

Algoritmos heurísticos para o Problema de Roteamento de Unidades Móveis de Mamografia

Otávio Augusto Souza Rosa
Universidade Federal de Ouro Preto

Orientadores: Marcone Jamilson Freitas Souza

Puca Huachi Vaz Penna



UNIVERSIDADE FEDERAL DE OURO PRETO

Algoritmos heurísticos para o Problema de Roteamento de Unidades Móveis de Mamografia

Otávio Augusto Souza Rosa
Universidade Federal de Ouro Preto

Orientadores: Marcone Jamilson Freitas Souza
Puca Huachi Vaz Penna

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Ouro Preto, como parte dos requisitos necessários à obtenção do título de Mestre em Ciência da Computação.

Ouro Preto, Abril de 2021

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

R788a Rosa, Otávio Augusto Souza .
Algoritmos heurísticos para o problema de roteamento de unidades móveis de mamografia. [manuscrito] / Otávio Augusto Souza Rosa. - 2021.

48 f.: il.: , gráf., tab., mapa. + Algoritmos.

Orientador: Prof. Dr. Marccone Jamilson Freitas Souza.

Coorientador: Prof. Dr. Puca Huachi Vaz Penna.

Dissertação (Mestrado Acadêmico). Universidade Federal de Ouro Preto. Departamento de Computação. Programa de Pós-Graduação em Ciência da Computação.

Área de Concentração: Ciência da Computação.

1. Mamografia. 2. Veículos - Roteamento. 3. Logística - Saúde. I. Penna, Puca Huachi Vaz. II. Souza, Marccone Jamilson Freitas. III. Universidade Federal de Ouro Preto. IV. Título.

CDU 004:61

Bibliotecário(a) Responsável: Celina Brasil Luiz - CRB6-1589



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE OURO PRETO
REITORIA
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS
DEPARTAMENTO DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO



FOLHA DE APROVAÇÃO

Otávio Augusto Souza Rosa

Algoritmos heurísticos para o problema de roteamento de unidades móveis de mamografia

Dissertação apresentada ao Programa de Pós Graduação em Ciência da Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Mestre em Ciência da Computação.

Aprovada em 22 de abril de 2021

Membros da banca

Prof. Dr. Marcone Jamilson Freitas Souza - Orientador - Universidade Federal de Ouro Preto
Prof. Dr. Puca Huachi Vaz Penna - Co-orientador - Universidade Federal de Ouro Preto
Prof. Dr. Igor Machado Coelho - Universidade Federal Fluminense
Prof. Dr. Marco Antonio Moreira de Carvalho - Universidade Federal de Ouro Preto

Prof. Dr. Marcone Jamilson Freitas Souza, orientador do trabalho, aprovou a versão final e autorizou seu depósito no Repositório Institucional da UFOP em 27/05/2021



Documento assinado eletronicamente por **Puca Huachi Vaz Penna, COORDENADOR(A) DO CURSO DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**, em 14/06/2021, às 16:12, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0181163** e o código CRC **8C7C09D6**.

Dedico este trabalho à todas as mulheres que lutam contra o câncer de mama.



Agradecimentos

À minha mãe e ao meu pai, que não mediram esforços para que eu pudesse prosseguir com os meus estudos.

À minha família, que é meu maior orgulho, por todo o apoio e carinho.

Aos meus orientadores, Marcone e Puca, nos quais eu me inspiro e tenho profunda admiração.

As minhas amigas que eu amo tanto, pelo cuidado e companheirismo.

Aos professores e colegas do Programa de Pós-Graduação em Ciência da Computação da UFOP pelo conhecimento compartilhado e por contribuírem para a minha formação.

Ao Hospital do Câncer de Patrocínio Dr. José Figueiredo por nos fornecer as informações que foram essenciais para o desenvolvimento deste trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES), pelo apoio financeiro dado à este trabalho.

À Universidade Federal de Ouro Preto (UFOP), à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) por todo o suporte prestado.

À Deus, por tudo.

Resumo

Este trabalho introduz o Problema de Roteamento de Unidades Móveis de Mamografia (MMURP). Este problema consiste em roteirizar um conjunto de Unidades Móveis de Mamografia (MMU) para atender a demanda de localidades desprovidas de mamógrafos fixos ou com número insuficiente deles. O objetivo é maximizar a demanda atendida e minimizar a distância total percorrida pelas MMUs. Para tratar o problema, propomos os algoritmos *Smart IGS-VND* e *Smart IGS-RVND*, ambos baseados na metaheurística *Iterated Greedy Search*. Nestes algoritmos, uma solução inicial é gerada por meio de um procedimento de três passos. Para refinar uma solução, usamos os procedimentos *Randomized Variable Neighborhood Descent (RVND)* e *Variable Neighborhood Descent (VND)*. Para não ficar preso em ótimos locais e explorar diferentes regiões do espaço de soluções do problema, aplicamos um procedimento para destruir a solução atual e outro para construí-la de forma gulosa. Para testar os algoritmos propostos, usamos instâncias com 579 localidades, dois depósitos, até 56 MMUs e 180 km entre dois locais no máximo. Realizamos os testes considerando três cenários diferentes. Esses cenários diferem entre si pelo número de localidades candidatas a serem atendidas, o número de MMUs disponíveis em cada depósito e a capacidade dessas MMUs. Os resultados mostraram que os dois algoritmos encontraram soluções que atendem integralmente a demanda da região estudada. O *Smart IGS-VND* obteve um melhor desempenho para encontrar um valor alvo de demanda previamente definido. No entanto, quando foram comparadas a distância total percorrida pelas MMUs com a cobertura de exames, o *Smart IGS-RVND* mostrou ser capaz de encontrar soluções de melhor qualidade, reduzindo a distância total percorrida pelos veículos. No último cenário, apresentamos um plano de serviço mensal para uma MMU, variando de um a doze meses.

Palavras-chave: Unidades Móveis de Mamografia, Roteamento de Veículos, Roteamento de Veículos Multi-depósito, Logística na Área de Saúde.

Abstract

This work introduces the Mobile Mammography Units Routing Problem (MMURP). This problem consists of defining routes for a set of Mobile Mammography Units (MMU) to cover the demand of locations without fixed mammography units or with an insufficient number of them. The objective is to maximize the demand attended and minimize the total distance traveled by the MMUs. To treat the problem, we propose two algorithms, named Smart IGS-VND and Smart IGS-RVND, which are based on the Iterated Greedy Search metaheuristic. We generated an initial solution through a three-phase procedure. We used the Randomized Variable Neighborhood Descent (RVND) and Variable Neighborhood Descent (VND) methods to refine the solution. To not get stuck in the local optimum and explore different regions of this search space, we applied one procedure to destroy the current solution and another to construct it greedily. To test the proposed algorithms, we used instances with 579 locations, two depots, up to 56 MMUs, and 180 km between two locations at maximum. We performed the tests considering three different scenarios. These scenarios differ from each other concerning the number of candidate locations to be attended, the number of MMUs available in each deposit, and the capacity of these MMUs. The results showed that the algorithms found solutions that reach the whole demand of the studied area. The Smart IGS-VND algorithm had a better performance to find a target value of demand previously defined. However, when we compare the total distance traveled by the MMUs with the exam coverage, the Smart IGS-RVND showed to be able to find better quality solutions, reducing the total distance traveled by the vehicles. In the last scenario, we present a monthly MMU service plan, ranging from one to twelve months.

Keywords: Mobile Mammography Units, Vehicle Routing, Multi-depot Vehicle Routing, Logistics in Health Area.

Sumário

1	Introdução	1
1.1	Objetivos	3
1.2	Justificativa	3
1.3	Contribuições	4
1.4	Limitações	4
1.5	Metodologia	5
1.6	Estrutura do Trabalho	5
2	Revisão Bibliográfica	7
3	Descrição do Problema	13
3.1	Caracterização do Problema	14
4	Algoritmos Propostos	17
4.1	Representação da Solução	18
4.2	Avaliação da Solução	18
4.3	Geração da Solução Inicial	19
4.4	Estruturas de Vizinhança	20
4.4.1	Estruturas de Vizinhança Inter-rota	20
4.4.2	Estruturas de Vizinhança Intrarrota	21

4.5	Procedimentos de Busca Local	22
4.5.1	<i>Variable Neighborhood Descent</i> - VND	22
4.5.2	<i>Randomized Variable Neighborhood Descent</i> - RVND	23
4.6	Destruição e Construção	24
4.7	<i>Smart Iterated Greedy Search</i> - <i>Smart</i> IGS	26
5	Experimentos Computacionais	29
5.1	Ambiente de Desenvolvimento e Testes	29
5.2	Descrição dos Cenários de Teste	29
5.3	Características das Instâncias	31
5.4	Calibração dos Parâmetros	33
5.5	Resultados	34
5.5.1	Análise de Convergência	39
6	Conclusões e Trabalhos Futuros	43
6.1	Publicação Gerada	44

Capítulo 1

Introdução

O câncer de mama é o tipo de câncer mais comum em mulheres e a maior causa de mortes por câncer nesse grupo. O Instituto Nacional de Câncer (INCA, 2019) constatou um aumento de 33,6% das taxas de mortalidade por câncer de mama, padronizadas por idade, entre 1980 e 2016. Ainda de acordo com o INCA, a taxa de mortalidade e a morbidade associada ao tratamento podem ser reduzidas pelo diagnóstico precoce da doença.

O exame de mamografia é um dos serviços gratuitos de diagnósticos ofertados pelo Sistema Único de Saúde (SUS). De acordo com Vieira et al. (2017), estima-se que o SUS seja responsável por 75% da saúde em nível nacional, sendo o sistema de saúde suplementar responsável pelo restante da população. A realização de exames periódicos em mulheres sem sintomas da doença é recomendada para a detecção precoce do câncer de mama.

As diretrizes brasileiras para o rastreamento do câncer de mama (INCA, 2015a) indicam que 60 quilômetros é a distância máxima permitida que um indivíduo deve se deslocar para realizar o exame de mamografia, respeitando-se os limites territoriais das regiões de saúde. Recomenda-se, ainda, que 20% das mulheres de 40 a 49 anos devem realizar exames anuais de mamografia, sendo 10% por indicação diagnóstica e 10% por outras indicações. Para todas as mulheres entre 50 a 69 anos é indicada a realização do exame bianualmente, com um adicional de 8,9% anual por indicação diagnóstica.

De acordo com Cunha et al. (2019), muitos fatores dificultam o acesso ao exame de mamografia, dentre eles podemos destacar: a qualidade dos equipamentos, a falta de especialistas para a solicitação de exames, as desigualdades socioeconômicas e a distância

entre a localidade onde o mamógrafo está instalado e a localidade em que a mulher reside.

No problema de localização de mamógrafos, há um conjunto de unidades fixas de mamografia a serem instaladas em localidades com infraestrutura hospitalar e um conjunto de municípios, cada um com demanda para exames de mamografia a serem realizados em mulheres de 40 a 69 anos. O objetivo é decidir onde instalar esses mamógrafos para maximizar a demanda total, atendendo às restrições de que uma mulher não pode viajar mais de 60 km para ser atendida e que nem todas as cidades são candidatas a sediar um mamógrafo.

Algumas localidades podem não ter hospitais com infraestrutura adequada e pode não ser justificável economicamente a instalação do mamógrafo. Este último caso ocorre quando, por exemplo, há cidades que não têm estrutura para sediar um equipamento, têm uma demanda baixa e estão a mais de 60 km de uma cidade com infraestrutura. Cidades nessas condições ficam desassistidas. Nessa situação, a alternativa para atender cidades com essas características é utilizar unidades móveis de mamografia.

Os serviços de mamografia móvel tornam o rastreamento mamográfico acessível para a população que esteja distante dos centros onde os equipamentos de mamografia estão localizados. Além de reduzir a desigualdade geográfica, o mamógrafo móvel possibilita diminuir a desigualdade social na medida em que torna o exame acessível aos indivíduos em situação de carência (Mil et al., 2019).

O exame de mamografia é considerado de média complexidade, e por isso, é possível desenvolver estratégias de rastreamento do câncer de mama que vão desde campanhas nacionais e mutirões até o deslocamento de equipamentos e profissionais a locais mais remotos (Xavier et al., 2016). Assim, a utilização de unidades móveis de mamografia pode servir como estratégia complementar para o atendimento da demanda feminina por exames de mamografia. Por outro lado, roteirizar Unidades Móveis de Mamografia (MMU, da sigla em inglês *Mobile Mammography Unit*) não é uma tarefa trivial e exige algoritmos especializados.

O problema associado à roteirização das MMUs, aqui denominado Problema de Roteamento de Unidades Móveis de Mamografia (MMURP, da sigla em inglês *Mobile Mammography Unit Routing Problem*), é uma variante de um problema de roteamento de veículos, que é NP-difícil (Lenstra e Rinnooy-Kan, 1981). Mais especificamente, O MMURP se assemelha ao Problema de Roteamento de Veículos com Frota Heterogênea e Múltiplos Depósitos. De fato, no MMURP, pretende-se roteirizar uma frota de MMUs de diferentes capacidades sediadas em diferentes hospitais (os quais servem como depósitos

desses veículos) para atender a um conjunto de localidades desprovidas de equipamentos fixos ou em número insuficiente destes. O objetivo é maximizar a cobertura de exames e reduzir a distância total percorrida pelas MMUs.

O MMURP tem características próprias que o diferenciam de outros problemas de roteamento encontrados na literatura. Dada a dificuldade de resolvê-lo na otimalidade por métodos exatos, nós desenvolvemos dois algoritmos heurísticos baseados na metaheurística *Iterated Greedy Search* (IGS) (Ruiz e Stützle, 2008) e na estratégia de perturbação do algoritmo *Smart ILS* de Reinsma et al. (2018). Esses dois algoritmos propostos foram nomeados *Smart IGS-VND* e *Smart IGS-RVND* e diferem entre si apenas com relação ao método de busca local utilizado.

1.1 Objetivos

Este trabalho tem como objetivo geral o desenvolvimento de algoritmos heurísticos, baseados em uma metaheurística, para resolver o MMURP.

Os objetivos específicos são:

- Caracterizar o Problema de Roteamento das Unidades Móveis de Mamografia;
- Obter a distribuição atual dos mamógrafos existentes, bem como a relação de todas as localidades do estado de Minas Gerais, juntamente com as distâncias reais entre todos os pares de localidades deste Estado;
- Desenvolver dois algoritmos heurísticos baseado na metaheurística *Iterated Greedy Search* para resolver o problema formulado;
- Validar os algoritmos desenvolvidos e testá-los em diferentes cenários;
- Apresentar os resultados obtidos em eventos científicos.

1.2 Justificativa

O câncer de mama é hoje um relevante problema de saúde pública. De acordo com INCA (2019), o planejamento de estratégias de controle do câncer de mama por meio da detecção precoce é fundamental, pois quanto mais cedo um tumor invasivo é detectado e o tratamento iniciado, maior a probabilidade de cura. Dessa forma, é muito importante expandir a oferta dos exames de mamografia e facilitar o seu acesso a população.

Rodrigues et al. (2019) avaliaram o acesso às campanhas de rastreamento do câncer de mama realizadas pelo SUS no ano de 2016, e analisaram a rede de oferta de exames de mamografia. Os autores destacaram que a quantidade de mamógrafos é suficiente para atender a toda a demanda por exames no Brasil. No entanto, o acesso ao exame é dificultado devido à localização inadequada dos mamógrafos, as desigualdades socioeconômicas e a qualidade dos recursos de saúde disponíveis. Conclusão similar foi obtida por Leung et al. (2014), os quais mostraram que as mulheres que residem distantes das áreas urbanas onde os mamógrafos normalmente estão instalados são menos propensas a realizarem o exame de mamografia.

Em vista disso, Mil et al. (2019) apontam o uso das MMUs como alternativa para tornar o exame de mamografia acessível para as mulheres que residem em áreas remotas ou carentes. Reuben et al. (2002) consideram que, dessa forma, é mais provável que as mulheres idosas e com baixa participação nas campanhas de rastreamento mamográfico realizem o exame. Assim, é importante o planejamento das rotas das MMUs para aumentar a quantidade de exames realizados.

Diversos estudos indicam que a triagem envolvendo as MMUs oferecem um ganho de efetividade maior do que somente com as campanhas de educação à saúde, na qual as mulheres são convidadas ao consultório de um especialista para fazer o exame de mamografia (Fontenoy et al., 2013; Mil et al., 2019; Reuben et al., 2002).

1.3 Contribuições

Esse trabalho contribui com o desenvolvimento e a implementação de algoritmos especializados para roteirizar as MMUs que atendem as localidades desprovidas de mamógrafos, ou onde o exame é de difícil acesso. Com a aplicação dos métodos propostos, espera-se um aumento no número de exames realizados e um melhor aproveitamento dos recursos disponíveis no serviço de mamografia móvel.

1.4 Limitações

Consideramos como limitações deste trabalho, as informações sobre o número de mamógrafos fixos e sua localização atual obtidos pelo site do DATASUS, pois nem sempre esses mamógrafos estão em operação. As regras de roteirização das MMUS foram defi-

nidas de acordo com informações fornecidas pelo Hospital do Câncer de Patrocínio Dr. José Figueiredo. O Hospital recebeu treinamento por uma instituição que é referência na prestação do serviço de mamografia móvel e que tem atuação em diversos Estados do Brasil. Porém, essas regras podem não se aplicar a outras sedes de unidades móveis.

1.5 Metodologia

Para que os objetivos propostos fossem alcançados, foram realizadas as seguintes atividades metodológicas:

- Revisão de Literatura: Análise dos estudos existentes relacionados a localização de mamógrafos, ao serviço de mamografia móvel e ao *Multi-Depot Vehicle Fleet Mix Problem* para o entendimento deste trabalho;
- Caracterização do Problema: Identificar as características do MMURP através de um estudo de caso do serviço de mamografia móvel prestado pelo Hospital do Câncer de Patrocínio Dr. José Figueiredo;
- Implementação dos procedimentos de Busca Local e as estruturas de vizinhanças para explorar o espaço de soluções do MMURP;
- Concepção e implementação dos algoritmos *Smart IGS-VND* e *Smart IGS-RVND* para resolução do MMURP;
- Calibração dos parâmetros dos algoritmos propostos por meio do pacote *irace* (López-Ibáñez et al., 2016).

1.6 Estrutura do Trabalho

O restante deste trabalho está organizado como segue. No Capítulo 2 é apresentada a revisão de literatura. O Capítulo 3 descreve o problema abordado. O Capítulo 4 introduz os algoritmos propostos para resolver o MMURP. No Capítulo 5 são apresentados os experimentos computacionais e os resultados alcançados. Por fim, o Capítulo 6 conclui o trabalho, apresenta as perspectivas de trabalhos futuros e a publicação gerada.

Capítulo 2

Revisão Bibliográfica

A distribuição espacial de mamógrafos no Brasil é um problema relevante e que afeta o acesso aos serviços de saúde, visto que um dos principais fatores para que as mulheres deixem de fazer o exame de mamografia é a distância que elas precisam percorrer até o local onde o mamógrafo que irá atendê-la está instalado (Andrade et al., 2016).

Xavier et al. (2016) fizeram uma análise de indicadores relacionados à cobertura de mamografia das mulheres de 40 a 49 anos, número, distribuição e grau de utilização dos mamógrafos nas Regiões de Saúde brasileiras. Após a análise dos dados, os autores comprovaram que os equipamentos estão em uma distribuição bastante heterogênea e, como agravante, baixo grau de utilização.

Amaral et al. (2017) também comprovaram uma desigualdade locacional na distribuição espacial de mamógrafos no Brasil. Segundo os autores, apesar da quantidade total de mamógrafos ser suficiente para o atendimento da população, quando se limita que uma mulher deveria percorrer no máximo uma distância de 60 km para ser atendida, é possível identificar regiões em que não há provisão do equipamento e, ao mesmo tempo, áreas que concentram uma quantidade de equipamento superior à necessária.

Rodrigues et al. (2019) avaliaram o acesso ao exame de mamografia no Sistema Único de Saúde (SUS), a distribuição espacial de mamógrafos e o número de mamografias realizadas no Brasil. O número de mamógrafos necessários para o rastreamento do câncer de mama foi calculado e comparado com o número de mamógrafos disponíveis, além disso, o número esperado de mamografias foi comparado com o número real de exames realizados. Os autores concluíram que o número de mamografias realizadas é insuficiente para atender a demanda da população.

Abreu e Silva (2015) analisaram a distribuição e acesso aos mamógrafos no Estado da Bahia, e identificaram uma concentração de mamógrafos em regiões com melhores condições socioeconômicas e uma baixa cobertura, causando uma iniquidade no acesso ao exame de mamografia. Os autores ressaltaram também a dificuldade em encontrar profissionais para operar os mamógrafos e médicos capacitados para solicitar os exames.

Tendo em vista a desigualdade locacional na distribuição espacial de mamógrafos no Brasil e o número insuficiente de mamografias realizadas para atender a demanda da população, Souza et al. (2019) definiram o Problema de Localização de Mamógrafos (PLM). O objetivo deste problema é decidir em quais localidades os mamógrafos serão instalados para maximizar a cobertura de atendimento dos equipamentos. O estudo apresentou uma formulação de programação matemática para o problema, bem como sua relaxação linear parcial. As formulações foram testadas utilizando dados do Estado de Rondônia. Os autores analisaram diversos cenários, considerando inclusive a possibilidade de aquisição de mais mamógrafos do que os atualmente disponíveis. Além de uma redistribuição para que fosse possível realizar mais exames, os resultados indicaram as localidades mais adequadas para a aquisição de novos mamógrafos a partir da alocação existente.

Souza et al. (2020) propuseram uma solução computacional por meio de formulações matemáticas e de procedimentos heurísticos para atender as localidades de Minas Gerais. Os resultados mostraram que se fosse possível redistribuir os mamógrafos existentes, mais exames poderiam ser realizados.

Mesmo após a redistribuição dos mamógrafos podem restar localidades que não foram cobertas por um mamógrafo fixo. Podemos citar como exemplo, as localidades que não possuem infraestrutura para a instalação de um mamógrafo ou que estão distantes dos centros onde esses equipamentos foram instalados. Diante disso, as Unidades Móveis de Mamografia (MMUs) são utilizadas para resolver este problema, pois estes veículos possuem um mamógrafo instalado e levam o exame de mamografia até as localidades que estão desassistidas por um mamógrafo fixo.

O serviço de mamografia móvel já vem sendo prestado em diversos países, inclusive no Brasil. Com a prestação deste serviço, as mulheres que não fizeram uma mamografia recentemente são incentivadas a realizarem o exame (Brooks et al., 2013). Além disso, as MMUs também são utilizadas para atender populações vulneráveis com acesso limitado ao sistema de saúde (Mil et al., 2019; Renck et al., 2014; Reuben et al., 2002).

DeBruhl et al. (1996) apresentaram um estudo para conhecer o funcionamento das

MMUs nos Estados Unidos. Um questionário com 82 perguntas foi elaborado, testado, e enviado para as instalações das MMUs. As perguntas abordaram diferentes aspectos dos serviços de mamografia móvel, incluindo administrativo, financeiro, equipamento, pessoal, processamento de filme, garantia de qualidade e comunicação de resultados. Os autores concluíram que apesar do serviço de mamografia móvel aumentar o acesso ao rastreamento mamográfico, esse serviço ainda enfrenta muitos obstáculos, como por exemplo, as dificuldades financeiras e a necessidade de subsídios para alguns desses programas.

Browder et al. (2015) também avaliaram o serviço de mamografia móvel, a partir de análises nos sistemas de informação, pessoal e processos envolvidos. Os dados analisados incluem observações no local, entrevistas e uma revisão do prontuário eletrônico de um hospital que oferece serviços de mamografia móvel e fixa para sua comunidade. Após a avaliação, os autores recomendaram o emprego de uma equipe de mamografia móvel dedicada para supervisão de ponta a ponta, resolvendo os problemas de conectividade do sistema, permitindo o encaminhamento próprio do paciente, integrando processos de agendamento e registro e uma abordagem focada em preparar os profissionais que irão receber os pacientes no local de atendimento e os respectivos pacientes sobre os preparos para o dia da visita.

No Brasil, Renck et al. (2014) avaliaram um programa de prevenção e diagnóstico precoce do câncer de mama, realizado com uma MMU que visitou que visitou municípios da região sul do Rio Grande do Sul, onde não havia um aparelho de mamografia disponível. De acordo com o estudo, há municípios no Rio Grande do Sul onde as mulheres necessitam se deslocar por distâncias de até 500km para realizar a mamografia. Os autores apresentaram uma comparação entre as características das mulheres avaliadas pela MMU com as das mulheres encaminhadas para exame mamográfico na cidade de Pelotas, e concluíram que a prevalência de casos positivos foi estatisticamente semelhante nos dois grupos. O estudo demonstrou a importância do rastreamento ativo do câncer de mama, como forma de diagnóstico precoce, prevenção da doença e redução dos índices de mortalidade.

Considerando os aspectos do serviço de mamografia móvel que precisam de melhorias, Bhateja et al. (2014) apresentaram um novo modelo desses veículos nomeados *Smart Mobile Mammography Unit* (SMMU) para fornecer amplo acesso ao rastreamento do câncer de mama e também garantir a participação de áreas remotas que geralmente são privadas de centros fixos. Segundo os autores existem limitações para fornecer análises no local e diagnóstico por radiologistas experientes. O modelo proposto produz uma rede

para o diagnóstico remoto de pacientes com câncer de mama, fornecendo aprimoramento das mamografias (como por exemplo, melhorar o contraste da região de interesse, e as relações sinal-ruído) para fins de análise e diagnóstico preciso por radiologistas.

Tendo em vista o relevante problema da distribuição de mamógrafos e a importância das MMUs no diagnóstico precoce do câncer de mama, neste trabalho nós tratamos do Problema de Roteamento de Unidades Móveis de Mamografia. Não foram encontrados relatos de abordagens computacionais para resolver este problema, no entanto, existem trabalhos com propostas para resolver problemas semelhantes.

O MMURP é uma variante de um problema de roteamento de veículos, que é NP-difícil (Lenstra e Rinnooy-Kan, 1981). Mais especificamente o MMURP se assemelha ao Problema de Roteamento de Veículos com Frota Heterogênea e Múltiplos Depósitos (MDVFMP, da sigla em inglês *Multi-Depot Vehicle Fleet Mix Problem*). No MDVFMP, a frota é composta por diferentes tipos de veículos, e para cada tipo é associado um conjunto de veículos. A frota é considerada heterogênea, isto é, os veículos possuem diferentes capacidades. Esse problema também considera haver mais de um depósito de onde os veículos iniciam e terminam as suas rotas.

De fato, no MMURP, pretende-se roteirizar uma frota de MMUs de diferentes capacidades sediadas em diferentes hospitais (os quais servem como depósitos desses veículos). No entanto, o MMURP tem características próprias que o diferenciam de outros problemas de roteamento encontrados na literatura, e por isso, faremos uma breve revisão de alguns trabalhos relacionados ao MDVFMP a seguir.

Com relação aos métodos de solução dessa classe de problemas, Salhi e Sari (1997) introduziram o MDVFMP com uma formulação de programação matemática e propuseram uma heurística de múltiplas fases para tratar o problema. Salhi et al. (2014) aperfeiçoaram esse trabalho com o desenvolvimento de um algoritmo baseado na meta-heurística VNS que inclui um método para tratar clientes no limite entre os dois depósitos mais próximos. Além disso, os autores aplicaram o algoritmo de Dijkstra para determinar o particionamento ideal das rotas, bem como, um procedimento para agregar e desagregar as rotas de diferentes depósitos, além de heurísticas para o refinamento e perturbação das rotas.

Vidal et al. (2012) propuseram uma meta-heurística baseada em Algoritmos Genéticos para resolver problemas de roteamento veículos com múltiplos depósitos e períodos. Os autores apresentaram um novo método intitulado de mecanismo adaptativo de gerenciamento populacional, que aumenta a diversidade de indivíduos permitindo um acesso

mais amplo à reprodução, enquanto preserva as características das melhores soluções encontradas. Assim, a avaliação de uma solução é feita com base nas medidas de custo e diversidade, isto é, na distância das demais soluções. Os testes demonstraram que esse método evita a convergência prematura da população e encontra soluções de qualidade em um tempo computacional reduzido, quando comparado as abordagens tradicionais.

Benslimane e Benadada (2013) apresentaram um modelo matemático e desenvolveram um algoritmo *Ant colony* para um problema de distribuição de produtos em larga escala partindo de múltiplos depósitos e com frota de diferentes capacidades. O objetivo é minimizar o custo total de distribuição, que consiste na soma dos custos relacionados ao deslocamento (combustível, por exemplo) e uso (aluguel, por exemplo) dos veículos.

Vidal et al. (2014) introduziram um procedimento de busca baseado em programação dinâmica, que explora um conjunto de vizinhanças de trocas e realocação para determinar a melhor posição para os depósitos e a melhor escolha de veículos. Além disso, os autores desenvolveram uma estratégia chamada de rotação para fazer a melhor escolha do primeiro cliente a ser visitado em cada rota. Esta abordagem foi aplicada em dois algoritmos baseados nas meta-heurísticas *Iterated Local Search* e Algoritmo Genético.

Bolaños et al. (2018) apresentaram um algoritmo baseado em Algoritmos Genéticos para tratar o MDVFMP. O algoritmo possui um método híbrido para gerar a população inicial, que combina uma heurística para gerar grandes sequências de clientes, e um método exato baseado no algoritmo de caminho mais curto que divide essa sequência em rotas menores. Os autores também apresentaram dois métodos para a fase de recombinação e um processo de mutação que faz uso de oito estruturas de vizinhança na busca local. Os resultados mostraram que o algoritmo proposto é capaz de obter soluções comparáveis às das melhores soluções da literatura à época.

Penna et al. (2019) apresentaram uma abordagem unificada capaz de resolver uma ampla classe de problemas de roteamento de veículos que combinam frota heterogênea a outros atributos, como exemplo, múltiplos depósitos, *backhauls* e janelas de tempo. A abordagem é composta por um método *Iterated Local Search* para gerar um conjunto de rotas associadas a ótimos locais, e um modelo matemático para o problema *Set Partitioning* construído através desse conjunto de rotas. Os resultados sugeriram que apesar de sua generalidade, o algoritmo proposto é bastante competitivo quando comparado a algoritmos específicos para o problema, em termos de qualidade da solução e tempo de computação.

Capítulo 3

Descrição do Problema

O Problema de Roteamento das Unidades Móveis de Mamografia, trata da roteirização de uma frota de Unidades Móveis de Mamografia para maximizar a cobertura de atendimentos para a população feminina e minimizar a distância total percorrida por esses veículos. As MMUs são popularmente conhecidas como as Carretas da Mamografia. Nestes veículos, são instalados o mamógrafo e outros equipamentos, como por exemplo, ultrassom, conversor de imagens analógicas em digitais, impressoras, computadores, entre outros, que são administrados por uma equipe de profissionais que os acompanham.

As MMUs são utilizadas para facilitar o acesso ao exame de mamografia levando o exame para as localidades que não estão sendo atendidas por um mamógrafo fixo. A Figura 3.1 mostra um exemplo de uma solução para o problema de alocação destes mamógrafos que estarão fixos na localidade escolhida para sua instalação. Nesta solução foram alocados dois mamógrafos, sendo que o primeiro foi alocado na localidade 1 para atender além dela própria as localidades 2 e 3, enquanto o segundo mamógrafo foi alocado na localidade 6, atendendo a própria localidade e a localidade 8. As localidades 4, 5 e 7 não foram atendidas por nenhum mamógrafo fixo.

Como pode ser observado na Figura 3.2, uma MMU foi utilizada para atender as localidades que não estavam cobertas por nenhum mamógrafo fixo. Neste exemplo, a MMU atendeu a demanda da localidade 4 (circulada na figura por ser onde também está localizado o seu depósito), depois disso o veículo partiu para atender a localidade 5, e por fim, a localidade 7 onde termina a rota.

Para modelar o MMURP, levou-se em consideração as informações fornecidas pelo Hospital do Câncer de Patrocínio Dr. José Figueiredo sobre o funcionamento da MMU

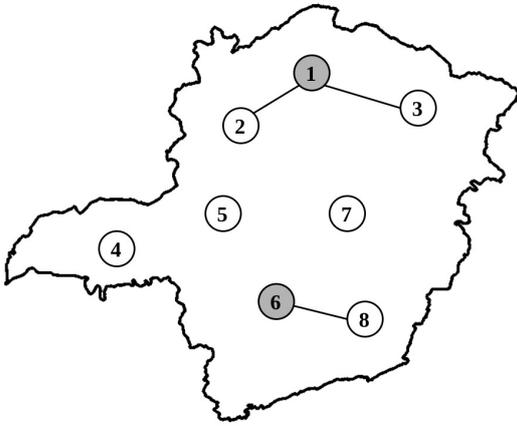


Figura 3.1: Exemplo de alocação de dois mamógrafos em um conjunto de oito localidades

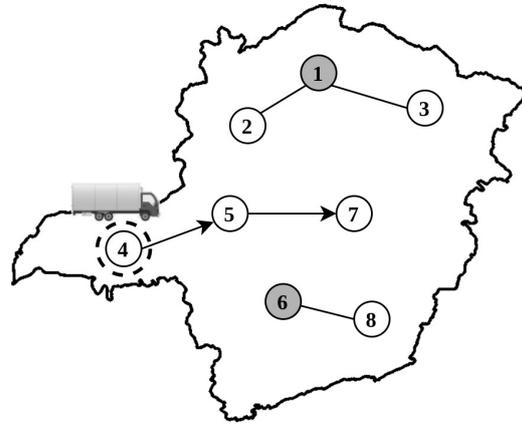


Figura 3.2: Exemplo de uma rota realizada por uma MMU para atender três localidades

localizada no município de Patrocínio, Minas Gerais. Toda a equipe responsável pela MMU foi devidamente capacitada e adota as práticas que são referências por prestadores do serviço de mamografia móvel em outros Estados do Brasil. A Seção 3.1 apresenta as características definidas para o MMURP, e um exemplo detalhado de uma solução para este problema.

3.1 Caracterização do Problema

O MMURP possui as seguintes características. Seja $G = (V, A)$ um grafo direcionado onde $V = N \cup M$ sendo N um conjunto de localidades e M um conjunto de depósitos, e $A = \{(i, j) : i, j \in V, i \neq j\}$ é o conjunto de arestas, sendo que para cada aresta $(i, j) \in A$ está associado uma distância d_{ij} entre as localidades i e j . O vértice 0 representa o depósito, onde se encontra a frota de veículos, enquanto o conjunto $V' = V \setminus \{0\}$ dos vértices restantes representam as n localidades. Cada localidade $i \in V'$ possui uma demanda dem_i não negativa (assume-se que $dem_0 = 0$).

Cada MMU $k \in K$ possui uma capacidade cap_k definida por: $cap_k = \text{Quantidade de mamógrafos transportado pela MMU } k \times \text{capacidade do mamógrafo}$. A capacidade de cada MMU equivale a quantidade de exames que podem ser realizados em cada veículo. Há uma distância máxima, dada por $distMax$, permitida para uma MMU realizar o percurso de uma localidade a outra. Apenas a viagem inicial partindo do depósito não

tem limite de quilometragem.

Considera-se que cada MMU pode alcançar uma velocidade máxima de 60km/h e que o deslocamento até a localidade a ser atendida é feito durante as 3 primeiras horas do primeiro dia de atendimento. Sendo assim, definiu-se neste trabalho que a distância máxima $distMax$ que a MMU deve percorrer entre duas localidades é de 180 km (60km/h x 3h).

Cada localidade deve ser visitada uma única vez e por apenas uma MMU. A demanda da localidade visitada deve ser totalmente atendida. O roteamento é aberto, isto é, as MMUs não retornam aos depósitos de origem, elas seguem um percurso enquanto for possível atender as demandas por exames e finalizam a rota na última localidade visitada.

A equipe é levada por um carro até a localidade onde a MMU será instalada para que sejam realizados os atendimentos, e também nesta localidade os funcionários ficarão hospedados. Após concluídos todos os atendimentos agendados, o motorista retorna para levar o veículo até o seu próximo destino, fazendo também o deslocamento da equipe de profissionais.

É mais comum que uma MMU opere com um mamógrafo, mas existem casos em que são instalados dois mamógrafos no veículo. Segundo INCA (2015b), cada mamógrafo instalado consegue realizar até 5069 mamografias anualmente, e dessa forma, um veículo com dois mamógrafos instalados é capaz de realizar por ano 10138 exames.

A Figura 3.3 ilustra um exemplo de solução viável com 12 localidades, representadas pelo conjunto $N = \{1, 2, \dots, 12\}$, e dois depósitos, representados pelo conjunto $M = \{13, 14\}$. No depósito 13 há uma única MMU, enquanto no depósito 14 há duas MMUs. Cada localidade possui uma demanda a ser atendida que está representada pelo valor entre colchetes. Como pode ser observado no exemplo, a demanda da localidade 1 é indicada por $dem_1 = 85$ exames. A distância entre cada par de vértices é representada pelo valor acima das arestas. No exemplo, a distância entre as localidades 1 e 6 é indicada por $d_{1,6} = 20$ unidades de distância.

Na solução apresentada, as localidades 4, 11, 5, 3 e 2 são atendidas pela MMU que inicia sua rota no depósito 13, nesta mesma ordem de visita. No depósito 14, duas MMUs foram utilizadas: a primeira visita as localidades 8, 1 e 6, respectivamente, e já a segunda percorre as localidades 10, 7, 12 e 9. A demanda total coberta neste exemplo de solução foi de 1985 exames (150 + 230 + 100 + 80 + 300 + 250 + 85 + 100 + 90 + 350 + 200 + 50), e a distância total percorrida pelas MMUs foi de 260 unidades de

distância ($20 + 40 + 10 + 20 + 10 + 20 + 10 + 30 + 40 + 30 + 10 + 20$).

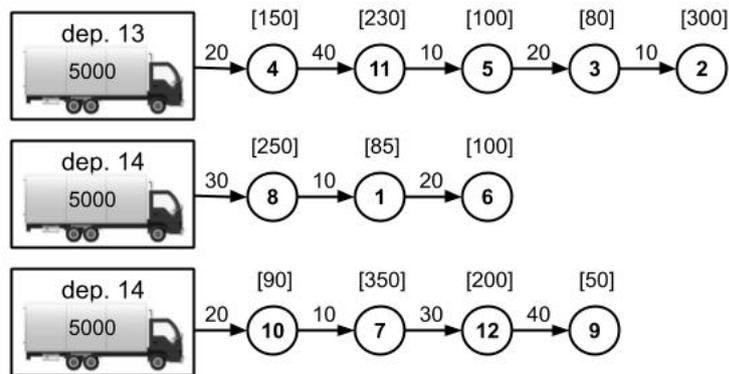


Figura 3.3: Exemplo de solução com doze localidades e dois depósitos

As MMUs apresentadas na Figura 3.3, possuem a capacidade de realizar 5000 exames. A MMU do depósito 13 atendeu uma demanda de 860 exames ($150 + 230 + 100 + 80 + 300$), restando assim uma capacidade residual de 4140 exames. A primeira MMU do depósito 14 possui capacidade residual de 4565 exames, enquanto que a segunda MMU ainda pode realizar 4310 exames.

Capítulo 4

Algoritmos Propostos

Os algoritmos propostos para resolver o MMURP são o *Smart IGS-VND* e o *Smart IGS-RVND*. Ambos são variações do IGS, usam a ideia da fase de perturbação do algoritmo *Smart ILS* de Reinsma et al. (2018) e se diferenciam apenas pelo procedimento de busca local empregado. O *Smart IGS-VND* utiliza como busca local o procedimento *Variable Neighborhood Descent - VND* (Hansen et al., 2010), enquanto que no *Smart IGS-RVND* é aplicada a busca local *Randomized Variable Neighborhood Descent - RVND* (Souza et al., 2010; Subramanian et al., 2010).

O *Iterated Greedy - IGS* (Ruiz e Stützle, 2008) possui como característica a exploração do espaço de busca por meio de modificações na solução ótima local utilizando os componentes de destruição e construção da solução. Diferentemente do algoritmo *Iterated Greedy*, no *Smart IGS* o nível de perturbação aumenta somente após um certo número de tentativas de melhoria sem sucesso, visto que a região pode não ter sido explorada adequadamente. Essa abordagem faz parte do estudo de Reinsma et al. (2018), os quais nomearam *Smart ILS* o algoritmo ILS desenvolvido com essa característica.

A Seção 4.1 mostra a representação de uma solução para o MMURP, e a Seção 4.2 define a função que avalia essa solução. Para a aplicação dos algoritmos propostos é necessário um procedimento de construção de uma solução inicial, apresentado na Seção 4.3; um procedimento de busca local que retorna uma solução possivelmente melhorada, e para isso, a Seção 4.4 apresenta as estruturas de vizinhança utilizadas e as técnicas de busca local são descritas na Seção 4.5. Os procedimentos que modificam a solução corrente guiando a uma solução intermediária são apresentados na Seção 4.6, e por fim, a Seção 4.7 apresenta o algoritmo *Smart IGS*.

4.1 Representação da Solução

Representa-se uma solução s do MMURP por meio de até $|K|$ vetores que armazenam em cada posição as localidades percorridas pelas MMUs na ordem em que aparecem na rota. O número $|K|$ de vetores corresponde à quantidade de MMUs disponíveis. Os vetores podem ou não ter tamanhos iguais, dependendo apenas da quantidade de localidades visitadas por cada MMU.

A Figura 4.1 ilustra a representação computacional de uma solução s . Os índices de 1 a 6 representam as posições dos vetores, sendo que cada posição armazena a localidade visitada na ordem em que ela aparece na rota. A primeira posição de cada vetor indica o depósito de onde as MMUs iniciam suas rotas. A MMU 1 deixa o depósito 13 e visita as localidades 4, 11, 5, 3 e 2, nesta ordem. Já a MMU 2 inicia sua rota no depósito 14 e visita as localidades 8, 1 e 6. Por último, a MMU 3 que também inicia sua rota no depósito 14, percorre as localidades 10, 7, 12 e 9.

	1	2	3	4	5	6
MMU 1	13	4	11	5	3	2
MMU 2	14	8	1	6		
MMU 3	14	10	7	12	9	

Figura 4.1: Representação de uma solução s do MMURP

4.2 Avaliação da Solução

Uma solução s do MMURP é avaliada de modo hierárquico pela função de avaliação: $f(s) = (f_{dem}(s), f_{dist}(s))$. A solução é avaliada inicialmente pela demanda total atendida, conforme é apresentado na Equação (4.1), e caso duas soluções obtiverem o mesmo valor nessa função, a melhor é aquela cuja soma das distâncias percorridas for a menor, como é apresentado na Equação (4.2):

$$f_{dem}(s) = \sum_{(j,k) \in A_1} dem_j \quad (4.1)$$

$$f_{dist}(s) = \sum_{(i,j) \in A_2} d_{ij} \quad (4.2)$$

em que A_1 é o conjunto das associações entre uma localidade j e uma MMU k que atende na solução s , dem_j é a demanda da localidade j , A_2 é o conjunto das arestas ligando as localidades i e j atendidas por uma mesma MMU, e d_{ij} é a distância entre as localidades i e j .

4.3 Geração da Solução Inicial

A construção de uma solução inicial para o MMURP é definida pelos passos seguintes:

Passo 1 - Ordenação: Seja LC a lista de localidades candidatas a serem visitadas pelas MMUs, ordene-a decrescentemente de acordo com a demanda de cada localidade;

Passo 2 - Alocação: Para cada localidade i da LC ordenada, aloque a localidade i ao depósito mais próximo e elimine-a de LC . Passe para a próxima localidade da lista. Ao final desse passo tem-se uma lista de localidades candidatas para cada depósito.

Passo 3 - Heurística do vizinho mais próximo: Para cada depósito, enquanto houver MMU disponível e localidades ainda não visitadas da lista de candidatas do depósito:

- 3.1: Inicie a rota de uma nova MMU com a localidade onde se encontra o depósito;
- 3.2: Atenda a demanda do depósito e atualize a capacidade da MMU que foi utilizada para atender a essa demanda.
- 3.3: Determine a localidade mais próxima da última localidade inserida na rota da MMU que ainda não foi visitada;
- 3.4: Verifique se é possível atender a demanda da localidade mais próxima:
 - (a) Se a demanda da localidade mais próxima for menor ou igual à capacidade da MMU e a distância até a localidade mais próxima for menor ou igual a $distMax$, atenda-a e insira-a na rota da MMU. Atualize a capacidade da

MMU e remova a localidade atendida da lista de candidatas do depósito.
Volte ao item 3 do Passo 3;

(b) Caso contrário, finalize a rota da MMU na última localidade por ela visitada;

3.5: Se houver MMU disponível, retorne ao item 1 do Passo 3; caso contrário, encerre o método e retorne as rotas feitas pelas MMUs.

4.4 Estruturas de Vizinhaça

O conjunto de estruturas de vizinhaças utilizadas para explorar o espaço de soluções do MMURP é definido através de quatro estruturas de vizinhaça inter-rota, apresentadas na Subseção 4.4.1, e duas estruturas de vizinhaça intrarrota, apresentadas na Subseção 4.4.2. Após a aplicação do movimento é encontrada uma solução intermediária que esteja em sua vizinhaça.

4.4.1 Estruturas de Vizinhaça Inter-rota

Os movimentos descritos a seguir, são aplicados em duas rotas distintas r_1 e r_2 , selecionadas aleatoriamente da solução. Nesses movimentos, as localidades que serão realocadas ou trocadas devem estar entre a segunda e a última posição de uma rota, pois a primeira posição da rota identifica o depósito. Esses movimentos podem ocorrer entre rotas de um mesmo depósito (intra-depósito), ou entre rotas de depósitos diferentes (inter-depósitos).

Realocação (1, 0): Uma localidade i é removida de uma rota r_1 e inserida em outra rota r_2 . Um exemplo desse movimento está na Figura 4.2.(b). Observa-se que a localidade 5 é retirada da rota r_1 e reinserida na rota r_2 .

Realocação (2, 0): Duas localidades adjacentes i e $i + 1$ são removidas de uma rota r_1 e inseridas na rota r_2 . Na Figura 4.2.(c), as localidades 5 e 3 pertencentes a rota r_1 são transferidas para a rota r_2 .

Troca (1, 1): É realizada uma troca entre uma localidade i de uma rota r_1 com uma localidade j de uma rota r_2 . A Figura 4.2.(d) exemplifica esse movimento, neste caso, a localidade 11 da rota r_1 é trocada com a localidade 9 da rota r_2 .

Troca (2, 1): É realizada uma troca entre duas localidades adjacentes i e $i + 1$

de uma rota r_1 , com uma localidade j de uma rota r_2 . Como pode ser observado na Figura 4.2.(e), a localidade 11 e 5 da rota r_1 foram trocadas com a localidade 9 da rota r_2 .

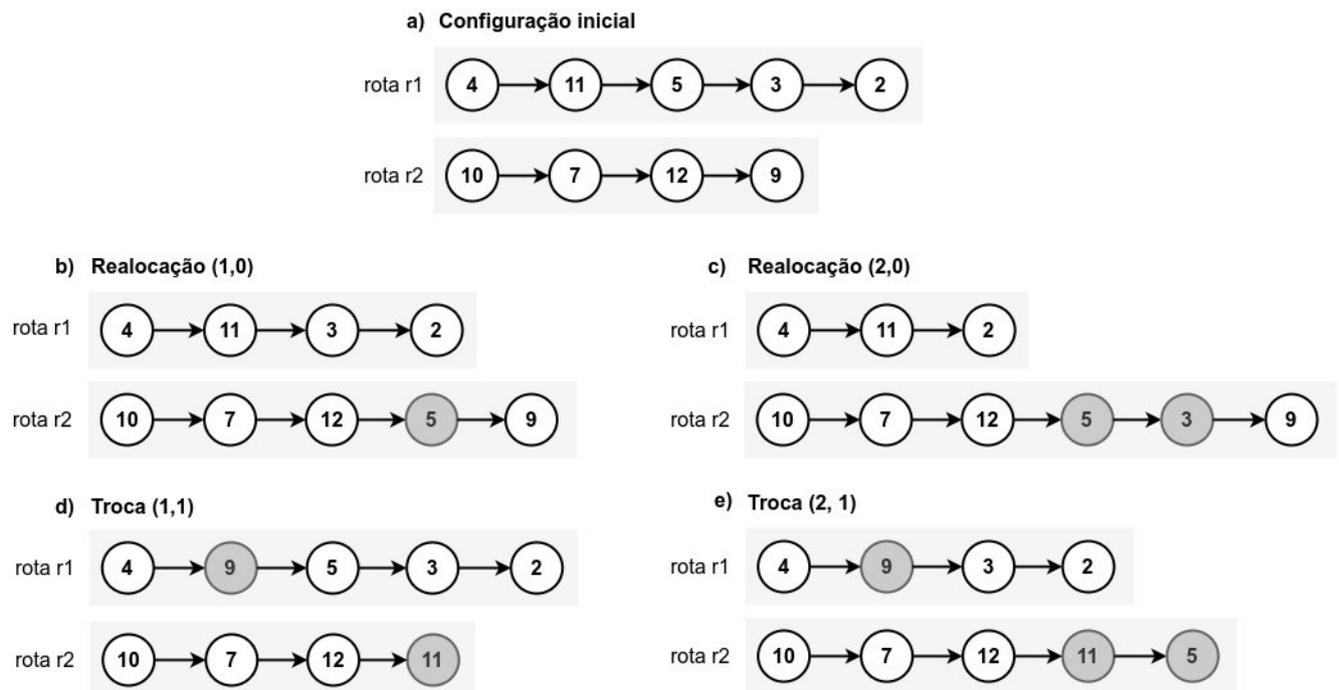


Figura 4.2: Estruturas de vizinhança inter-rota

4.4.2 Estruturas de Vizinhança Intrarrota

Os movimentos descritos a seguir definem as estruturas de vizinhança intrarrota, utilizadas para fazer modificações em uma única rota. Esses movimentos são aplicados somente nas rotas que sofreram alguma modificação durante a execução dos movimentos inter-rota. Assim como nas estruturas apresentadas anteriormente, as localidades que serão realocadas devem estar entre a segunda e a última posição de uma rota.

Or-opt1: Uma localidade i é removida e inserida em uma outra posição da rota. Um exemplo desse movimento está na Figura 4.3.(b). Observa-se que a localidade 11 é retirada de sua posição e inserida entre as localidades 3 e 2.

Or-opt2: Duas localidades adjacentes i e $i+1$ são removidas e realocadas em um outro ponto da rota. Observa-se na Figura 4.3.(c), que a localidade 11 e 5 foram realocadas para o final da rota.

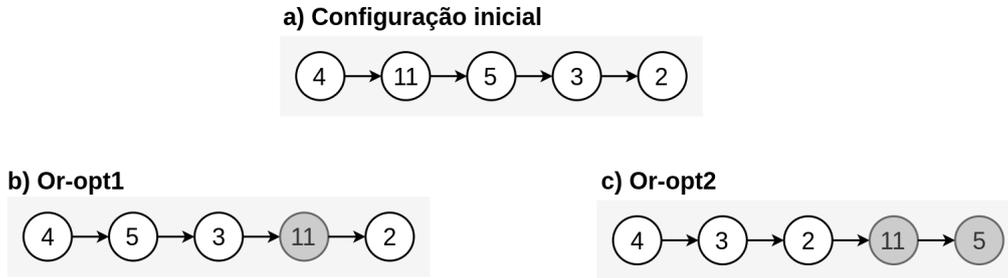


Figura 4.3: Estruturas de vizinhança intrarota

4.5 Procedimentos de Busca Local

O algoritmo *Smart* IGS-VND utiliza na fase de busca local o procedimento VND, que faz a exploração do espaço de soluções através de uma ordem de vizinhanças determinística. De outro modo, o algoritmo *Smart* IGS-RVND utiliza a busca local RVND, na qual as vizinhanças são selecionadas para explorar o espaço de soluções de acordo com uma ordem aleatória. A Subseção 4.5.1 descreve o funcionamento do VND, e a Subseção 4.5.2 descreve o RVND.

4.5.1 *Variable Neighborhood Descent - VND*

No procedimento VND a exploração do espaço de soluções considera as seis vizinhanças apresentadas na Seção 4.4, na seguinte ordem: *Or-opt1*, *Realocação (1, 0)*, *Or-opt2*, *Troca (1, 1)*, *Realocação (2, 0)* e *Troca (2, 1)*. Esta ordem é definida pela complexidade das vizinhanças, iniciando pela vizinhança que requer menos esforço computacional, para a vizinhança que requer mais esforço computacional.

O Algoritmo 1 descreve o funcionamento do VND. No início, a variável v_{max} recebe o número de vizinhanças inter-rota que serão utilizadas (linha 1), isto é, as quatro estruturas de vizinhança apresentadas na Subseção 4.4.1. A variável v indica o tipo de estrutura de vizinhança corrente. Inicialmente, v equivale a 1, indicando que a primeira vizinhança da ordem estabelecida deve ser utilizada (linha 2). Caso v tivesse o valor 2, a segunda vizinhança da ordem deveria ser utilizada, e assim suscetivamente, até a última vizinhança v_{max} .

Enquanto a última vizinhança não for alcançada (linha 3), é realizada uma descida na solução usando a estratégia *First Improvement* para encontrar um vizinho de pri-

meira melhora s' , de acordo com a vizinhança v (linha 4). A solução ótima local s' , é então avaliada conforme a função objetivo (linha 5), e caso seja melhor que a solução corrente, a busca continua de s' (linha 6). Neste caso, também é realizada uma nova busca local, porém desta vez utilizando as vizinhanças intrarrotas apresentadas na Subseção 4.4.2 (linha 7), e a variável v é reiniciada. Caso não houver melhorias na solução, v é incrementado e a busca parte da próxima vizinhança dentro da ordem estabelecida.

Algoritmo 1: VND

Entrada: s

Saída: s

```

1 Seja  $v_{max}$  o número de estruturas de vizinhança;
2  $v \leftarrow 1$ ;
3 enquanto  $v \leq v_{max}$  faça
4    $s' \leftarrow$  Encontre o vizinho de primeira melhora de  $s$ , de acordo com a vizinhança
    $v$ ;
5   se  $f_{dem}(s') > f_{dem}(s)$  ou  $(f_{dem}(s') = f_{dem}(s) \text{ e } f_{dist}(s') < f_{dist}(s))$  então
6      $s \leftarrow s'$ ;
7      $s \leftarrow Busca\_Intrarrota(s)$ ;
8      $v \leftarrow 1$ ;
9   senão
10     $v \leftarrow v + 1$ ;
11  fim
12 fim
```

4.5.2 Randomized Variable Neighborhood Descent - RVND

O pseudocódigo do RVND é apresentado no Algoritmo 2. A princípio, inicializamos o conjunto V_1 das quatro vizinhanças inter-rotas apresentadas na Seção 4.4.1. A cada iteração, uma vizinhança v desse conjunto é selecionada aleatoriamente (linha 3); em seguida, é realizada uma descida na solução usando a estratégia *First Improvement* (linha 4) para encontrar um vizinho de primeira melhora s' , dentro da vizinhança escolhida anteriormente.

A solução ótima local s' é, então, avaliada conforme a função objetivo (linha 5). Caso essa solução ótima local com relação à vizinhança inter-rota v seja melhor do que a solução corrente, a busca continua a partir de s' (linha 6), porém aplicando-se o procedimento *Busca_Intrarrota*. Este procedimento consiste também em um RVND, porém utilizando-se movimentos intrarrotas (linha 7). Na linha 8, o conjunto V_1 é

reiniciado com todas as vizinhanças definidas inicialmente. No caso de a solução s' não ser de melhora, a vizinhança selecionada anteriormente é removida do conjunto V_1 (linha 10), e a busca continua a partir de uma outra estrutura de vizinhança inter-rota. A busca termina quando o conjunto de vizinhanças V_1 estiver vazio.

Algorithm 2: RVND

Entrada: s
Saída: s

- 1 Inicialize o conjunto de Vizinhanças V ;
- 2 **enquanto** $V \neq \emptyset$ **faça**
- 3 $v \leftarrow$ Escolha uma vizinhança inter-rota $v \in V_1$ aleatoriamente;
- 4 $s' \leftarrow$ Encontre o vizinho de primeira melhora de s , de acordo com a vizinhança v escolhida;
- 5 **se** $f_{dem}(s') > f_{dem}(s)$ **ou** $(f_{dem}(s') = f_{dem}(s) \text{ e } f_{dist}(s') < f_{dist}(s))$ **então**
- 6 $s \leftarrow s'$;
- 7 $s \leftarrow Busca_Intrarrota(s)$;
- 8 Reinicialize V_1 ;
- 9 **senão**
- 10 Remova v de V_1 ;
- 11 **fim**
- 12 **fim**

4.6 Destruição e Construção

Os procedimentos de destruição e construção modificam a solução corrente para que a busca local explore diferentes regiões, mantendo características importantes do ótimo local. O procedimento de destruição é descrito no Algoritmo 3. Esse procedimento recebe como parâmetro de entrada uma solução s ; a lista de localidades candidatas LC' ; o nível de intensidade da destruição $nivel$, que deve ser alto o suficiente para que a busca local explore diferentes regiões, e baixo o suficiente para manter características do ótimo local e evitar um reinício aleatório; e o percentual de MMUs que serão modificadas $kPercentPerturb$.

A princípio, as MMUs são ordenadas de maneira decrescente de acordo com a sua capacidade residual (linha 1), isto é, as MMUs com maior capacidade disponível para realizar exames estarão nas primeiras posições. Em seguida, são selecionadas aleato-

riamente $kPercentPerturb$ MMUs dentre as $nivel$ MMUs de maior capacidade residual (linha 2). Por fim, as rotas das MMUs selecionadas anteriormente são esvaziadas e as localidades removidas são inseridas no conjunto de localidades candidatas LC' (linha 3).

O parâmetro $kPercentPerturb$ equivale ao percentual de MMUs que serão escolhidas aleatoriamente entre as de maior capacidade residual. Este percentual pode estar entre 0 e 1, 0 caso nenhuma MMU for selecionada e 1 caso todas as $nivel$ MMUs de maior capacidade residual forem escolhidas. O parâmetro $nivel$ equivale ao nível de modificação do algoritmo Smart IGS, este parâmetro é incrementado sempre que o algoritmo não conseguir encontrar uma solução de melhora.

Algoritmo 3: Destruição

Entrada: $s, nivel, kPercentPerturb, LC'$

Saída: s, LC'

- 1 Ordene as $MMUs$ em ordem decrescente de acordo com sua capacidade residual;
 - 2 Dentre as $nivel$ MMUs de maior capacidade residual, selecione aleatoriamente $kPercentPerturb$ MMUs;
 - 3 Retire todas as localidades das $kPercentPerturb$ MMUs selecionadas anteriormente e as insira na lista de localidades candidatas LC' ;
-

Após aplicado o procedimento de destruição, a solução s' é então reconstruída conforme mostrado no Algoritmo 4. No procedimento de construção, parte-se da inicialização de uma lista auxiliar com as localidades candidatas LC_{aux} , e enquanto essa lista não estiver vazia, a localidade c de maior demanda é selecionada (linha 3), e caso houver uma MMU com capacidade suficiente para atender a demanda dessa localidade (linha 4), ela será inserida na posição cuja soma das distâncias percorridas pela MMU, seja a menor, e por isso, será removida da lista de localidades candidatas LC' . Por fim, a localidade c é removida da lista LC_{aux} .

A cada iteração do laço principal (linhas 2 a 8) é feita uma tentativa de inserir uma localidade candidata em uma rota da solução, e caso seja possível realizar a inserção, a localidade candidata é removida da lista de candidatas inicial LC' .

Algoritmo 4: Construção

Entrada: s, LC'
Saída: s ,

- 1 $LC_{aux} \leftarrow LC'$;
- 2 **enquanto** $LC_{aux} \neq \emptyset$ **faça**
- 3 $c \leftarrow$ Selecione a localidade de maior demanda $\in LC_{aux}$;
- 4 **se** *houver uma MMU com capacidade para atender a demanda de c* **então**
- 5 Insira c na posição de menor custo de inserção de s ;
- 6 $LC' \leftarrow LC' \setminus \{c\}$;
- 7 **fim**
- 8 $LC_{aux} \leftarrow LC_{aux} \setminus \{c\}$;
- 9 **fim**

4.7 *Smart Iterated Greedy Search* - *Smart IGS*

O funcionamento do *Smart IGS* do qual derivou-se os dois algoritmos propostos *Smart IGS-VND* e *Smart IGS-RVND* é apresentado no Algoritmo 5. Neste algoritmo, parte-se da inicialização de uma lista LC com as localidades que são candidatas a serem inseridas na solução. Em seguida, é gerada uma solução inicial s_0 na qual será realizada uma busca por um ótimo local corrente (linhas 2 e 3), gerando uma solução intermediária s . A cada iteração (linhas 8 a 28) a solução corrente s é parcialmente destruída de acordo com um nível de intensidade (linha 11), e reconstruída pelo procedimento de construção (linha 12). A solução reconstruída s'' é então submetida ao procedimento de busca local (linha 13).

Caso a solução ótima local, s'' , seja melhor que a solução s corrente, ou seja, caso a demanda total atendida na solução s'' seja maior, ou se caso as duas soluções atenderam a mesma demanda e a soma das distâncias percorridas em s'' for a menor, esta passará a ser então a solução corrente (linha 15), e dessa forma, a lista de candidatas é atualizada com as localidades que foram removidas da solução e não foram reinseridas na fase de construção (linha 16), e o índice de iteração em que houve melhora *melhorIter*, o nível de perturbação *nivel*, e o número de tentativas antes de aumentar o nível de perturbação *tentativas*, são reiniciados (linha 17 a 19).

Caso não haja melhorias na solução e o número máximo de tentativas de melhora for alcançado, o número de tentativas é reiniciado (linhas 21 e 22), e o nível de perturbação é incrementado se o seu valor for menor que o nível máximo de perturbação *nivelMax*-

Perturb (linhas 23 e 24). Senão, caso o número máximo de tentativas de melhora não tenha sido alcançado, o número de tentativas é incrementado (linha 27). O algoritmo é executado enquanto o número máximo de iterações sem melhora no valor da função de avaliação, $maxIter$, não for atingido.

Algoritmo 5: *Smart Iterated Greedy Search*

Entrada: $maxIter$, $maxTentativasMelhora$

Saída: s

```

1 Inicializa  $LC$  com as localidades candidatas;
2  $s_0 \leftarrow GeraSolucaoInicial(LC)$ ;
3  $s \leftarrow BuscaLocal(s_0)$ ;
4  $iter \leftarrow 0$ ;
5  $melhorIter \leftarrow iter$ ;
6  $nivel \leftarrow 1$ ;
7  $tentativas \leftarrow 1$ ;
8 enquanto  $iter - melhorIter < maxIter$  faça
9    $iter \leftarrow iter + 1$ ;
10   $LC' \leftarrow LC$ ;
11   $s' \leftarrow Destruicao(s, nivel, LC')$ ;
12   $s'' \leftarrow Construcao(s', LC')$ ;
13   $s'' \leftarrow BuscaLocal(s'')$ ;
14  se  $f_{dem}(s'') > f_{dem}(s)$  ou ( $f_{dem}(s'') = f_{dem}(s)$  e  $f_{dist}(s'') < f_{dist}(s)$ ) então
15     $s \leftarrow s''$ ;
16     $LC \leftarrow LC'$ ;
17     $melhorIter \leftarrow iter$ ;
18     $nivel \leftarrow 1$ ;
19     $tentativas \leftarrow 1$ ;
20  senão
21    se  $tentativas \geq maxTentativasMelhora$  então
22       $tentativas \leftarrow 1$ ;
23      se  $nivel < nivelMaxPerturb$  então
24         $nivel \leftarrow nivel + 1$ ;
25      fim
26    senão
27       $tentativas \leftarrow tentativa + 1$ ;
28    fim
29  fim
30 fim

```

Capítulo 5

Experimentos Computacionais

Neste capítulo, são apresentados os experimentos realizados e os resultados alcançados com a abordagem proposta. A Seção 5.1 especifica o ambiente de desenvolvimento dos algoritmos propostos e a configuração do equipamento utilizado para testá-los. A Seção 5.2 apresenta os cenários considerados durante os experimentos. Na Seção 5.3, são caracterizadas as instâncias geradas para testar os algoritmos propostos. A Seção 5.4 apresenta a calibração dos parâmetros dos algoritmos junto aos valores que foram assumidos, e por fim, na Seção 5.5 os resultados alcançados são analisados e discutidos.

5.1 Ambiente de Desenvolvimento e Testes

O algoritmo proposto foi desenvolvido na linguagem C++, usando o compilador gcc 9.3.0. Todos os testes foram realizados em um computador com processador Intel Core i7-9750, CPU @2.60GHz, com 16 GB de memória RAM sob o sistema operacional Linux Ubuntu, versão 20.04.1 LTS.

5.2 Descrição dos Cenários de Teste

Foram criados três cenários de testes para validar o algoritmo proposto. Estes cenários são compostos por um conjunto de localidades candidatas a constituir uma solução, e um conjunto de instâncias formadas por frotas de veículos de diferentes capacidades.

Para a elaboração dos cenários de testes foram utilizadas as informações relativas

as 853 localidades que compõem o estado de Minas Gerais. As demandas de cada localidade foram obtidas por meio do Departamento de Informática do SUS (DATASUS), e esses dados são do censo de 2010 realizado pelo IBGE, projetado para o ano de 2020. Nessa projeção, a demanda total no Estado foi de 1727487 exames de mamografia. As distâncias entre cada par de localidades foram obtidas por meio da API Google Maps, considerando-se o deslocamento por carro.

O modelo de programação matemática desenvolvido em Souza et al. (2020) foi aplicado em uma primeira etapa para simular a atual distribuição dos mamógrafos fixos no Estado de Minas Gerais e identificar localidades desprovidas desses equipamentos ou em número insuficiente para atendê-las. De acordo com as informações obtidas pelo DATASUS, em Setembro de 2019, Minas Gerais possuía 326 mamógrafos. Com essa quantidade de mamógrafos disponíveis no estado, 274 localidades tiveram a sua demanda atendida por eles. Essa demanda representa um total de 1146490 exames.

Um total de 579 localidades não foram atendidas parcial ou integralmente pelos mamógrafos fixos. Verifica-se que 13 delas têm um mamógrafo fixo instalado, mas ainda possuem demanda a ser atendida. A demanda total das localidades não atendidas é de 464.410 exames.

Após a identificação das localidades desassistidas por um mamógrafo fixo em Minas Gerais e das suas respectivas demandas, foram formulados três cenários em que seria possível atender essas localidades. Estes cenários são apresentados na Tabela 5.1. A coluna *Cenário*, exibe o identificador do cenário; a coluna *Localidades*, corresponde a quantidade de localidades candidatas; *Demanda Total*, mostra a demanda total das localidades candidatas; *Depósitos*, apresenta os depósitos que foram considerados; e por fim, a coluna *Instâncias*, indica as instâncias que foram consideradas durante os testes em cada cenário.

Tabela 5.1: Características dos cenários propostos

Cenário	Localidades	Demanda Total	Depósitos	Instâncias
1	579	464410	Patrocínio / Belo Horizonte	i1 - i8
2	579	464410	Patrocínio / Belo Horizonte	i9 - i13
3	211	63841	Belo Horizonte	i14 - i25

Foram considerados dois depósitos para os cenários de 1 e 2. O primeiro depósito na localidade de Patrocínio, por sediar o Hospital do Câncer de Patrocínio Dr. José

Figueiredo que nos forneceu as informações para caracterizar o problema abordado, e o segundo depósito é localizado em Belo Horizonte, a capital do Estado. No cenário 3, consideramos apenas o depósito de Belo Horizonte por estar mais próximo da maior parte das localidades candidatas.

Nos testes com o primeiro cenário foram utilizadas as instâncias de i1 a i8 que são compostas por frotas de MMUs de capacidade para realizar 5069 exames anuais. No segundo cenário, foram utilizadas as instâncias de i9 a i13 na qual as MMUs possuem capacidade para realizar 10138 exames anuais.

Para o cenário 3, foi estabelecido que um mês é o tempo máximo que uma MMU deve permanecer em uma localidade para atendimento. Dessa forma, foram identificadas 211 localidades com uma demanda capaz de ser totalmente atendida em um período máximo de um mês, e a demanda total dessas localidades é de 63.841 exames. Neste cenário, foram utilizadas as instâncias de i14 a i25, na qual a capacidade das MMUs é fornecida de acordo com a quantidade de meses que ela poderá permanecer fora do depósito realizando os atendimentos.

5.3 Características das Instâncias

Cada instância define a quantidade de MMUs disponíveis para serem usadas nos cenários propostos, e também a capacidade de cada MMU disponível. A Tabela 5.2 apresenta as características destas instâncias. A coluna *Instância*, mostra o identificador da instância; *MMUs Disp.* mostra quantas MMUs compõe a frota de cada depósito; e *Cap. MMUs*, apresenta a capacidade disponível de cada MMU. As instâncias estão divididas de acordo com o cenário em que foram utilizadas.

O primeiro cenário é constituído por 8 instâncias, enquanto que o segundo cenário conta com 5 instâncias. Foi considerado nestas instâncias a aquisição gradativa de MMUs de 8 em 8 para simular os cenários a fim de obter a cobertura máxima de atendimentos com o menor número de MMUs utilizadas. O cenário 5 é composto por 12 instâncias que possuem uma única MMU, e que se diferenciam entre si pela capacidade deste veículo.

As MMUs usadas nos atendimentos possuem um ou dois mamógrafos instalados. De acordo com a nota técnica divulgada pelo Instituto Nacional de Câncer (INCA, 2015b), a capacidade de produção de um mamógrafo simples é calculada da seguinte forma:

Tabela 5.2: Características das Instâncias

	Instância	MMUs Disp.	Cap. MMUs
Cenário 1	i1	1 / 1	5069
	i2	8 / 8	5069
	i3	16 / 16	5069
	i4	24 / 24	5069
	i5	32 / 32	5069
	i6	40 / 40	5069
	i7	48 / 48	5069
	i8	56 / 56	5069
Cenário 2	i9	1 / 1	10138
	i10	8 / 8	10138
	i11	16 / 16	10138
	i12	24 / 24	10138
	i13	32 / 32	10138
Cenário 3	i14	0 / 1	422
	i15	0 / 1	845
	i16	0 / 1	1267
	i17	0 / 1	1690
	i18	0 / 1	2112
	i19	0 / 1	2534
	i20	0 / 1	2957
	i21	0 / 1	3379
	i22	0 / 1	3802
	i23	0 / 1	4224
	i24	0 / 1	4646
	i25	0 / 1	5069

número de mamógrafos \times 3 exames/hora \times turno trabalho de 8h \times 22 dias \times 12 meses \times desempenho de 80% = **5069 mamografias/ano**.

Neste cálculo, considera-se que é possível realizar três mamografias por hora, em um turno de 8 horas diárias de trabalho, o total de dias úteis no mês durante um ano, e a utilização do equipamento com 80% de sua capacidade. Dessa forma, uma MMU equipada com um mamógrafo é capaz de realizar 5069 exames de mamografia anualmente, enquanto que uma MMU com dois mamógrafos é capaz de realizar o dobro desta quantidade, isto é, 10138 exames anualmente.

Nas instâncias do cenário 3, a capacidade da MMU é definida de acordo com um período de atendimento. Consideramos um período de atendimento gradativo de 1 a 12 meses, e por isso, nas instâncias deste cenário a capacidade da MMU é calculada conforme a quantidade de meses que os atendimentos poderão durar e não anualmente como nas instâncias dos demais cenários. Como por exemplo, se substituirmos na fórmula de cálculo da capacidade do mamógrafo o período de 12 meses por um período de 1 mês,

encontraríamos que a capacidade mensal do mamógrafo é de 422 exames (instância i14), e se substituirmos por 2 meses a capacidade seria de 845 exames (instância i15), e assim sucessivamente até a capacidade anual de 5069 exames (instância i25).

5.4 Calibração dos Parâmetros

Para a aplicação dos algoritmos propostos é necessária a definição de quatro parâmetros, sendo eles o número máximo de iterações sem melhora (*maxIter*); o número máximo de rotas que podem ser perturbadas (*nivelMaxPerturb*); o número máximo de tentativas de melhora na solução antes que se possa aumentar o nível da perturbação (*maxTentativasSemMelhora*); e, por fim, *kPercentPerturb*, que corresponde à porcentagem de rotas que serão selecionadas aleatoriamente para serem perturbadas dentre as *nivelMaxPerturb* rotas de maior capacidade residual. Os valores assumidos por esses parâmetros foram definidos pela ferramenta *irace*. A Tabela 5.3 apresenta os valores considerados para a calibração de cada parâmetro em cada cenário.

Tabela 5.3: Valores sugeridos ao *irace* para cada parâmetro do algoritmo.

<i>maxIter</i>	100	200	500						
<i>nivelMaxPerturb</i>	5	30	40	60	80				
<i>maxTentativasSemMelhora</i>	1	3	5	7	9				
<i>kPercentPerturb</i>	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1,0

Os parâmetros dos algoritmos propostos foram calibrados usando-se um subconjunto das instâncias de cada cenário com características distintas. No primeiro cenário foram consideradas as instâncias i2, i4 e i6; no segundo cenário usamos as instâncias i10 e i12; e no terceiro cenário, as instâncias i16, i20 e i24. As combinações retornadas pelo *irace* estão apresentadas na Tabela 5.4.

Como pode ser observado pela Tabela 5.4, os melhores valores retornados pelo *irace* para o parâmetro *maxTentativasSemMelhora* foram superiores à uma unidade. Assim, esse resultado mostra que a versão *Smart* IGS é superior à versão IGS original.

Tabela 5.4: Melhores combinações de valores de parâmetros retornadas pelo *irace*

Cenário	Algoritmo	<i>maxIter</i>	<i>nivelMaxPerturb</i>	<i>maxTentativasSemMelhora</i>	<i>kPercentPerturb</i>
1	<i>Smart</i> IGS-VND	100	60	3	0,9
	<i>Smart</i> IGS-RVND	100	40	5	0,8
2	<i>Smart</i> IGS-VND	200	30	7	0,8
	<i>Smart</i> IGS-RVND	100	60	3	0,8
3	<i>Smart</i> IGS-RVND	100	5	5	0,7

5.5 Resultados

Nesta seção, abordamos os resultados alcançados pelos algoritmos *Smart* IGS-VND e *Smart* IGS-RVND durante os experimentos computacionais considerando os cenários e as instâncias apresentadas nas seções anteriores. Os resultados estão divididos entre a média e o melhor resultado encontrado em 30 execuções. O tempo de execução dos algoritmos foi limitado para até 1200 segundos. A melhor solução é aquela cuja demanda total atendida seja a maior, e caso duas soluções apresentarem a mesma demanda total atendida, a melhor é aquela cuja distância total percorrida pelas MMUs seja a menor.

Os resultados obtidos nos cenários 1 e 2 com o algoritmo *Smart* IGS-VND são mostrados nas Tabelas 5.5 e 5.6, respectivamente. As colunas dessas tabelas são descritas da seguinte forma: *Inst.* mostra o identificador da instância; *MMUs* mostra a quantidade de MMUs usadas em cada depósito (como exemplo, 1 / 1 indica que 1 MMU do depósito de Patrocínio foi usada e 1 do depósito de Belo Horizonte); *Loc.* apresenta a quantidade de localidades atendidas pelas MMUs de cada depósito; *Dem.* mostra a demanda total atendida pelas MMUs de ambos os depósitos; *Cob. (%)* equivale ao percentual de cobertura em relação à demanda inicial de 464.410 exames, *Dist.* (km) é a distância total percorrida pelas MMUs de ambos os depósitos e, por fim, *Tempo* (s) representa o tempo gasto, em segundos, para encontrar a solução.

Na Tabela 5.5, para atender toda a demanda das 579 localidades candidatas foram necessárias em média 102,7 MMUs, e a média da distância total percorrida por esses veículos foi de 57693,5 km. Na melhor solução encontrada, foram necessárias 104 MMUs para cobrir 100% da demanda e a distância total percorrida foi de 56344 km.

Os resultados alcançados no cenário 2 com *Smart* IGS-VND estão na Tabela 5.6. Neste cenário, foram necessárias em média 53 MMUs que percorreram um total de

Tabela 5.5: Resultados alcançados no Cenário 1 com o *Smart IGS-VND*

<i>Smart IGS-VND</i>												
Inst.	Média						Melhor					
	MMUs	Loc.	Dem.	Cob. (%)	Dist. (km)	Tempo (s)	MMUs	Loc.	Dem.	Cob. (%)	Dist. (km)	Tempo (s)
i1	2	4	10000	2,15	597	0,05	2	4	10000	2,15	597	0,05
i2	16	51,7	80743	17,4	9465,8	0,2	16	57	80744	17,38	9156	0,5
i3	32	134,2	161449,7	34,8	17717,1	3,3	32	116	161629	34,8	19190	5
i4	48	196,9	241786,3	52,1	30860,9	28,6	48	197	242027	52,11	28937	27
i5	64	303,8	322398,8	69,4	41585,5	51,8	64	298	322977	69,54	41936	34
i6	80	425,9	403856,4	87	62253,3	227	80	439	404361	87,07	62239	261
i7	95,9	577	463532	99,8	59014,8	159,9	96	579	464410	100	58588	127
i8	102,7	579	464410	100	57693,5	622,1	104	579	464410	100	56344	543

37915,5 km para obter a cobertura máxima de exames. No melhor resultado, foram usadas 52 MMUs para cobrir 100% da demanda e a distância total percorrida reduziu para 36361 km. Como neste cenário cada MMU possui dois mamógrafos instalados, a quantidade necessária de MMUs para atender a todas as localidades candidatas foi reduzida quase pela metade, quando comparamos com os resultados do cenário 1.

Tabela 5.6: Resultados alcançados no Cenário 2 com o *Smart IGS-VND*

<i>Smart IGS-VND</i>												
Inst.	Média						Melhor					
	MMU	Loc.	Dem.	Cob. (%)	Dist. (km)	Tempo (s)	MMU	Loc.	Dem.	Cob. (%)	Dist. (km)	Tempo (s)
i9	2	11	20259	5,65	678	0,02	2	11	20259	5,65	678	0,02
i10	16	120,4	161986,1	34,9	14136,3	3	16	111	162044	34,89	14009	3
i11	32	285,6	324007,4	69,8	33424,5	38,6	32	275	324146	69,79	36655	40
i12	48	571,2	461440,4	99,4	40454,1	78,3	48	577	464044	99,92	40260	233
i13	53	579	464410	100	37915,5	812,8	52	579	464410	100	36361	940

Como pode ser observado nas Tabelas 5.5 e 5.6, o percentual de uso da capacidade das MMUs foi superior a 90%. Como exemplo, na primeira solução apresentada na Tabela 5.5 utilizou-se uma MMU de capacidade 5069 por cada depósito, totalizando uma capacidade disponível de 10138 exames. A demanda total atendida foi de 10000 exames; dessa forma, a taxa de utilização das MMUs foi de 99%.

A Tabela 5.7 mostra os resultados obtidos no cenário 1 com o algoritmo *Smart IGS-RVND*. Neste cenário, foram necessárias em média 99,81 MMUs de capacidade 5069 para atender toda a demanda das 579 localidades candidatas, que corresponde a

464.410 exames, e foi percorrida uma distância média de 54906,54 km. Observando a melhor solução encontrada, nota-se que foram necessárias 100 MMUs para atender toda a demanda e a distância total percorrida de 53843 km. Além disso, em uma outra instância deste cenário o atendimento de 100% da demanda total foi alcançado utilizando 96 MMUs, valor abaixo da média, e que percorreram uma distância total de 54150 km.

A Tabela 5.8 apresenta os resultados obtidos no cenário 2. Observa-se que na solução de melhor média nos resultados, foram necessárias em média 51,9 MMUs para atender a demanda de todas as 579 localidades candidatas, e foi percorrida uma distância média de 36202,6 km. Na melhor solução encontrada, foram usadas 51 MMUs que percorreram uma distância correspondente a 35232 km. Outra solução atendeu toda a demanda fazendo uso de 48 MMUs, e neste caso os veículos fizeram um percurso de 37647 km.

Tabela 5.7: Resultados alcançados no Cenário 1 pelo *Smart* IGS-RVND

<i>Smart</i> IGS-RVND												
Inst.	Média						Melhor					
	MMU	Loc.	Dem.	Cob. (%)	Dist. (km)	Tempo (s)	MMU	Loc.	Dem.	Cob. (%)	Dist. (km)	Tempo (s)
i1	2	4	10000	2,15	597	0,05	2	4	10000	2,15	597	0,05
i2	16	53,59	80718,59	17,38	9035,59	1,22	16	58	80780	17,39	9315	2
i3	32	129,27	161436	34,76	17511,31	34,76	32	140	161551	34,78	17415	6
i4	48	209,30	241925,3	52,09	28192,38	48,84	48	209	242142	52,14	28368	40
i5	64	302,56	322301,12	69,40	39808,06	86,87	64	307	322787	69,50	41496	77
i6	80	429,09	403378	86,85	57077,54	374,81	80	428	404111	87,01	61942	512
i7	95,9	576	463249,6	99,75	54754,3	274,9	96	579	464410	100	54150	185
i8	99,81	579	464410	100	54906,54	894,81	100	579	464410	100	53843	917

Tabela 5.8: Resultados alcançados no Cenário 2 pelo *Smart* IGS-RVND

<i>Smart</i> IGS-RVND												
Inst.	Média						Melhor					
	MMU	Loc.	Dem.	Cob. (%)	Dist. (km)	Tempo (s)	MMU	Loc.	Dem.	Cob. (%)	Dist. (km)	Tempo (s)
i9	2	11	20259	5,65	678	0,02	2	11	20259	5,65	678	0,02
i10	16	118,4	161973,3	34,9	14113,1	2,27	16	103	162025	34,88	13262	2
i11	32	290,8	323992	69,8	32785,6	31	32	276	324121	69,79	33346	39
i12	48	573,2	461960,6	99,5	37284,5	108,3	48	579	464410	100	37647	188
i13	51,9	579	464410	100	36202,6	509,8	51	579	464410	100	35232	684

Os Gráficos 5.1 e 5.2 mostram a relação entre o percentual de cobertura da demanda total atendida e a média da distância total percorrida pelas MMUs. O Gráfico 5.1

apresenta uma comparação a partir dos resultados alcançados no primeiro cenário pelos algoritmos *Smart* IGS-VND e *Smart* IGS-RVND. Observa-se que no *Smart* IGS-RVND, a distância total percorrida pelos veículos foi menor, sendo essa diferença mais evidente a partir de um percentual de cobertura acima de 40%. Quando o percentual de cobertura alcançou um valor acima de 86%, a distância total percorrida começou a reduzir. Neste caso, as instâncias utilizadas para os testes possuíam à disposição uma quantidade maior de MMUs.

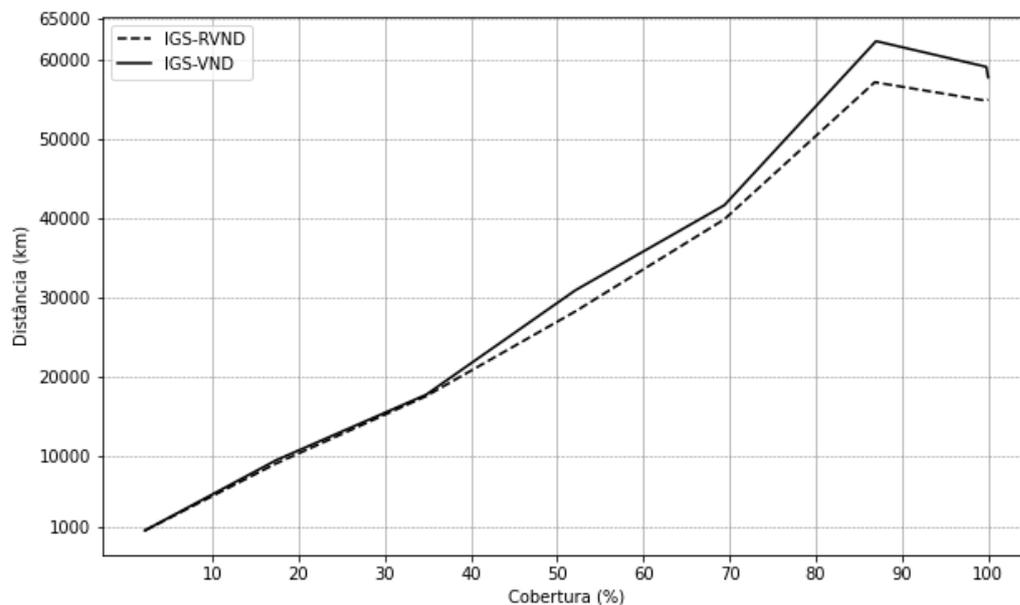


Figura 5.1: Comparativo entre distância percorrida e cobertura no cenário 1

No Gráfico 5.2 também foram comparados o percentual de cobertura da demanda total atendida e a média da distância total percorrida pelas MMUs, porém considerando os resultados do segundo cenário. As MMUs usadas neste cenário possuíam uma capacidade de realizar 10138 exames anuais (o dobro da capacidade das MMUs usadas no Gráfico 5.1). Neste cenário, o *Smart* IGS-RVND alcançou novamente uma média de distância percorrida menor se comparado ao *Smart* IGS-VND, visto que essa diferença é ainda maior quando o percentual de cobertura está acima de 70%. Quando alcançada a cobertura de 100% da demanda, houve uma redução da distância percorrida em ambos os algoritmos; neste caso, no *Smart* IGS-VND foram percorridos 37915,5 km e no *Smart* IGS-RVND a distância total foi de 36202,6 km.

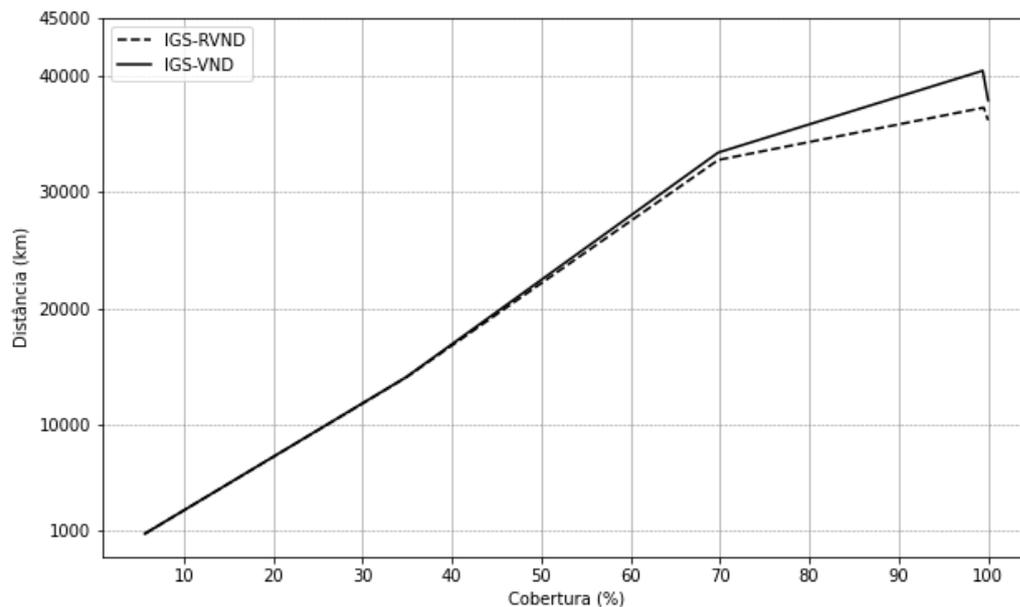


Figura 5.2: Comparativo entre distância percorrida e cobertura no cenário 2

A Tabela 5.9 apresenta os resultados alcançados no cenário 3 com o algoritmo *Smart* IGS-RVND. Este algoritmo foi escolhido por ser capaz de encontrar soluções de qualidade superior se comparado ao *Smart* IGS-VND. A coluna *Inst.* mostra o identificador da instância; *MMUs* exibe quantas MMUs foram usadas nos atendimentos; *Depósito* apresenta qual a localidade que sediou o depósito das MMUs; a coluna *Meses* mostra quantos meses foram necessários para atender a demanda total programada; *Capacidade* mostra a capacidade máxima de exames que podem ser realizados dentro do período de tempo disponível; *Localidades Atendidas* apresenta a quantidade de localidades atendidas; *Demanda Atendida* corresponde a demanda total atendida; *Capacidade Residual* é a capacidade residual da MMU após os atendimentos; e por fim, *Distância (km)* é a distância total em quilômetros percorrida pela MMU.

Os valores das soluções apresentadas na Tabela 5.9 correspondem a um planejamento mensal de atendimentos, diferente dos cenários anteriores em que o planejamento tinha um escopo anual. Nestas soluções, as demandas de cada localidade foram completamente atendidas; no entanto, as localidades candidatas a compor uma solução foram somente aquelas em que a demanda pudesse ser totalmente atendida no período máximo de um mês, ou seja, as localidades candidatas possuíam uma demanda de até 422 exames.

Tabela 5.9: Resultados alcançados pelo *Smart* IGS-RVND no cenário 3

<i>Smart</i> IGS-RVND								
Inst.	MMUs	Depósito	Meses	Capacidade	Localidades Atendidas	Demanda Atendida	Capacidade Residual	Distância (km)
i14	1	Belo Horizonte	1	422	1	422	0	294
i15	1	Belo Horizonte	2	845	2	838	7	337
i16	1	Belo Horizonte	3	1267	3	1236	31	495
i17	1	Belo Horizonte	4	1690	4	1617	73	635
i18	1	Belo Horizonte	5	2112	5	1996	116	859
i19	1	Belo Horizonte	6	2534	7	2526	8	1196
i20	1	Belo Horizonte	7	2957	8	2950	7	1390
i21	1	Belo Horizonte	8	3379	9	3371	8	1527
i22	1	Belo Horizonte	9	3802	10	3787	15	1311
i23	1	Belo Horizonte	10	4224	11	4185	39	1514
i24	1	Belo Horizonte	11	4646	12	4537	109	1658
i25	1	Belo Horizonte	12	5069	14	5052	17	1775

Observa-se que em um ano, uma MMU partindo do depósito localizado em Belo Horizonte foi capaz de atender a 14 localidades com uma demanda total de 5052 exames, percorrendo uma distância de 1775 km. Esta mesma MMU atendeu em um semestre um total de 7 localidades com uma demanda de 2526 exames, fazendo um percurso de 1196 km. O aproveitamento médio da capacidade das MMUs neste cenário ficou acima de 90%, e por isso, os resultados mostraram também uma baixa capacidade residual.

A Figura 5.3 apresenta o mapa obtido pela aplicação *Google Maps* para ilustrar uma solução para o Cenário 3. Nesta solução, foi usada uma MMU com capacidade de realizar 5069 exames anuais. O veículo parte do depósito localizado em Belo Horizonte e atende as localidades de Alvinópolis, Orizânia, São Domingos das Dores, Braúnas, Divinolândia de Minas, Conceição do Mato Dentro, Santo Antônio do Rio Abaixo, nesta ordem. A demanda total atendida nesta solução foi de 2526 exames em um percurso de 861 km.

5.5.1 Análise de Convergência

Para avaliar o desempenho dos algoritmos propostos para encontrar uma solução para o problema, foi feita uma análise de distribuição de probabilidade empírica (Aiex et al., 2007).

Para tanto, foi definido como valor alvo atender a 90% da demanda da região estudada, o que corresponde a 417.969 exames. As simulações foram feitas considerando a instância i8. Para cada simulação realizada foi fixado o tempo máximo de 60 segundos para que a demanda alvo fosse alcançada. Caso isso não ocorresse no limite máximo de

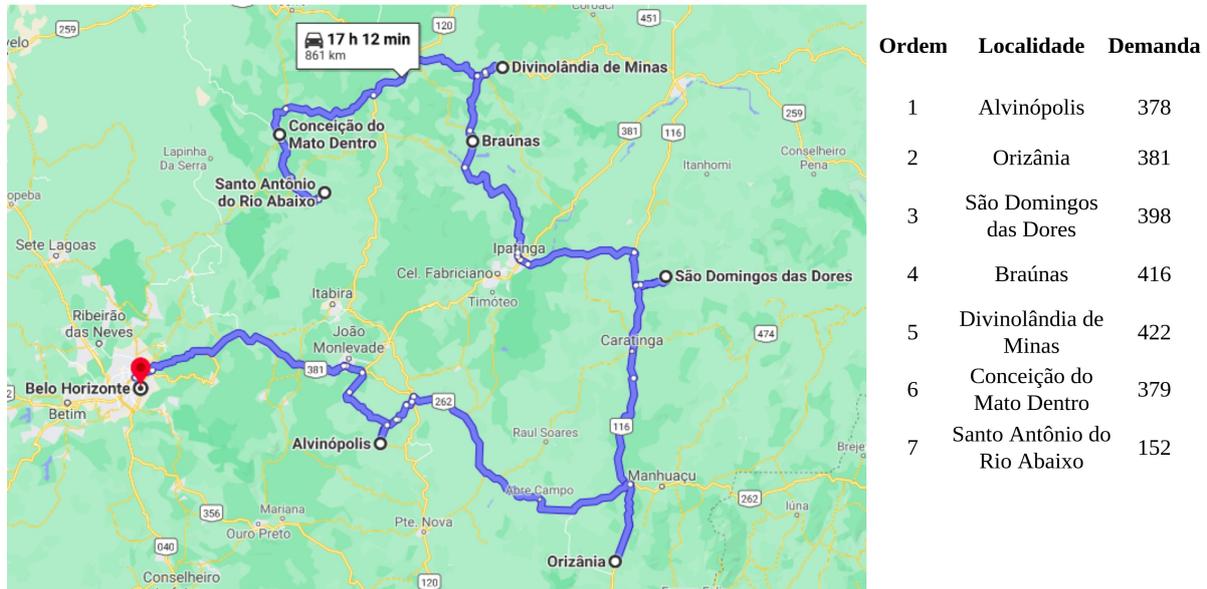


Figura 5.3: Exemplo de uma solução para o Cenário 3

tempo estabelecido, o processamento dos algoritmos era interrompido.

Para gerar os gráficos de distribuição de probabilidade empírica, foram realizados os seguintes passos: inicialmente, ambos os algoritmos foram executados 100 vezes para cada valor alvo a ser encontrado. Dentre essas 100 execuções em cada um dos algoritmos, naquelas em que o valor alvo fosse obtido com sucesso, o instante de tempo t_i processado era registrado; caso contrário, ele era ignorado. Ao final dessas execuções, os instantes de tempo t_i registrados foram ordenados crescentemente e, dessa maneira, para cada t_i bem sucedido, foi associada a probabilidade p_i de se encontrar a demanda alvo de acordo com a equação abaixo:

$$p_i = \frac{(i - 0,5)}{100} \quad \forall i = 1$$

na qual i indica o i -ésimo registro do tempo do processamento bem sucedido do valor alvo. O objetivo dessa análise foi mostrar graficamente a probabilidade p_i de os algoritmos retornarem um determinado valor alvo em função do tempo de processamento da solução no instante de tempo t_i .

A Figura 5.4 ilustra a comparação de desempenho entre os algoritmos *Smart IGS-VND* e *Smart IGS-RVND* para alcançar 90% do valor da demanda total da região estudada. Os testes foram realizados no primeiro cenário, no qual as MMUs possuem

uma capacidade de 5069 exames. Observa-se que o algoritmo *Smart IGS-VND* obteve um melhor desempenho em atingir a demanda alvo, requerendo menos tempo que o *Smart IGS-RVND*. No caso, foram necessários 17 segundos para alcançar a demanda alvo de 417.969 exames com uma probabilidade de 99,5%. Por sua vez, o *Smart IGS-RVND* requereu aproximadamente 22 segundos para alcançar esse mesmo valor alvo.

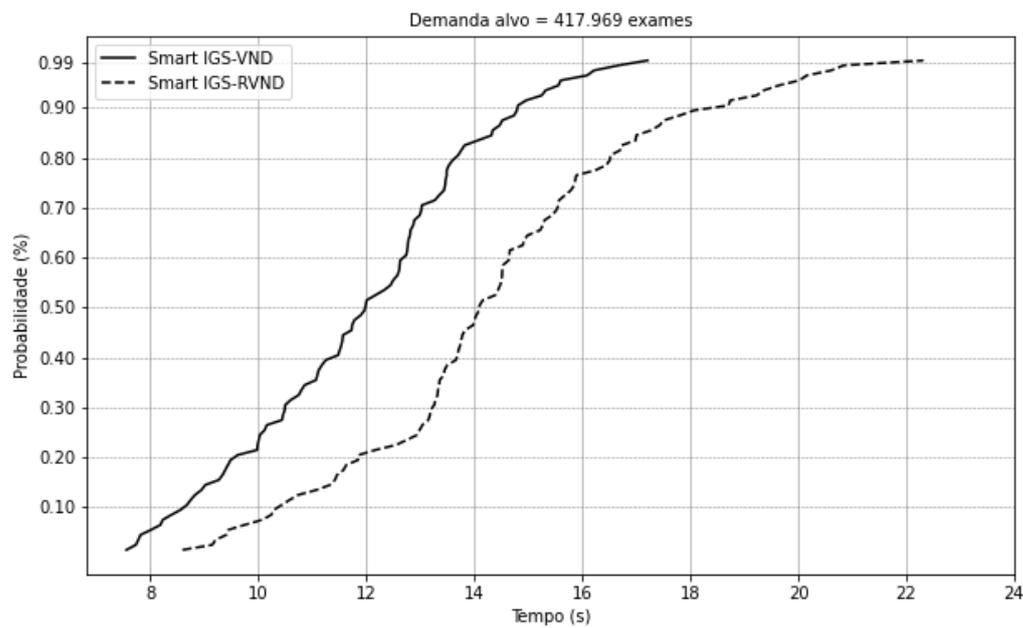


Figura 5.4: Análise de convergência com demanda alvo de 417.969 exames

Capítulo 6

Conclusões e Trabalhos Futuros

Este trabalho introduziu o Problema de Roteamento de Unidades Móveis de Mamografia (MMURP). Neste problema pretende-se roteirizar uma frota de Unidades Móveis de Mamografia (MMU) de diferentes capacidades e que estão sediadas em diferentes hospitais (isto é, os depósitos onde elas também iniciam as suas rotas). As MMUs foram usadas no atendimento às localidades que estão desprovidas de mamógrafos fixos, ou em número insuficiente deles. O objetivo deste problema é maximizar a cobertura de exames e reduzir a distância total percorrida por esses veículos.

Para resolvê-lo, foram propostos os algoritmos *Smart IGS-VND* e *Smart IGS-RVND*. Estes algoritmos são variações da metaheurística *Iterated Greedy Search* (IGS) e foram utilizados dada a dificuldade de resolver este problema na otimalidade por métodos exatos. Para gerar uma solução inicial para o problema, foi desenvolvido um procedimento de três passos. Para refinar uma solução, nós usamos os procedimentos *Variable Neighborhood Descent* (VND) e *Randomized Variable Neighborhood Descent* (RVND). Para não ficar preso em ótimos locais e explorar diferentes regiões do espaço de soluções do problema, aplicamos um procedimento para destruir a solução atual e outro para reconstruí-la de forma gulosa.

Para testar os algoritmos propostos, usamos instâncias com 579 localidades do Estado de Minas Gerais que possuíam uma demanda por exames de mamografia que não foi atendida por mamógrafos fixos. Estas localidades foram atendidas por até 56 MMUs, que partem de dois depósitos, e possuem capacidade para realizar 5069 ou 10138 exames anuais. Consideramos também uma distância de 180 km entre dois locais no máximo.

Os testes foram realizados considerando três diferentes cenários. Os experimentos

foram realizados em cada cenário considerando um conjunto de instâncias que se diferenciam entre si pela quantidade de MMUs disponíveis e pela capacidade desses veículos. No primeiro cenário, considera-se que cada MMU possui capacidade de realizar 5069 exames por ano, de outro modo, no segundo cenário considera-se que essa capacidade é de 10138 exames. No último cenário, definimos que um mês é o tempo máximo que uma MMU deve permanecer em uma localidade para atendimento. Dessa forma, foi apresentado um plano de serviço mensal para uma MMU, variando de um a doze meses.

Os resultados mostraram que os dois algoritmos encontraram soluções que atendem a 100% da demanda da região estudada. O *Smart* IGS-VND obteve um melhor desempenho quando comparamos o tempo de processamento dos algoritmos para alcançar 90% desta demanda. No entanto, quando foram comparadas a distância total percorrida pelas MMUs com a cobertura de exames, o *Smart* IGS-RVND mostrou ser capaz de encontrar soluções de melhor qualidade, reduzindo a distância total percorrida pelos veículos. Analisando estes resultados, concluímos que a aquisição de mamógrafos fixos em conjunto com a implementação do serviço de mamografia móvel, permite expandir a oferta da mamografia e facilitar o acesso aos recursos de saúde pública para população.

Como trabalhos futuros, propõe-se um estudo para conhecer como é o serviço de roteamento das Unidades Móveis de Mamografia em outras regiões do Brasil; um estudo para identificar quais as localidades mais adequadas para serem os depósitos das MMUs; e o desenvolvimento de um aplicativo para apoiar os gestores da área de saúde na definição das rotas das MMUs.

6.1 Publicação Gerada

A partir deste trabalho, o seguinte artigo foi publicado:

Título: Um algoritmo construtivo para o Problema de Roteamento de Unidades Móveis de Mamografia

Autores: Otávio A. S. Rosa, Patrick M. Rosa, Puca H. V. Penna, Marcene J. F. Souza

Evento: LII Simpósio Brasileiro de Pesquisa Operacional

Local: João Pessoa, Paraíba, Brasil

Data: 3 a 5 de Novembro de 2020

Referências Bibliográficas

- Abreu, G. R. F. e Silva, S. A. L. d. S. e. (2015). Distribuição geográfica e acesso ao mamógrafo no estado da bahia. *Revista Baiana de Saúde Pública*, 39(1):88–104.
- Aiex, R. M., Resende, M. G. C., e Ribeiro, C. C. (2007). Ttt plots: a perl program to create time-to-target plots. *Optimization Letters*, 1:355–366.
- 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*, 19(2):326–341.
- Andrade, M. V., de Souza Noronha, K. M., do Amaral, P. V. M., Barbosa, A. C. Q., de Carvalho, L. R., Calazans, J. A., Souza, M. N., de Souza, A., Rocha, T. A. H., e da Silva, N. C. (2016). Distribuição espacial dos mamógrafos em minas gerais e o efeito na probabilidade da realização do exame. *Anais do XX Encontro Nacional de Estudos Populacionais*, pages 1–21.
- Benslimane, M. T. e Benadada, Y. (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*, 51(1):31–40.
- Bhateja, V., Urooj, S., e Misra, M. (2014). Technical advancements to mobile mammography using nonlinear polynomial filters and ieee 21451-1 ncap information model. *IEEE Sensors Journal*, 15(5):2559–2566.
- Bolaños, R., Escobar, J., e Echeverri, M. (2018). A metaheuristic algorithm for the multi-depot vehicle routing problem with heterogeneous fleet. *International Journal of Industrial Engineering Computations*, 9(4):461–478.
- Brooks, S. E., Hembree, T. M., Shelton, B. J., Beache, S. C., Aschbacher, G., Schervish, P. H., e Dignan, M. B. (2013). Mobile mammography in underserved populations: Analysis of outcomes of 3,923 women. *Journal of Community Health*, 38(5):900–906.
- Browder, C., Eberth, J. M., Schooley, B., e Porter, N. R. (2015). Mobile mammography: An evaluation of organizational, process, and information systems challenges. *Healthcare*, 3(1):49–55.

- Cunha, G. N. d., Vianna, C. M. d. M., Mosegui, G. B. G., Silva, M. P. R. d., e Jardim, F. N. (2019). Rastreamento do câncer de mama: modelo de melhoria do acesso pelo uso de mamógrafos móveis. *Rev Panam Salud Publica*, 43:e19. PMC6459392.
- DeBruhl, N. D., Bassett, L. W., Jessop, N. W., e Mason, A. M. (1996). Mobile mammography: results of a national survey. *Radiology*, 201(2):433–437. PMID: 8888236.
- Fontenoy, A.-M., Langlois, A., Chang, S.-L., Daigle, J.-M., Pelletier, É., Guertin, M.-H., Thériège, I., e Brisson, J. (2013). Contribution and performance of mobile units in an organized mammography screening program. *Canadian Journal of Public Health*, 104(3):e193–e199.
- Hansen, P., Mladenović, N., e Pérez, J. A. M. (2010). Variable neighbourhood search: methods and applications. *Annals of Operations Research*, 175(1):367–407.
- INCA (2015a). Diretrizes para a detecção precoce do câncer de mama no brasil. Instituto Nacional do Câncer. Disponível em <http://twixar.me/LQrT>. Acessado em 21/03/2021.
- INCA (2015b). Revisão do parâmetro para cálculo da capacidade de produção do mamógrafo simples. Instituto Nacional do Câncer. Disponível em <http://twixar.me/bLfm>. Acessado em 21/03/2021.
- INCA (2019). A situação do câncer de mama no brasil: síntese de dados dos sistemas de informação. Instituto Nacional do Câncer. Disponível em <http://twixar.me/FQrT>. Acessado em 21/03/2021.
- Lenstra, J. K. e Rinnooy-Kan, A. H. G. (1981). Complexity of vehicle routing and scheduling problems. *Networks*, 11:221–227.
- Leung, J., McKenzie, S., Martin, J., e McLaughlin, D. (2014). Effect of rurality on screening for breast cancer: a systematic review and meta-analysis comparing mammography. *Rural & Remote Health*, 14(2):2730. PMID 24953122.
- López-Ibáñez, M., Dubois-Lacoste, J., Pérez Cáceres, L., Birattari, M., e Stützle, T. (2016). The irace package: Iterated racing for automatic algorithm configuration. *Operations Research Perspectives*, 3:43–58.
- Mil, R. D., Guillaume, E., Launay, L., Guittet, L., Dejardin, O., Bouvier, V., Notari, A., Launoy, G., e Berchi, C. (2019). Cost-effectiveness analysis of a mobile mammography unit for breast cancer screening to reduce geographic and social health inequalities. *Value in Health*, 22(10):1111 – 1118.
- Penna, P. H. V., Subramanian, A., Ochi, L. S., Vidal, T., e Prins, C. (2019). A hybrid heuristic for a broad class of vehicle routing problems with heterogeneous fleet. *Annals of Operations Research*, 273(1-2):5–74.

- Reinsma, J., Penna, P. H. V., e Souza, M. J. F. (2018). Um algoritmo simples e eficiente para resolução do problema do caixeiro viajante generalizado. *Simpósio Brasileiro de Pesquisa Operacional*.
- Renck, D. V., Barros, F., Domingues, M. R., Gonzalez, M. C., Scowitz, M. L., Caputo, E. L., e Gomes, L. d. M. (2014). Equity in access to breast cancer screening in a mobile mammography program in southern rio grande do sul state, brazil. *Cadernos de saude publica*, 30(1):88—96.
- Reuben, D. B., Bassett, L. W., Hirsch, S. H., Jackson, C. A., e Bastani, R. (2002). A randomized clinical trial to assess the benefit of offering on-site mobile mammography in addition to health education for older women. *American Journal of Roentgenology*, 179(6):1509–1514.
- Rodrigues, D. C. N., Freitas-Junior, R., Rahal, R. M. S., Correa, R. d. S., Peixoto, J. E., Ribeiro, N. V., Ferreira, N. C., e Soares, L. R. (2019). Difficult access and poor productivity: Mammography screening in brazil. *Asian Pacific Journal of Cancer Prevention*, 20(6):1857–1864.
- 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.
- Salhi, S., Imran, A., e Wassan, N. A. (2014). The multi-depot vehicle routing problem with heterogeneous vehicle fleet: Formulation and a variable neighborhood search implementation. *Computers & Operations Research*, 52(Part B):315–325.
- Salhi, S. e Sari, M. (1997). A multi-level composite heuristic for the multi-depot vehicle fleet mix problem. *European Journal of Operational Research*, 103(1):95–112.
- Souza, M. J. F., Coelho, I. M., Ribas, S., Santos, H. G., e Merschmann, L. (2010). A hybrid heuristic algorithm for the open-pit-mining operational planning problem. *European Journal of Operational Research*, 207(2):1041–1051.
- 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, pages 37–52. Springer, Cham, Switzerland.
- 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. *Simpósio Brasileiro de Pesquisa Operacional*.
- Subramanian, A., Drummond, L., Bentes, C., Ochi, L., e Farias, R. (2010). A parallel heuristic for the vehicle routing problem with simultaneous pickup and delivery. *Computers Operations Research*, 37(11):1899 – 1911. Metaheuristics for Logistics and Vehicle Routing.

- Vidal, T., Crainic, T. G., Gendreau, M., Lahrichi, N., e Rei, W. (2012). A hybrid genetic algorithm for multidepot and periodic vehicle routing problems. *Operations Research*, 60(3):611–624.
- Vidal, T., Crainic, T. G., Gendreau, M., e Prins, C. (2014). Implicit depot assignments and rotations in vehicle routing heuristics. *European Journal of Operational Research*, 237(1):15–28.
- Vieira, R. A. C., Formenton, A., e Bertolini, S. R. (2017). Breast cancer screening in brazil. barriers related to the health system. *Revista da Associação Médica Brasileira*, 63(5):466–474.
- Xavier, D. R., Oliveira, R. A. D. d., Matos, V. P. d., Viacava, F., e Carvalho, C. d. C. (2016). Cobertura de mamografias, alocação e uso de equipamentos nas regiões de saúde. *Saúde em Debate*, 40:20 – 35.