

UM ALGORITMO *ITERATED GREEDY 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

¹Programa 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, marcone@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 problema, busca-se uma distribuição mais eficiente dos equipamentos de mamografia de modo a maximizar a cobertura de exames. Na versão tratada, considera-se que uma cidade que sedia um equipamento pode atender parcialmente outra cidade. Para tratar o problema, é proposto um algoritmo baseado na metaheurística *Iterated Greedy Search*. O algoritmo proposto explora o espaço de soluções por meio de iterações de destruição, reconstrução e refinamento aplicadas à solução corrente. Os resultados obtidos foram comparados com os de um algoritmo da literatura.

PALAVRAS CHAVE. Problema de Localização de Mamógrafos, *Iterated Greedy Search*, Decida em Vizinhança Variável.

Tópicos: PO na Área de Saúde, Metaheurísticas

ABSTRACT

This paper addresses the Mammography Unit Location Problem with partial attendance. In this problem, we seek a more efficient distribution of mammography equipment to maximize mammography screening coverage. In the treated version, we consider that a city that hosts equipment can partially serve another city. To deal with the problem, we develop an algorithm based on the *Iterated Greedy Search* metaheuristic. It explores the problem's solution space through destruction, reconstruction, and refinement iterations applied to the actual solution. We compared its results with those of a literature algorithm.

KEYWORDS. Mammography Unit Location, *Iterated Greedy*, Variable Neighborhood Descent.

Paper topics: OR in Health, Metaheuristics

1. Introdução

O câncer de mama é o segundo tipo de câncer mais comum no Brasil, perdendo apenas para os tumores de pele não melanomas, conforme aponta o Instituto Nacional do Câncer (INCA). Em 2018, 17572 mulheres foram vitimadas por este tipo de câncer. Em 2019, o câncer de mama foi a primeira causa de morte por câncer na população brasileira feminina. Em 2020, foi estimada uma taxa de incidência de 43,74 casos por 100 mil mulheres [INCA, 2021].

O câncer de mama, quando diagnosticado nos estágios iniciais, apresenta uma taxa superior a 95% de sobrevivência [Witten e Parker, 2018]. Neste contexto, Xavier e et al [2016] afirmam que a mamografia é a principal ferramenta para detecção da doença em sua fase inicial. Portanto, por recomendação do Ministério da Saúde, mulheres na faixa etária entre 50 e 59 anos devem realizar o exame bianualmente. Por indicação diagnóstica, 8,9% desta faixa etária e 20% da população feminina entre 40 e 49 anos de idade devem realizar o exame anualmente. Dessa maneira, 58,9% das mulheres entre 50 e 69 anos e 20% daquelas entre 40 e 49 anos devem realizar o exame anualmente.

Miranda e Patrocínio [2018] e Amaral et al. [2017] mostram que, embora a rede pública e privada brasileira tenham disponibilidade satisfatória de mamógrafos, os exames não estão acessíveis a todas as mulheres. A determinação do Ministério da Saúde (2015), que define a distância máxima aceitável entre o mamógrafo e a mulher como 60 KM, é um dos fatores apontados como causa. O trabalho de Amaral et al. [2017] constata que existem municípios que concentram um excesso de oferta de exames, enquanto outros não dispõem de mamógrafos no raio de 60 KM. Embora existam outros fatores que contribuem para o desestímulo ou até mesmo inviabilização do exame, o estudo mostra que o deslocamento tem papel fundamental no acesso ao exame.

O presente trabalho aborda o Problema de Localização de Mamógrafos (PLM) utilizando um algoritmo heurístico baseado na metaheurística *Iterated Greedy Search* [Ruiz e Stützle, 2008]. Este procedimento consiste em gerar uma solução inicial, aplicar refinamento e, em seguida, aplicar iterativamente métodos de destruição, reconstrução e refinamento. Ao final de cada iteração, um critério de aceitação decide se o método deve continuar e a solução corrente é atualizada. Os resultados obtidos são comparados com os alcançados por de Campos et al. [2020], que utiliza um algoritmo baseado na metaheurística *Simulated Annealing*.

Souza et al. [2019] fizeram um estudo de caso do PLM no Estado de Rondônia. Eles apresentaram duas formulações de programação matemática. Na primeira, uma cidade pode ser atendida somente se sua cobertura for integral, enquanto na segunda formulação permite-se uma cobertura parcial. Um estudo de caso relativo ao PLM aplicado ao Estado de Minas Gerais é apresentado em Souza et al. [2020]. Nesse trabalho foi utilizado um algoritmo baseado na metaheurística *Variable Neighborhood Search* (VNS), além de uma nova formulação matemática. Já o trabalho de Andrade de Campos et al. [2020] desenvolveu um algoritmo heurístico baseado na metaheurística *Simulated Annealing* e analisou cenários de possíveis aquisições de novos mamógrafos. Todos esses trabalhos buscam uma melhor distribuição dos equipamentos de mamografia, distinguindo-se entre si no método de solução, modelagem e estudo de caso. Todos têm, como ponto em comum, o objetivo de maximizar a cobertura de mamografias, fundamentando-se nos problemas clássicos de Localização da Máxima Cobertura [Church e Velle, 1974].

A abordagem primordial, no contexto da distribuição de mamógrafos, é aumentar a cobertura de exames. Em seu trabalho, de Campos et al. [2020] propõe uma formulação matemática para representar o PLM. A formulação apresentada por de Campos et al. [2020] considera uma solução contínua para o problema, admitindo o atendimento parcial de uma determinada cidade. Dado que o PLM é NP-difícil, o que em geral inviabiliza a resolução de instâncias maiores em tempo de tomada de decisão, nesse mesmo trabalho é proposto um algoritmo heurístico baseado na meta-heurística

Simulated Annealing. Os autores testaram a formulação e o algoritmo heurístico em uma instância do estado de Minas Gerais, em diferentes cenários. No melhor desses cenários, no qual é considerada a aquisição de novos mamógrafos e a liberdade de realocação dos já existentes para o Estado de Minas Gerais, chegou-se à cobertura total em 713 municípios (dentre os 853 existentes no Estado), cobertura parcial em outros 27, enquanto 113 cidades não tiveram suas demandas atendidas com a alocação dos mamógrafos fixos, em função das restrições de distância impostas e de infraestrutura mínima necessária para sediar equipamentos de mamografia.

O restante deste trabalho está estruturado como segue. A Seção 2 apresenta a caracterização do problema, explicitando os conceitos e dados utilizados em sua formulação. A Seção 3 descreve a metodologia adotada, mostrando a representação computacional adotada; a construção da solução inicial; a função de avaliação; as estruturas de vizinhança; e o detalhamento dos algoritmos propostos para a solução do problema. A Seção 4 apresenta os resultados computacionais encontrados e, por fim, a Seção 5 conclui este artigo.

2. Caracterização

Dado um conjunto de mamógrafos, um conjunto de possíveis locais de instalação destes equipamentos e um conjunto de locais a serem atendidos por eles, o Problema de Distribuição Espacial de Mamógrafos (PLM) consiste em determinar quais pontos candidatos receberão o equipamento, de forma que o máximo de pontos de demanda sejam atendidos, respeitando-se uma distância máxima de 60 quilômetros entre o ponto de demanda e os locais de instalação dos mamógrafos.

A Figura 1 ilustra o PLM em uma região hipotética envolvendo 5 cidades (A, B, C, D, e E) e um único mamógrafo disponível para alocação.

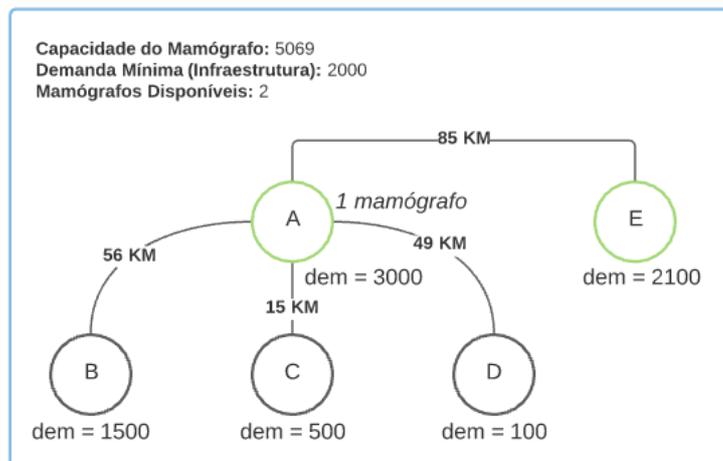


Figura 1: Exemplo de alocação

Na Figura 1, cada cidade tem uma demanda cujo valor é indicado na figura como *dem*. Neste exemplo, o mamógrafo tem capacidade anual de atender a 5069 exames e as cidades A e E são candidatas a sediar o mamógrafo, pois possuem a demanda mínima necessária, critério estabelecido para que uma cidade seja definida como tendo infraestrutura hospitalar. O mamógrafo disponível, neste exemplo, é capaz de atender integralmente a demanda de A, gerando uma capacidade ociosa de 2069 exames. Esta capacidade ociosa pode ser utilizada para atender as cidades situadas a uma distância máxima de 60 km da cidade A. Neste caso, as cidades B e C podem ser atendidas

integralmente, enquanto a cidade D pode ter sua demanda atendida parcialmente em 69 exames. A cidade E não pode ser atendida pela cidade A, ainda que esta possuísse sobra de exames após os atendimentos anteriores, pois a distância entre estas duas cidades ultrapassa a distância máxima estipulada.

3. Metodologia

Esta seção apresenta a metodologia utilizada na solução do PLM. O algoritmo proposto é baseado na metaheurística *Iterated Greedy Search*. A solução inicial é gerada a partir de uma construção gulosa, distribuindo os aparelhos de mamografia conforme a demanda regional de cada cidade. Para o refinamento da solução é utilizada uma busca local VND, descrita na Subseção 3.5. As estruturas de vizinhança utilizadas são apresentadas na Subseção 3.4.

3.1. Representação

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

	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 2: Representação da solução.

A Figura 2 ilustra uma instância da solução descrita na Figura 1. A Figura 2(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 zero (referente à cidade A) é atribuído o valor zero (0), indicando que a cidade A não atende nenhuma demanda da cidade E. A Figura 2(b), por sua vez, representa o vetor y . Este vetor é preenchido por valores correspondentes ao número de mamógrafos alocados na cidade i . Note que o índice zero (0), correspondente à cidade A, possui valor 1, indicando que a cidade A possui um mamógrafo.

3.2. Função de Avaliação

Uma solução é avaliada com base na função objetivo expressa pela Equação (1). Nesta expressão é avaliada a cobertura de exames, dada pelo somatório da demanda atendida na solução.

$$\max \sum_{i \in N} \sum_{j \in S_i} dem_j \cdot x_{ij} \quad (1)$$

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 .

3.3. Solução Inicial

A solução inicial é determinada conforme descrito pelo Algoritmo 1.

Algoritmo 1: solucaoInicial(*dados*)

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

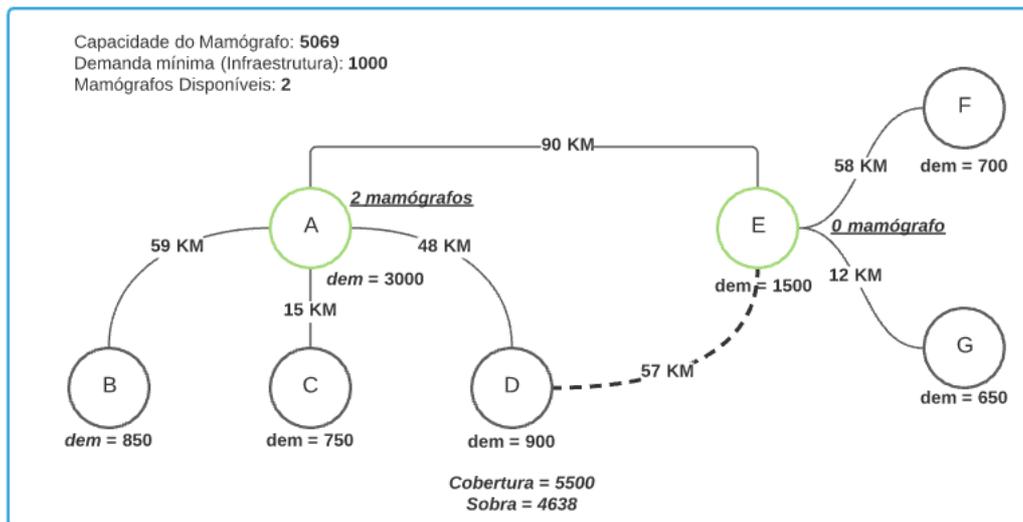
Na linha 2 do Algoritmo 1 é escolhida uma cidade para atendimento, tendo, como base, sua demanda regional. A demanda regional é definida aqui como a soma das demandas das cidades pertencentes à região da cidade escolhida. Uma região é o conjunto das cidades com distância máxima de 60 km em relação a 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, este vínculo é desfeito, gerando uma lista de cidades que atendiam à 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 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_{ij} , a fração correspondente ao atendimento da cidade i .

3.4. Estruturas de Vizinhança

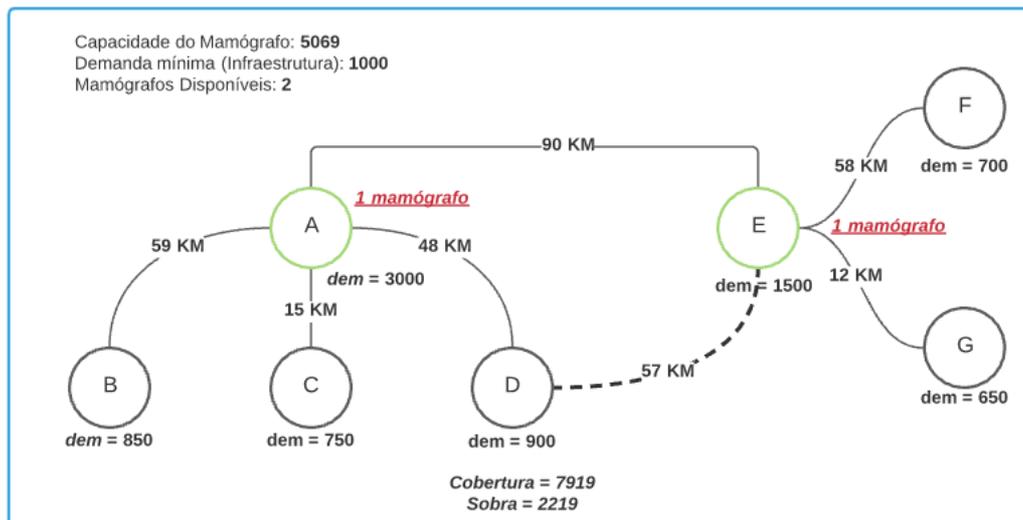
O espaço de soluções do PLM é explorado por meio de duas estruturas de vizinhança: Realoca Mamógrafo e Realoca Exames Atendidos. A primeira estrutura de vizinhança é obtida a partir do movimento realocar mamógrafo, que retira um mamógrafo de uma cidade e o coloca em outra cidade. A segunda estrutura de vizinhança consiste em realocar exames atendidos por uma

cidade para outra cidade que tenha capacidade de atendimento disponível. As Figuras 3 e 4 ilustram estes dois movimentos.

A Figura 3(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..

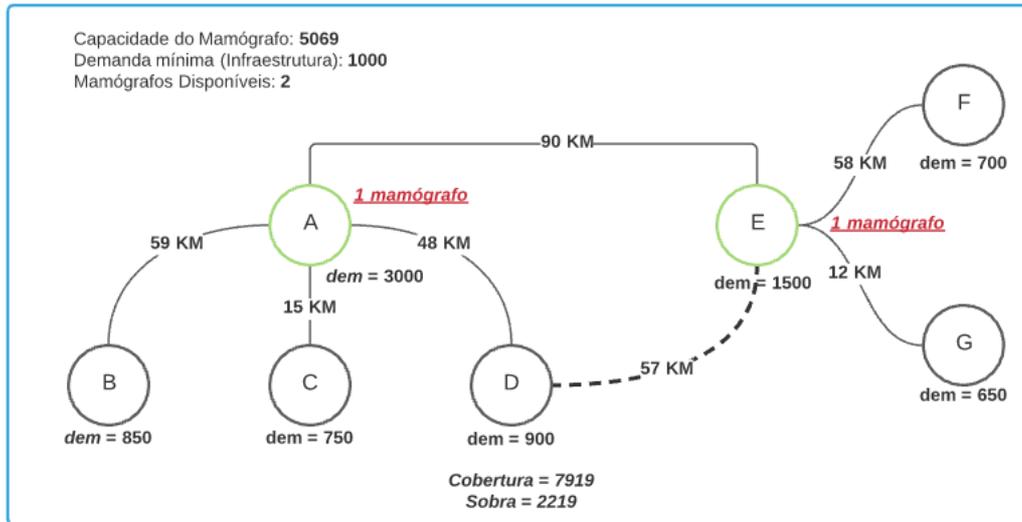


(b) Representação da solução após a aplicação da estrutura de vizinhança Realoca Mamógrafo.

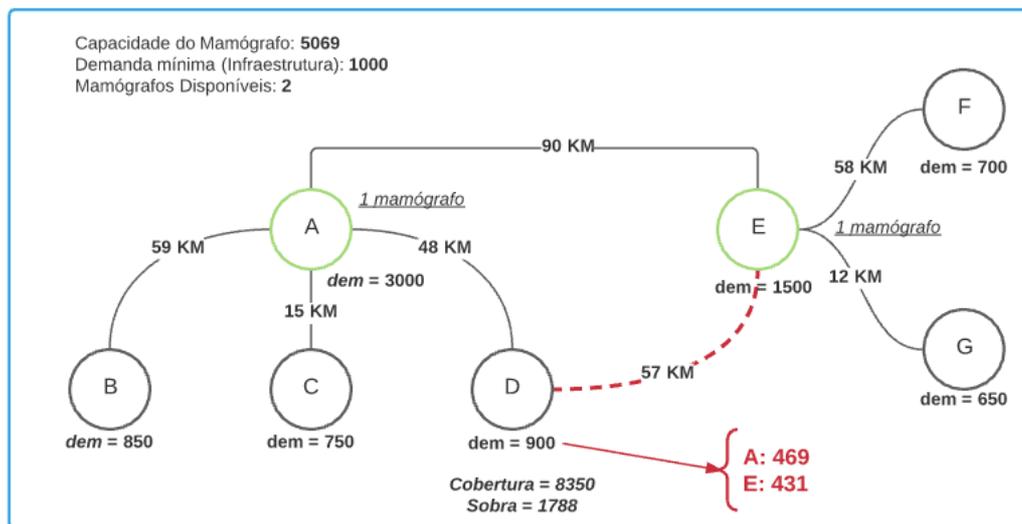
Figura 3: Um exemplo da estrutura de vizinhança Realoca Mamógrafo.

Aplicando o primeiro movimento, um mamógrafo é realocado da cidade A para a cidade E, gerando a solução vizinha apresentada na Figura 3(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.

O segundo movimento 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) 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: Um exemplo da estrutura de vizinhança Realoca Exames Atendidos.

A Figura 4(b) ilustra a solução após a aplicação do movimento Realocar Exames Aten-

dados na solução da Figura 4(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 3 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.

3.5. Algoritmo Proposto

Para tratar o problema foi desenvolvido um algoritmo baseado na metaheurística *Iterated Greedy Search* (IGS). Seu pseudocódigo é apresentado no Algoritmo 2.

Algoritmo 2: $IGS(dados, parada, nivel_{max}, k_{max})$

```
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
```

Inicialmente, na linha 1 do Algoritmo 2, é gerada a solução inicial conforme descrito na Seção 3.3. Na linha 2 a solução é refinada utilizando o Método de Descida em Vizinhança Variável (*Variable Neighborhood Descent* – VND) com a estratégia *First Improvement*, descrito pelo pseudocódigo do Algoritmo 3. O método VND explora o espaço de soluções pela troca sistemática de vizinhanças. As vizinhanças utilizadas são as apresentadas na Seção 3.4, 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.

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 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 que a solução atual s , esta solução é atualizada. A execução do algoritmo é encerrada com base no tempo demandado pelo algoritmo *Simulated Annealing* (SA) proposto em Campos [2020].

Algoritmo 3: 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  $s$ 
```

4. Resultados

O algoritmo 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 pelo algoritmo proposto foram comparados com aqueles obtidos pelo *Cplex* e pelo algoritmo proposto por de Campos et al. [2020], utilizando o método *Simulated Annealing* (SA). Para uma comparação justa, todos os métodos de solução foram testados no mesmo computador.

As instâncias utilizadas 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.

A Tabela 1 apresenta os resultados obtidos pelo CPLEX. A Tabela 2 compara os resultados encontrados pelo algoritmo proposto com aqueles obtidos pelo método *Simulated Annealing* (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. Já 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, o valor médio em 10 execuções do método SA, o *gap* do melhor valor, o *gap* do valor médio, calculados conforme Eq. (2), e o tempo demandado por esse algoritmo, em segundos. A quinta e sexta colunas reportam o melhor valor e o 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.

$$gap_i^{Alg} = \frac{UB_i - f o_i^{Alg}}{UB_i} \quad (2)$$

Na Equação (2), $f o_i^{Alg}$ 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 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 2: Comparação entre os resultados dos métodos *Simulated Annealing* e IGS

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

Como pode ser observado na Tabela 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 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 apresentou um *gap* de apenas 0,03% no melhor caso e 0,06% na média.

5. Conclusão

Este trabalho tratou o Problema de Localização de Mamógrafos utilizando um algoritmo heurístico baseado na metaheurística *Iterated Greedy Search*. Para testá-lo, foram utilizadas instâncias baseadas em dados do estado de Minas Gerais. Os resultados obtidos pelo algoritmo proposto foram comparados com os gerados pelo algoritmo *Simulated Annealing* desenvolvido por de Campos et al. [2020]. Embora o algoritmo IGS tenha alcançado desempenho inferior ao do *Simulated Annealing*, o *gap* obtido, considerando os resultados médios, é pequeno, de no máximo 0,43%. Esses resultados mostram que é necessário melhorar o desempenho do algoritmo proposto. Para isso, sugere-se estudar a inclusão de outras estruturas de vizinhança no método VND, novas formas de gerar solução inicial, nova forma de representação computacional, considerando mamógrafos com diferentes capacidades operacionais, bem como fazer um projeto de experimentos para calibrar os parâmetros do algoritmo.

Agradecimentos

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES, código de financiamento 001), à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG, processo PPM CEX 676/17), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq, processo 303266/2019-8), ao Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG), à Universidade Federal de Ouro Preto (UFOP), Universidade Federal de Viçosa (UFV), Instituto Federal de Minas Gerais (IFMG) e Instituto Federal do Triângulo Mineiro (IFTM), 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. *Revista Brasileira de Estudos Urbanos e Regionais (RBEUR)*, 19(2):326–341.
- Andrade de Campos, M. V., 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 *Proceedings of the International Conference on Enterprise Information Systems (ICEIS)*, volume 1, p. 428–439, Online. Scitepress.
- Campos, M. V. A. d. (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.
- Church, R. e Velle, C. R. (1974). The maximal covering location problem. *Papers of the Regional Science Association*, 32:101–118.
- de Campos, M. V. A., Moreira 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 *Proceedings of the 22nd International Conference on Enterprise Information Systems (ICEIS 2020)*, volume 1, p. 428–439, Online. SCITEPRESS.
- INCA (2021). Conceito e magnitude do câncer de mama. Instituto Nacional do Câncer. <https://www.inca.gov.br/controlado-cancer-de-mama/conceito-e-magnitude>. Acesso em 20/03/2021.
- 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.
- Ruiz, R. e Stützle, T. (2008). An iterated greedy heuristic for the sequence dependent setup times flowshop problem with makespan and weighted tardiness objectives. *European Journal of Operational Research*, 187(3):1143 – 1159.
- 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. In *LI Simpósio Brasileiro de Pesquisa Operacional*, volume 2, Campinas. Galoá.
- 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.
- Witten, M. e Parker, C. C. (2018). Screening mammography recommendations and controversies. *Surgical Clinics of North America*, 98(4):667–675.
- Xavier, D. R. e et al (2016). Cobertura de mamografias, alocação e uso de equipamentos nas regiões de saúde. *Saúde em debate*, 40(110):20–35.