

Um algoritmo *Variable Neighborhood Search* para o Problema de Localização de Mamógrafos com atendimento parcial

**Romário dos Santos Lopes de Assis^{1,4}, Marcos Vinícius Andrade de Campos^{1,2},
Marcone Jamilson Freitas Souza^{1,3}, Maria Amélia Lopes Silva⁴,
Eduardo Camargo de Siqueira⁵, Sérgio Ricardo de Souza¹**

¹ Programa de Pós-Graduação em Modelagem Matemática e Computacional,
Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG),
Av. Amazonas 7675, CEP 30.510-000, Belo Horizonte (MG), Brasil

²Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais (IFMG),
CEP 30.575-180, Belo Horizonte (MG), Brasil

³Departamento de Computação – Universidade Federal de Ouro Preto (UFOP),
CEP 35.400-000, Ouro Preto (MG), Brasil

⁴Universidade Federal de Viçosa (UFV) – campus Florestal,
CEP 35.690-000 Florestal (MG), Brasil

⁵Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro (IFTM),
CEP 38.600-000, Paracatu (MG), Brasil

romario@ufv.br, marcos.campos@ifmg.edu.br, marccone@ufop.edu.br,
mamelia@ufv.br, eduardosiqueira@iftm.edu.br, sergio@cefetmg.br

RESUMO

Este trabalho trata o Problema de Localização de Mamógrafos com atendimento parcial. Neste trabalho busca-se uma distribuição mais eficiente de mamógrafos de forma a maximizar a cobertura de exames. Nesta versão, busca-se expandir o atendimento fracionado de uma cidade por meio de novas estruturas de vizinhanças. Para tratar o problema é proposto um algoritmo baseado na metaheurística *General Variable Neighborhood Search*. O algoritmo proposto avança pelo espaço de soluções explorando vizinhos gradativamente mais distantes por meio de trocas sistemáticas de estruturas de vizinhanças. Os resultados alcançados foram comparados com os de um algoritmo da literatura.

PALAVRAS CHAVE. Problema de Localização de Mamógrafos, *General Variable Neighborhood Search*, Localização de facilidades.

Tópicos: PO na Saúde, Metaheurísticas.

ABSTRACT

This work deals with the Mammography Unit Location Problem with partial care. This work aims to maximize the coverage for screenings through more efficient distribution of mammography units. In this version, we seek to expand the fractional service of a city through new neighborhood structures. An algorithm based on the metaheuristic *General Variable Neighborhood Search* is proposed to address the problem. The proposed algorithm advances through the solution space, exploring more distant neighborhoods gradually through systematic exchanges of neighborhood structures. The results achieved were compared with those of a literature algorithm.

KEYWORDS. Mammography Unit Location Problem. *General Variable Neighborhood Search*. Location Facility.

Paper topics: OR in Health, Metaheuristics.

1. Introdução

O câncer de mama é, entre a população feminina, o mais incidente no Brasil e no mundo, depois do câncer de pele não melanoma [INCA, 2022a]. Conforme dados estatísticos apresentados em INCA [2022b], estima-se uma incidência de 66.280 casos no Brasil para o ano de 2022, que representa 29,7% de todos os casos. Os casos de fatalidade também superam os dos demais tipos de câncer, sendo prevista para 2022 uma taxa de 13,6%. Podendo ser detectado, na maior parte dos casos, em sua fase inicial, o câncer de mama tem taxas de sucesso no tratamento satisfatórias, exigindo intervenções menos agressivas. Em vista disso, o Ministério da Saúde do Brasil recomenda que 58,9% mulheres entre 50 e 69 anos e 20% daquelas entre 40 e 49 anos devem realizar o exame anualmente [Brasil, 2017].

Estudos realizados por Miranda e Patrocínio [2018] apontam que, embora as redes pública e privada sejam equipadas com equipamentos suficientes para atender toda a população brasileira feminina, nem todas as mulheres têm acesso aos aparelhos. Amaral et al. [2017] apontam que, embora não seja o único fator, a distância entre a residência da mulher e o local de atendimento do exame de mamografia tem grande relevância para o desestímulo ou até mesmo para inviabilizar a realização do exame. Em 2015, o Ministério da Saúde estabeleceu como aceitável que essa distância fosse de, no máximo, 60 quilômetros [Amaral et al., 2017].

O Problema de Localização de Mamógrafos consiste em distribuir um conjunto de mamógrafos entre as cidades com infraestrutura para recebê-los e, na sequência, atender com exames as cidades sedes e as cidades pertencentes à região onde cada mamógrafo for instalado. O principal objetivo, em termos de distribuição de mamógrafos, é maximizar a cobertura de exames.

O presente trabalho trata o Problema de Localização de Mamógrafos (PLM) com atendimento parcial utilizando um algoritmo baseado na metaheurística *General Variable Neighborhood Search* (GVNS) [Hansen et al., 2017]. O método combina um procedimento de construção via a fase de construção do método *Greedy Randomized Adaptive Search Procedures* (GRASP) [Feo e Resende, 1995], com buscas locais feitas pelo procedimento *Variable Neighborhood Descent* (VND) [Mladenović e Hansen, 1997].

Souza et al. [2020] também tratam o PLM utilizando um algoritmo heurístico baseado no GVNS; entretanto, os autores não consideram o atendimento parcial da demanda de uma cidade. Ao contrário do presente trabalho, esses autores consideram que uma cidade ou é totalmente atendida ou não é atendida. Por sua vez, de Campos et al. [2020] solucionam o PLM utilizando um algoritmo baseado na metaheurística *Simulated Annealing* (SA). A abordagem desses autores considera uma solução contínua para o problema, admitindo também o atendimento de parte da demanda de uma determinada cidade. O algoritmo heurístico proposto foi testado em uma instância de Minas Gerais considerando diferentes cenários. Em um desses cenários admite-se a realocação dos equipamentos já existentes e considera-se a aquisição de novos equipamentos. Os autores mostraram que foi alcançada uma cobertura total em 713 municípios dos 853 existentes e cobertura parcial em outros 27. Os demais municípios não tiveram suas demandas atendidas com a alocação de mamógrafos fixos, uma vez que muitas cidades não têm infraestrutura hospitalar para sediar um equipamento de mamografia ou têm baixa demanda e estão distantes das cidades com infraestrutura.

Dentre as contribuições deste trabalho estão: a apresentação de uma nova representação computacional para o PLM com atendimento parcial e três novas estruturas de vizinhanças. Ao contrário de de Campos et al. [2020], que aglutina os atendimentos dos mamógrafos sediados em uma cidade, nesta nova representação os atendimentos de cada mamógrafo são individualizados.

O restante do trabalho está estruturado como segue. Na Seção 2 são apresentadas as principais características do problema. A Seção 3 é subdividida em cinco subseções. Na primeira

delas, Subseção 3.1, mostra-se como uma solução do problema é representada. Na Subseção 3.2 descreve-se a função de avaliação. A construção da solução inicial para o problema é apresentada na Subseção 3.3. Na sequência, Subseção 3.4, é descrito o algoritmo de refinamento, e na Subseção 3.5 são apresentadas as estruturas de vizinhança utilizadas pelo algoritmo proposto. Na Subseção 3.6 descreve-se o algoritmo proposto. Os resultados são apresentados na Seção 4. Por fim, na Seção 5, as conclusões e indicações de trabalhos futuros são apontadas.

2. Caracterização do problema

A partir de um conjunto de demandas por exames de mamografia e disponibilidade de equipamentos para o atendimento desta demanda, o PPLM consiste em indicar pontos candidatos a receber esses equipamentos de forma a aumentar a demanda atendida, respeitando a distância máxima entre a sede do equipamento e o ponto de demanda.

A Figura 1 ilustra o PLM em um cenário hipotético formado por dez cidades (A, B, C, D, E, F, G, H, I e J) e três mamógrafos disponíveis para alocação.




Figura 1: Exemplo de alocação

Na Figura 1, cada cidade tem uma demanda cujo valor é indicado como *dem*. Aquelas 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 tem capacidade para realizar 1000 exames anuais. Os mamógrafos M1 e M2 são instalados na cidade A, atendendo integralmente a demanda da cidade sede, restando um excedente de 1400 exames. O excedente do mamógrafo M1 atende integralmente a demanda das cidades B e D, e parcialmente a 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 déficit da cidade E; contudo, a distância entre as cidades A e E excede ao máximo permitido.

3. Metodologia

Esta seção apresenta a metodologia utilizada para a solução do PLM com atendimento parcial. O algoritmo proposto é baseado na metaheurística *General Variable Neighborhood Search* (GVNS) de Hansen et al. [2017]. A solução inicial é construída com base na fase de construção do algoritmo GRASP [Feo e Resende, 1995]. Para o refinamento da solução são utilizadas buscas

locais com estratégia *First Improvement* baseadas no procedimento VND, caracterizando, assim, o método GVNS.

3.1. Representação

Contrariamente a 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 PLM 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

(a) Representação da matriz x .

M1	M2	M3
A	A	H

(b) Representação do vetor y .

Figura 2: Representação da solução.

A Figura 2 ilustra uma instância da solução apresentada na Figura 1. A Figura 2(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 2(b) mostra o vetor y . Este vetor é preenchido com os identificadores das cidades onde cada mamógrafo está alocado.

3.2. Avaliação da Solução

São definidas duas funções de avaliação da solução: a primeira com base na função objetivo propriamente dita do problema, expressa pela Equação (1); e a segunda, a partir de uma função de avaliação expressa pela Equação (2). Na primeira equação é avaliada a cobertura de exames, dada pelo somatório da demanda atendida na solução. A segunda equação, por sua vez, 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.

$$z_1 = \max \sum_{k \in P} \sum_{j \in N} x_{kj} \quad (1)$$

$$z_2 = \max \sum_{k \in P} \sum_{j \in N} peso_j x_{kj} \quad (2)$$

Nas Equações (1) e (2), 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.

3.3. Construção da Solução Inicial

A construção da solução inicial é baseada na fase de construção da metaheurística GRASP. Na fase de construção do GRASP é utilizada uma estratégia gulosa aleatória, na qual são escolhidos os α melhores elementos de uma Lista de Candidatos (LC), formando uma Lista Restrita de Candidatos (LRC).

Algoritmo 1: *constroiSolucaoInicial(s, α)*

```

1  LC ← cidadesComInfraestrutura
2  LRC ← gereListaRestritaDeCandidatos(LC,  $\alpha$ )
3  enquanto (houverMamografo) faça
4      i ← selecioneUmaCidadeAleatoria(LRC)
5      aloqueMamografo(s, i)
6      atualizeLRC(LC)
7  fim
8  enquanto (houverMamografo) faça
9      LC ← cidadesRegiaoSedeMamografo
10     RCL ← gereListaRestritaDeCandidatos(LC,  $\alpha$ )
11     enquanto houverExameDisponivel faça
12         i ← selecioneUmaCidadeAleatoria(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 1. 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 α melhores candidatos da LC são colocados na Lista Restrita de Candidatos (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 α 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.

3.4. Busca Local

A busca local é feita por meio do método VND [Hansen et al., 2017]. Seu pseudocódigo é descrito pelo Algoritmo 2.

Algoritmo 2: VND_PLM($k_{\max}$, $iter_{\max}$, 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  $s$ 

```

O Algoritmo VND_PLM 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 3.5, 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.


3.5. Estruturas de Vizinhança

O espaço de soluções do PLM 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 remover um mamógrafo de uma cidade e alocá-lo a outra.

A Figura 3(a) ilustra a aplicação dessa vizinhança em 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 estão 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 3(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.

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 4. Como pode ser observado na Figura 4, ao aplicar o movimento Realoca Atendimento Intra Mamógrafo sobre o cenário apresentado na Figura 3(b), 50 atendimentos são realocados da cidade D para a



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



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

Figura 3: Exemplo das estruturas de vizinhança Realoca Mamógrafo e Realoca Atendimento Intra Mamógrafo.

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 (2). 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.

A terceira estrutura, por sua vez, é obtida com o movimento Realoca Atendimento Inter Mamógrafo, que remove 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 foi definido utilizando a




Figura 4: Exemplo do movimento Realoca Atendimento Intra Mamógrafo




Figura 5: Exemplo do movimento Realoca Atendimento Inter Mamógrafo

ferramenta Irace. A Figura 5 mostra o resultado da aplicação do movimento Realoca Atendimento Inter Mamógrafo sobre a Figura 4, na qual 50 atendimentos da cidade F realizados pelo mamógrafo M2 passam a ser realizados pelo mamógrafo M3. 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 (2).

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 5, obtemos o grafo representado pela Figura 6, na qual 50 atendimentos da cidade D passam a ser feitos pelo mamógrafo 2, elevando a função objetivo de 2950 para 3000 atendimentos.

3.6. Algoritmo GVNS proposto

Para tratar o problema, foi proposto um algoritmo baseado na metaheurística GVNS, cujo pseudocódigo é apresentado no Algoritmo 3.




Figura 6: Exemplo do movimento Busca Atendimento

Algoritmo 3: GVNS_PLM(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          VND_PLM( $s'$ )
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_PLM 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 é gerada na k -ésima vizinhança (*shake* - linha 5), esta solução é refinada pela 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. Resultados

O algoritmo proposto foi implementado em C++. Os testes foram realizados em uma máquina virtual com as seguintes configurações: processador de 16 núcleos e 8 GB de memória

RAM, Sistema Operacional Ubuntu 20.04, virtualizada em um servidor com processador Xeon(R) v3 2.30 GHz, 110 GB de Memória RAM.

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 atual de 353 equipamentos de mamografia, a capacidade de realização de 6758 exames anuais, e atualizadas as demandas por exames no período.

Dado seu caráter estocástico, o algoritmo GVNS_PLM 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 *Simulated Annealing*, denotado por SA_PLM, desses autores. Para uma comparação justa, todos os métodos de solução foram testados na mesma máquina.

Para calibração dos parâmetros do algoritmo proposto 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 1. Nesta tabela, α representa o tamanho da lista restrita de candidatos utilizada no Algoritmo 1, ITER_MAX indica o número máximo de iterações sem melhora do Algoritmo 3 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 1: Valores dos parâmetros testados e retornados pelo *Irace*

Parâmetros	Valores Testados	Valores Retornados
α	[2, 5]	4
ITER_MAX	[20, 50]	39
E_INTER	[1, 10]	5
E_INTRA	[1, 10]	2

A Tabela 2 reporta a comparação de resultados entre os métodos CPLEX, *Simulated Annealing* [de Campos et al., 2020] e o proposto neste trabalho aplicados ao PLM. 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 *Simulated Annealing*, 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 (3), e o tempo de processamento consumido em cada instância, em segundos. Os resultados alcançados pelo algoritmo GVNS_PLM são exibidos da oitava à décima segunda coluna e seguem a mesma ordem de apresentação do algoritmo SA_PLM. Os melhores resultados são destacados em negrito. Os valores de GAP são calculados com base na Equação (3), 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_PLM ou o GVNS_PLM) na instância i e $CPLX_i$ é o resultado retornado pelo resolvidor CPLEX na instância i em no máximo uma hora de processamento.

$$gap_i^{Alg} = \frac{CPLX_i - f_{o_i}^{Alg}}{CPLX_i} \quad (3)$$

Tabela 2: Comparação entre os resultados dos métodos *Simulated Annealing* e GVNS aplicados ao PLM

Instância	CPLEX	SA_PLM					GVNS_PLM				
		Melhor	Média	GAP do Melhor (%)	GAP da Média (%)	Tempo (s)	Melhor	Média	GAP do Melhor (%)	GAP da Média (%)	Tempo (s)
MG_324_0.5069	1642034	1641261	1640187	0,05	0,11	59	1640872	1639503	0,07	0,15	4483
MG_344_375_5069	1706321	1698418	1693794	0,46	0,73	59	1703829	1696074	0,15	0,60	6040
MG_324_0.6758	1739432 ⁽¹⁾	1739432	1738794	0,00	0,04	52	1739432	1738997	0,00	0,03	2249
MG_324_375_6758	1738872 ⁽²⁾	1738063	1736403	0,05	0,14	51	1737890	1735553	0,06	0,19	1610
MG_353_375_6758	1733024 ⁽³⁾	1731325	1729810	0,10	0,19	45	1729414	1727835	0,21	0,30	222

⁽¹⁾ Obtido em 14 segundos; ⁽²⁾ Obtido em 9 segundos; ⁽³⁾ Obtido em 10 segundos

Como pode ser observado na Tabela 2, 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. Já na instância MG_324_0.6758, o algoritmo proposto encontra a solução ótima e seu resultado médio supera o do algoritmo SA_PLM. Destaca-se que em todas as instâncias, para as melhores execuções do GVNS_PLM, 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 *Simulated Annealing*. Os tempos computacionais demandados pelo algoritmo proposto são, no entanto, bem maiores do que os dos outros métodos de solução.

5. Conclusões e trabalhos futuros

Este trabalho tratou o Problema de Localização de Mamógrafos utilizando um algoritmo baseado na metaheurística *General Variable Neighborhood Search*. Nos experimentos computacionais realizados foram utilizados dados de instâncias do estado de Minas Gerais, sendo quatro delas utilizadas em de Campos et al. [2020] e outra com dados atualizados para o estado, relativos ao mês de outubro de 2021. Os resultados obtidos pelo algoritmo proposto foram comparados com aqueles obtidos pelo algoritmo *Simulated Annealing* proposto em de Campos et al. [2020] e também com o resultado da aplicação do resolvidor CPLEX à formulação proposta por esses autores. Os resultados mostraram que o algoritmo proposto foi capaz de encontrar o valor ótimo em uma instância e nas demais o gap da melhor solução foi inferior a 0,21%. Já com relação ao gap da média dos resultados, este foi inferior a 0,60%. Comparando com o algoritmo *Simulated Annealing* proposto em de Campos et al. [2020], o algoritmo proposto teve desempenho melhor em duas instâncias. Desta forma, verifica-se que o algoritmo proposto representa uma alternativa de solução para o PLM com atendimento parcial. No entanto, o algoritmo proposto demanda um tempo computacional muito maior do que os demais métodos de solução.

Para a continuidade deste estudo, propõe-se: (i) identificar novas estruturas de vizinhança que permitam explorar melhor o espaço de soluções do problema de forma a aumentar a cobertura de exames; (ii) buscar estratégias para reduzir o tempo de processamento do algoritmo proposto e (iii) rotear unidades móveis de mamografia para atendimento dos exames não contemplados pelos mamógrafos fixos.

Agradecimentos

Os autores registram seus agradecimentos ao CEFET-MG, ao IFMG, à UFOP, à UFV, ao IFB e às agências CNPq (processos 303266/2019-8 e 428817/2018-1), FAPEMIG (processo PPM-CEX 676/17) e CAPES (código de financiamento 001), pelo apoio ao desenvolvimento deste trabalho.

Referências

- Amaral, P., Luz, L., Cardoso, F., e Freitas, R. (2017). Distribuição espacial de equipamentos de mamografia no Brasil. *Rev. Bras. de Estudos Urbanos e Regionais (RBEUR)*, 19(2):326–341.
- Brasil (2017). 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. Disponível em <https://bit.ly/30D04Rj>. Acesso em 24/06/2022.
- de Campos, M. V. A., de Sá, M. V. S. M., Rosa, P. M., Penna, P. H. V., de Souza, S. R., e Souza, M. J. F. (2020). A mixed linear integer programming formulation and a simulated annealing algorithm for the mammography unit location problem. In *Proc. of the 22nd International Conference on Enterprise Information Systems*, p. 428–439, Setúbal, Portugal. Scitepress Digital Library.
- Feo, T. A. e Resende, M. G. (1995). Greedy randomized adaptive search procedures. *Journal of Global Optimization*, 6(2):109–133.
- Hansen, P., Mladenović, N., Todosijević, R., e Hanafi, S. (2017). Variable neighborhood search: basics and variants. *EURO Journal on Computational Optimization*, 5(3):423–454.
- INCA (2022a). Conceito e magnitude do câncer de mama. Instituto Nacional do Câncer. Disponível em <https://www.inca.gov.br/controlado-cancer-de-mama/conceito-e-magnitude>. Acesso em 14/05/2022.
- INCA (2022b). Estatísticas de câncer. Instituto Nacional do Câncer. Disponível em <https://www.inca.gov.br/numeros-de-cancer>. Acesso em 14/05/2022.
- López-Ibáñez, M., Dubois-Lacoste, J., Pérez Cáceres, L., Stützle, T., e Birattari, M. (2016). The irace package: Iterated racing for automatic algorithm configuration. *Operations Research Perspectives*, 3:43–58.
- Miranda, S. e Patrocínio, A. (2018). Distribuição de mamógrafos por macrorregião do Brasil. In *V Congresso Brasileiro de Eletromiografia e Cinesiologia e X Simpósio de Engenharia Biomédica*, p. 433–436, Ribeirão Preto. Associação Brasileira de Física Médica.
- Mladenović, N. e Hansen, P. (1997). Variable neighborhood search. *Computers & Operations Research*, 24(11):1097–1100.
- Souza, M. J. F., Penna, P. H. V., Moreira de Sá, M. V. S., e Rosa, P. M. (2020). A VNS-based algorithm for the mammography unit location problem. In Benmansour, R., Sifaleras, A., e Mladenović, N., 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*, chapter 3, p. 37–52. Springer, Cham, Switzerland.