor. Desta forma, seis instâncias do MMURP são formadas pelas soluções advindas do IGS-PLAM e apenas uma pelo GVNS-PLAM.

As instâncias do MMURP contêm, além das distâncias entre as cidades, o número de cidades não cobertas integralmente na solução do PLAM, o *id* das cidades, suas demandas não cobertas e a relação de cidades com infraestrutura hospitalar. Essa última informação estabelece o critério para definir se uma cidade pode ser a base de uma MMU ou não.

### 5.3.2 Resultados do algoritmo construtivo ao MMURP

A Tabela 5.6 mostra os resultados da aplicação do algoritmo construtivo ao MMURP. A primeira coluna identifica a instância e a segunda indica o algoritmo que produziu a melhor solução do PLAM (isto é, o IGS-PLAM ou o GVNS-PLAM). A terceira mostra o número de cidades a serem atendidas, a quarta coluna apresenta a demanda total em cada instância, e as quinta e sexta colunas reportam a quantidade de rotas e a distância total obtidas com a aplicação do algoritmo construtivo para atender toda a demanda da instância.

Tabela 5.6: Resultados do algoritmo construtivo aplicado ao MMURP

Instância	Melhor Alg. PLAM	Número de Cidades	Demanda	Rotas	Distância ( <i>km</i> )
AP	IGS	11	5270	4	403
CE	GVNS	60	71238	12	9947
MA	IGS	117	131862	24	15596
PA	IGS	58	79314	19	21548
PI	IGS	70	27869	6	6634
RJ	IGS	45	301322	45	11718
TO	IGS	74	26881	6	8019

Como pode ser observado na Tabela 5.6, para a instância AP são necessárias 4 MMUs para atender integralmente a demanda do Estado do Amapá, percorrendo, ao todo, 403 *km*. Como uma MMU é capaz de realizar 6758 exames anualmente, o número de unidades é relativamente alto. Isto ocorre porque o Estado do Amapá possui um número elevado de municípios com demanda a ser coberta e a distância entre estas cidades excede o limite de 180 *km* em muitos casos. Para a instância CE, o algoritmo sugere 12 MMUs para cobrir toda a demanda do Estado do Ceará, percorrendo, no total, 9947 *km*. Para este Estado, o número de unidades sugerida se aproxima mais da quantidade mínima para atendê-lo.

A Figura 5.1 ilustra a solução obtida para a instância PI. Nela, a cor verde representa os municípios que tiveram suas demandas integralmente cobertas na solução fornecida pelo IGS-PLAM, já as linhas coloridas representam as rotas propostas na solução obtida pelo algoritmo construtivo para o MMURP, o ícone com uma cruz vermelha ao centro representa o depósito de cada rota.

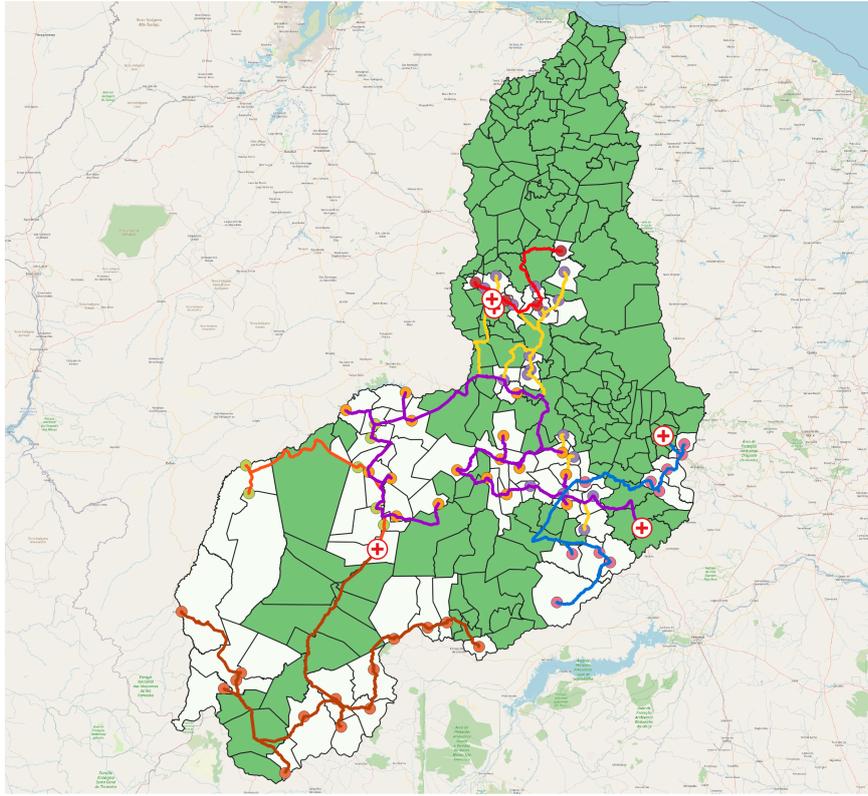


Figura 5.1: Rotas MMURP - Instância MMURP-PI-IGS

Na Figura 5.1, observa-se que todos os municípios não contemplados na solução fornecida pelo IGS-PLAM, ilustrados na cor branca, são percorridos pelas rotas sugeridas na solução do MMURP. Parte destas rotas são iniciadas em cidades cobertas pelo IGS-PLAM, outras não. Isto acontece porque, entre elas, há cidades candidatas a se tornarem depósito.

A Tabela 5.7 reporta o resultado obtido pelo algoritmo construtivo aplicado à instância PI do MMURP. A primeira coluna indica o ID de cada rota que é apresentada na segunda coluna, já a terceira e quarta colunas indicam a distância percorrida e a demanda coberta por cada uma delas.

Tabela 5.7: Solução MMURP - Instância MMURP-PI-IGS

ID	Rota	Distância ( <i>km</i> )	Cobertura
[1]	<b>7</b> → 60 → 123 → 117 → 121 → 207 → 172 → 17	624	3178
[2]	<b>2</b> → 14 → 184 → 220 → 166 → 83 → 191 → 175 → 151 → 129 → 127 → 214 → 81 → 223 → 210 → 185 → 62 → 144 → 42	1679	6508
[3]	<b>7</b> → 16 → 91 → 79 → 51 → 110 → 132 → 67 → 109 → 149 → 131 → 20 → 206 → 89 → 176	1658	6199
[4]	<b>1</b> → 21 → 69 → 201 → 140	332	1231
[5]	<b>0</b> → 23 → 42 → 211 → 171 → 98 → 196 → 182 → 186 → 202 → 39 → 103 → 90 → 165 → 26 → 47 → 77 → 155	1720	5834
[6]	<b>4</b> → 41 → 122 → 209 → 70 → 53 → 96 → 50 → 113 → 167 → 75	621	4910
Total		<b>6634</b>	<b>27869</b>

Como pode ser observado na Tabela 5.7, para cobrir a demanda remanescente do Estado do Piauí após a aplicação do algoritmo IGS-PLAM, são necessárias 6 MMUs, as quais percorrem um total de 6634 *km*. As rotas 1 e 4 ocupam cerca de 50% da capacidade total de cada unidade, isto acontece devido a restrição de deslocamento máximo de 180 *km*, já as rotas 2, 3 e 5 alcançaram a taxa máxima de utilização para cada unidades. Na solução percebe-se que a cidade 42 está presente nas rotas 2 e 5, isto acontece porque o algoritmo permite que uma cidade seja atendida por mais de uma MMU, neste caso a rota 2 não disponibilizou exames suficientes para a cobertura integral, sendo a demanda remanescente coberta pela rota 5.

# Capítulo 6

## Considerações Finais e Direções Futuras

### 6.1 Considerações Finais

Esta dissertação tratou, inicialmente, do problema de localização e alocação de mamógrafos fixos (PLAM).

Uma nova forma de representação computacional para uma solução do PLAM foi proposta. Ao contrário da representação anteriormente adotada na literatura, com ela é possível identificar os equipamentos alocados em cada cidade. Em virtude dessa representação, foram desenvolvidas novas estruturas de vizinhança. Essas novas estruturas permitiram uma melhor exploração do espaço de soluções do problema. Dois algoritmos de busca local baseados nas metaheurísticas *Iterated Greedy Search* e *General Variable Neighborhood Search*, e nomeados IGS-PLAM e GVNS-PLAM, respectivamente, foram desenvolvidos para tratar o PLAM.

Inicialmente, o algoritmo IGS-PLAM foi comparado com o algoritmo SA de [de Campos et al. \(2020\)](#) e com o CPLEX utilizando a versão anterior da representação de soluções, na qual não se identificavam os equipamentos instalados em cada cidade. Os experimentos computacionais mostraram que o algoritmo IGS-PLAM, embora não tenha superado os resultados obtidos por [de Campos et al. \(2020\)](#), obteve valores de *gap* próximos de zero. Em seguida, o algoritmo GVNS-PLAM foi comparado com o algoritmo SA de [de Campos et al. \(2020\)](#) e com o CPLEX. Observa-se, nesta comparação, que o algoritmo GVNS-PLAM utiliza a nova representação de solução, bem como as novas estruturas de vizinhança. Os resultados dessa comparação mostraram que o GVNS-PLAM teve desempenho melhor do que o do IGS-PLAM, tanto em valor de *gap*, quanto em variabilidade da solução final. Além disso, ele também foi capaz de superar o algoritmo de [de Campos et al. \(2020\)](#) em uma instância e igualar em outra com relação ao melhor resultado obtido. Entretanto, ele também teve desempenho global inferior ao algoritmo SA de [de Campos et al. \(2020\)](#), e exigiu um tempo de processamento muito maior.

Posteriormente, o algoritmo IGS-PLAM foi atualizado com relação à representação e adição das novas estruturas de vizinhança. Com essas alterações, mostrou-se que o IGS-PLAM teve melhor desempenho que o GVNS-PLAM, sendo capaz de produzir melhores soluções em seis de sete instâncias do PLAM. Esse resultado mostra a influência da nova representação da solução e das novas estruturas de vizinhança

usadas para explorar o espaço de soluções do problema.

As soluções geradas por qualquer dos algoritmos aplicados ao **PLAM** podem não atender a toda a demanda existente. Isso ocorre devido à imposição das restrições de distância máxima para atendimento do exame e de localização de mamógrafos fixos apenas a cidades que tenham infraestrutura para sediar tais equipamentos. Assim, se uma cidade não tem infraestrutura hospitalar e está distante de outra que tenha o equipamento instalado, a demanda dessa cidade não tem como ser atendida. Em função disso, a demanda remanescente deve ser atendida por unidades móveis de mamografia, as chamadas MMUs. O problema de roteamento dessas MMUs, conhecido na literatura como **MMURP**, é um **PRV** aberto. Ou seja, não é necessário que as MMUs retornem ao depósito ao final de suas rotas.

Assim, foi desenvolvido um algoritmo heurístico construtivo para o **MMURP** partindo-se da melhor das soluções geradas pelos algoritmos IGS-PLAM e GVNS-PLAM com a nova representação de solução para o **PLAM**. Isto é, o algoritmo de localização e alocação que gera a melhor cobertura usando mamógrafos fixos é utilizado para estabelecer as demandas remanescentes em cada instância. Esse algoritmo construtivo foi aplicado em sete unidades da federação brasileira com o objetivo de determinar a quantidade de MMUs necessária para cobrir toda a demandas dessas unidades.

Em resumo, os algoritmos heurísticos IGS-PLAM e GVNS-PLAM retornam uma solução para o **PLAM** visando à localização e alocação dos mamógrafos fixos. Em seguida, a demanda das cidades não cobertas pelos mamógrafos fixos é atendida pelas MMUs resolvendo-se o **MMURP** por meio de um algoritmo heurístico construtivo.

Por fim, para cada um dos sete estados da federação brasileira considerados neste trabalho, foi, então, proposta a localização e alocação do conjunto de mamógrafos fixos existentes nesses estados, bem como uma sugestão de roteirização das MMUs para cobrir toda a demanda existente.

## 6.2 Publicações derivadas desta pesquisa

Abaixo são relacionados os trabalhos derivados desta pesquisa que foram publicados em anais de eventos científicos.

1. Título: Um algoritmo *Iterated Greedy Search* para o Problema de Localização de Mamógrafos com atendimento parcial.
  - Autores: Romário dos S. L. de Assis, Marcos V. A. de Campos, Marcone J. F. Souza, Maria Amélia L. Silva, Eduardo C. de Siqueira e Sérgio R. de Souza.
  - Evento: LIII Simpósio Brasileiro de Pesquisa Operacional (SBPO 2021)
  - Local: João Pessoa, PB, Brasil.
  - Período: 3 a 5 de novembro de 2021
  - Trabalho completo apresentado em evento
2. Título: Um algoritmo *Variable Neighborhood Search* para o Problema de Localização de Mamógrafos com atendimento parcial.

- Autores: Romário dos S. L. de Assis, Marcos V. A. de Campos, Marcone J. F. Souza, Maria Amélia L. Silva, Eduardo C. de Siqueira e Sérgio R. de Souza.
- Evento: LIV Simpósio Brasileiro de Pesquisa Operacional (SBPO 2022)
- Local: Juiz de Fora, MG, Brasil.
- Período: 8 a 11 de novembro de 2022
- Trabalho completo apresentado em evento

### 6.3 Direções Futuras

Esta pesquisa apresentou os problemas [PLAM](#) e [MMURP](#) e as soluções encontradas com algoritmos heurísticos para cada um deles. Os resultados encontrados foram satisfatórios; contudo, ainda existem lacunas a serem preenchidas. Para tanto, algumas direções de continuidade desse trabalho são apresentadas a seguir:

- Desenvolver um algoritmo baseado em meta-heurística para melhorar a qualidade das soluções geradas para o [MMURP](#);
- Desenvolver um algoritmo heurístico que trate, de forma integrada, o [MMURP](#) e o [PLAM](#);
- Analisar a possibilidade de estender a solução do problema a outras estruturas de saúde pública.

# Referências Bibliográficas

Ahmadi-Javid, Amir; Seyedi, Pardis e Syam, Siddhartha S. (2017). A survey of healthcare facility location. *Computers & Operations Research*, v. 79, p. 223–263.

Almeida, João Flávio de Freitas e Campos, Francisco Carlos Cardoso de. sep(2021). A two-step planning method to increase accessibility to medium complexity procedures for public secondary healthcare. *Cien. Saude Colet.*, v. 26, n. 9, p. 4287–4298.

Almeida, João Flávio de Freitas; Pinto, Luiz Ricardo; Conceição, Samuel Vieira e Campos, Francisco Carlos Cardoso de. (2019). Medical centers location and specialists' allocation: a healthcare planning case study. *Production*, v. 29.

Amaral, Pedro; Luz, Luciana; Cardoso, Francisco e Freitas, Rosiene. (2017). Distribuição espacial de equipamentos de mamografia no Brasil. *Revista Brasileira de Estudos Urbanos e Regionais (RBEUR)*, v. 19, n. 2, p. 326–341.

Azamjah, Nasrindokht; Soltan-Zadeh, Yasaman e Zayeri, Farid. 7(2019). Global trend of breast cancer mortality rate: A 25-year study. *Asian Pacific Journal of Cancer Prevention*, v. 20, n. 2, p. 2015–2020.

Benslimane, Mohammed Taha e Benadada, Youssef. (2013). Ant colony algorithm for the multi-depot vehicle routing problem in large quantities by a heterogeneous fleet of vehicles. *INFOR: Information Systems and Operational Research*, v. 51, n. 1, p. 31–40. doi: 10.3138/infor.51.1.31.

Brandão, José. (2018). Iterated local search algorithm with ejection chains for the open vehicle routing problem with time windows. *Computers & Industrial Engineering*, v. 120, p. 146–159. ISSN 0360-8352. doi: <https://doi.org/10.1016/j.cie.2018.04.032>.

Brasil,. Critérios e parâmetros assistenciais para o planejamento e programação de ações e serviços de saúde no âmbito do Sistema Único de Saúde. Ministério da Saúde, Secretaria de Atenção à Saúde, Departamento de Regulação, Avaliação e Controle de Sistemas, (2017). URL <https://bit.ly/3KSHSDB>. Acesso em 11/03/2022.

Church, R. e Velle, C. R. (1974). The maximal covering location problem. *Papers of the Regional Science Association*, v. 32, p. 101–118.

Corrêa, Victor Hugo Vidigal; Lima, Bruno Jhonatan Costa; Silva-e-Souza, Pedro Henrique; Penna, Puca Huachi Vaz e Souza, Marccone Jamilson Freitas. (2018). Localização de mamógrafos: um estudo de caso na rede pública de saúde. *L Simpósio Brasileiro de Pesquisa Operacional*, Rio de Janeiro - Brasil.

Daskin, M. S. (2008). What you should know about location modeling. *Naval Research Logistics*, v. 55, n. 4, p. 283–294.

de Campos, Marcos Vinícius Andrade. (2020). Formulações de programação matemática e um algoritmo heurístico para o problema de localização de mamógrafos. Dissertação de mestrado, Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte.

de Campos, Marcos Vinícius Andrade; de Sá, Manoel Victor Stilpen Moreira; Rosa, Patrick Moreira; Penna, Puca Huachi Vaz; de Souza, Sérgio Ricardo e Souza, Marcene Jamilson Freitas. (2020). A mixed linear integer programming formulation and a simulated annealing algorithm for the mammography unit location problem. *Proceedings of the 22nd International Conference on Enterprise Information Systems*, p. 428–439, Setúbal, Portugal. Scitepress Digital Library.

De Mil, Rémy; Guillaume, Elodie; Launay, Ludivine; Guittet, Lydia; Dejardin, Olivier; Bouvier, Véronique; Notari, Annick; Launoy, Guy e Berchi, Célia. (2019). Cost-effectiveness analysis of a mobile mammography unit for breast cancer screening to reduce geographic and social health inequalities. *Value in Health*, v. 22, n. 10, p. 1111–1118. doi: <https://doi.org/10.1016/j.jval.2019.06.001>.

dosSantos Silva, Isabel; De Stavola, Bianca L; Renna, Nelson L; Nogueira, Mário C; Aquino, Estela M L; Bustamante-Teixeira, Maria Teresa e Azevedo e Silva, Gulnar. (2019). Ethnoracial and social trends in breast cancer staging at diagnosis in Brazil, 2001–14: a case only analysis. *The Lancet Global Health*, v. 7, n. 6, p. e784–e797.

Duffy, Stephen W.; Tabár, László; Yen, Amy Ming-Fang; Dean, Peter B.; Smith, Robert A.; Jonsson, Håkan; Törnberg, Sven; Chen, Sam Li-Sheng; Chiu, Sherry Yueh-Hsia; Fann, Jean Ching-Yuan; Ku, May Mei-Sheng; Wu, Wendy Yi-Ying; Hsu, Chen-Yang; Chen, Yu-Ching; Svane, Gunilla; Azavedo, Edward; Grundström, Helene; Sundén, Per; Leifland, Karin; Frodis, Ewa; Ramos, Joakim; Epstein, Birgitta; Åkerlund, Anders; Sundbom, Ann; Bordás, Pál; Wallin, Hans; Starck, Leena; Björkgren, Annika; Carlson, Stina; Fredriksson, Irma; Ahlgren, Johan; Öhman, Daniel; Holmberg, Lars e Chen, Tony Hsiu-Hsi. (2020). Mammography screening reduces rates of advanced and fatal breast cancers: Results in 549,091 women. *Cancer*, v. 126, n. 13, p. 2971–2979.

Eiselt, H A. jan(2011). *Foundations of location analysis*. International Series in Operations Research & Management Science. Springer Science+Business Media.

Feo, Thomas A e Resende, Mauricio GC. (1995). Greedy randomized adaptive search procedures. *Journal of global optimization*, v. 6, n. 2, p. 109–133.

Garey, Michael R e Johnson, David S. apr(1979). *Computers and intractability*. W.H. Freeman, New York, NY.

Ginsburg, Ophira; Yip, Cheng-Har; Brooks, Ari; Cabanes, Anna; Caleffi, Maira; Dunstan Yataco, Jorge Antonio; Gyawali, Bishal; McCormack, Valerie; McLaughlin deAnderson, Myrna; Mehrotra, Ravi; Mohar, Alejandro; Murillo, Raul; Pace, Lydia E.; Paskett, Electra D.; Romanoff, Anya; Rositch, Anne F.; Scheel, John R.;

- Schneidman, Miriam; Unger-Saldaña, Karla; Vanderpuye, Verna; Wu, Tsu-Yin; Yuma, Safina; Dvaladze, Allison; Duggan, Catherine e Anderson, Benjamin O. (2020). Breast cancer early detection: A phased approach to implementation. *Cancer*, v. 126, n. S10, p. 2379–2393.
- Hansen, Pierre; Mladenović, Nenad; Todosijević, Raca e Hanafi, Said. 08(2017). Variable neighborhood search: basics and variants. *EURO Journal on Computational Optimization*, v. 5, n. 3, p. 423–454.
- INCA,. Detecção precoce, Agosto(2022)a. Instituto Nacional do Cancer. <https://bityli.com/tujSdt>. Acesso em 08/08/2022.
- INCA,. Mortalidade, Agosto(2022)b. Instituto Nacional do Cancer. <https://bityli.com/0aQrrwu>. Acesso em 06/08/2022.
- Jewett, Patricia I.; Gangnon, Ronald E.; Elkin, Elena; Hampton, John M.; Jacobs, Elizabeth A.; Malecki, Kristen; LaGro, James; Newcomb, Polly A. e Trentham-Dietz, Amy. (2018). Geographic access to mammography facilities and frequency of mammography screening. *Annals of Epidemiology*, v. 28, n. 2, p. 65–71.e2. ISSN 1047-2797. doi: <https://doi.org/10.1016/j.annepidem.2017.11.012>.
- Lenstra, J. K. e Kan, A. H. G. Rinnooy. (1981). Complexity of vehicle routing and scheduling problems. *Networks*, v. 11, n. 2, p. 221–227. doi: <https://doi.org/10.1002/net.3230110211>.
- Li, Feiyue; Golden, Bruce e Wasil, Edward. (2007). The open vehicle routing problem: Algorithms, large-scale test problems, and computational results. *Computers & Operations Research*, v. 34, n. 10, p. 2918–2930. doi: <https://doi.org/10.1016/j.cor.2005.11.018>. URL <https://www.sciencedirect.com/science/article/pii/S0305054805003515>.
- López-Ibáñez, Manuel; Dubois-Lacoste, Jérémie; Pérez Cáceres, Leslie; Stützle, Thomas e Birattari, Mauro. (2016). The IRACE package: Iterated racing for automatic algorithm configuration. *Operations Research Perspectives*, v. 3, p. 43–58.
- López-Sánchez, A.D.; Hernández-Díaz, A.G.; Vigo, D.; Caballero, R. e Molina, J. (2014). A multi-start algorithm for a balanced real-world open vehicle routing problem. *European Journal of Operational Research*, v. 238, n. 1, p. 104–113. ISSN 0377-2217. doi: <https://doi.org/10.1016/j.ejor.2014.04.008>.
- Migowski, Arn et al. (2018). Diretrizes para detecção precoce do câncer de mama no Brasil. ii - novas recomendações nacionais, principais evidências e controvérsias. *Cadernos de Saúde Pública [online]*, v. 34.
- Mladenović, N. e Hansen, P. (1997). Variable neighborhood search. *Computers & Operations Research*, v. 24, n. 11, p. 1097–1100.
- Mohammadian-Hafshejani, Abdollah. 12(2019). Global, regional, and national cancer incidence, mortality, years of life lost, years lived with disability, and disability-adjusted life-years for 29 cancer groups, 1990 to 2017: A systematic analysis for the global burden of disease study. *JAMA Oncology*, v. 5, n. 12, p. 1749–1768.

- Paiva, Jéssica Natália Miranda; Rosa, Patrick Moreira; Penna, Puca Huachi Vaz; Monteiro, Janne Cavalcanti; Lisboa, Maillene Rodrigues e Souza, Marccone Jamilson Freitas Souza. (2023). Localização de mamógrafos: um estudo de caso para novos investimentos em Rondônia. *Pesquisa Operacional para o Desenvolvimento*, v. 16, p. 1–22. <https://doi.editoracubo.com.br/10.4322/PODes.2023.001>.
- Renck, Décio Valente; Barros, Fernando; Domingues, Marlos Rodrigues; Gonzalez, Maria Cristina; Sclowitz, Marcelo Leal; Caputo, Eduardo Lucia e Gomes, Laura de Moraes. Jan(2014). Equidade no acesso ao rastreamento mamográfico do câncer de mama com intervenção de mamógrafo móvel no sul do rio grande do sul, brasil. *Cadernos de Saúde Pública*, v. 30, n. 1, p. 88–96. doi: 10.1590/0102-311X00017113.
- ReVelle, C. S.; Eiselt, H. A. e Daskin, M. S. (2008). A bibliography for some fundamental problem categories in discrete location science. *European Journal of Operational Research*, v. 184, n. 3, p. 817–848.
- Rosa, M. P.; Sá, V. S. M.; Paiva, P. H. V.J. N. M. Penna e Souza, M. J. F. (2020). Análise da localização de mamógrafos em Minas Gerais. *LII Simpósio Brasileiro de Pesquisa Operacional*, João Pessoa – Brasil.
- Rosa, O. A. S.; Rosa, P. M.; Paiva, J. N. M.; Penna, Puca H. V. e Souza, Marccone J.F. (2021). Um algoritmo heurístico baseado em iterated greedy para o problema de roteamento de unidades móveis de mamografia. *LIII Simpósio Brasileiro de Pesquisa Operacional (SBPO 2021)*, João Pessoa – Brasil.
- Ruiz, Rubén e Stützle, Thomas. (2008). An iterated greedy heuristic for the sequence dependent setup times flowshop problem with makespan and weighted tardiness objectives. *European Journal of Operational Research*, v. 187, n. 3, p. 1143 – 1159.
- Sá, M. V. S. M.; Rosa, P. M.; Paiva, J. N. M.; Souza, M. J. F. e Penna, P. H. V. (2019). Localização de mamógrafos: Um estudo de caso do estado do espírito santo. *XXVI Simpósio de Engenharia de Produção*, Baurú. Universidade Estadual Paulista.
- Sathler, T. M.; Conceição, S. V.; Almeida, J. F e R., Pinto L. (2017). Problema de localização e alocação de centros de especialidades médicas no estado de minas gerais. *XLIX Simpósio Brasileiro de Pesquisa Operacional*, Blumenau - Brasil.
- Souza, M. J. F.; Penna, P. H. V.; Stilpen, M; Rosa, P. M.; Monteiro, J. C. e Lisboa, M. R. (2019). Localização de mamógrafos: formulações e estudo preliminar de caso de rondônia. *LI Simpósio Brasileiro de Pesquisa Operacional*, Limeira - Brasil.
- Souza, Marccone Jamilson Freitas; Penna, Puca Huachi Vaz; Moreira deSá, Manoel Victor Stilpen e Rosa, Patrick Moreira. (2020). A vns-based algorithm for the mammography unit location problem. Benmansour, Rachid; Sifaleras, Angelo e Mladenović, Nenad, editors, *Variable Neighborhood Search: 7th International Conference, ICVNS 2019, Rabat, Morocco, October 3–5, 2019, Revised Selected Papers*, volume 12010 of *Lecture Notes in Computer Science*, Capítulo 3, p. 37–52. Springer, Cham, Switzerland.

---

Vang, S.; Margolies, L.R. e Jandorf, L. (2018). Mobile mammography participation among medically underserved women: A systematic review. *Preventing Chronic Disease*, v. 15, n. 1, p. 1–15. doi: <https://doi.org/10.5888/pcd15.180291>.

Xavier, Diego Ricardo; deOliveira, Ricardo Antunes Dantas; deMatos, Vanderlei Pascoal; Viacava, Francisco e deCampos Carvalho, Carolina. (2016). Cobertura de mamografias, alocação e uso de equipamentos nas regiões de saúde. *Saúde em debate*, v. 40, n. 110, p. 20–35.

Zhang, Wenting; Cao, Kai; Liu, Shaobo e Huang, Bo. (2016). A multi-objective optimization approach for health-care facility location-allocation problems in highly developed cities such as hong kong. *Computers, Environment and Urban Systems*, v. 59, p. 220–230.