



**UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO  
UNIVERSIDADE ESTADUAL DO RIO GRANDE DO NORTE  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA  
COMPUTAÇÃO**



**SEBASTIÃO MATEUS MARQUES DE MENEZES**

**UMA ABORDAGEM MATEMÁTICA E HEURÍSTICA DO  
PROBLEMA DE ALOCAÇÃO DE PACIENTES NO  
CONTEXTO DA PANDEMIA DE COVID-19**

**MOSSORÓ**

**2022**

**SEBASTIÃO MATEUS MARQUES DE MENEZES**

**UMA ABORDAGEM MATEMÁTICA E HEURÍSTICA DO  
PROBLEMA DE ALOCAÇÃO DE PACIENTES NO  
CONTEXTO DA PANDEMIA DE COVID-19**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação - associação ampla entre a Universidade Estadual do Rio Grande do Norte e a Universidade Federal Rural do Semi-Árido, para a obtenção do título de Mestre em Ciência da Computação.

Orientador: Dr. Dario José Aloise- UERN

Coorientador: Dr. Fábio Francisco da Costa Fontes- UFERSA

**MOSSORÓ**

**2022**

**SEBASTIÃO MATEUS MARQUES DE MENEZES**

**UMA ABORDAGEM MATEMÁTICA E HEURÍSTICA DO  
PROBLEMA DE ALOCAÇÃO DE PACIENTES NO  
CONTEXTO DA PANDEMIA DE COVID-19**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação para a obtenção do título de Mestre em Ciência da Computação.

Aprovada em:

**BANCA EXAMINADORA**

---

Dr. Dario José Aloise- UERN  
Presidente

---

Dr. Fábio Francisco da Costa Fontes- UFERSA  
Primeiro Membro

---

Prof. Dr. Breno Barros Telles do Carmo- UFC  
Segundo Membro

---

Prof. Dr. Luciano Carlos Azevedo da Costa- UFPE  
Terceiro Membro

*Aos meus pais*

*Gilson Marques (In Memoriam) e*

*Marilene Menezes*

## **AGRADECIMENTOS**

À minha família por todo o apoio, motivação e amor incondicional.

Aos meus orientadores prof. Dario Aloise e prof. Fábio Fontes e também ao prof. Breno Barros pelas orientações, conhecimentos passados e pela paciência, que possibilitaram que esta pesquisa se tornasse o que é hoje.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela disponibilização de bolsa.

## RESUMO

A pandemia de COVID-19, provocada pelo vírus SARS-COV-2, disseminou-se rapidamente por vários países e as diferentes variantes do vírus têm contribuído para um elevado número de internações hospitalares. Este cenário tem sobrecarregado os sistemas de saúde tornando mais escassos os recursos hospitalares já insuficientes em situações normais, tornando-os ainda mais escassos. Além do investimento na criação de novas unidades hospitalares, a fim de prover um melhor atendimento à população, também são necessárias estratégias inteligentes que auxiliem no fluxo de atendimento dos pacientes, visto que sem métodos efetivos de alocação, os hospitais enfrentam o risco de tomar decisões mais custosas na alocação de recursos. Este trabalho apresenta um modelo de programação linear inteira bem como uma metaheurística para realizar uma alocação otimizada de pacientes com COVID-19 às unidades hospitalares. Para isto foi desenvolvido um modelo de programação matemática e uma metaheurística Busca Local Guiada considerando aspectos particulares e relevantes da pandemia no tocante ao atendimento dos pacientes, tais como a ordem de prioridade dos pacientes, a gravidade da doença neles, a distância entre suas residências e as unidades hospitalares e estratégias para encaminhamento após a lotação de recursos. Os resultados mostraram que o modelo conseguiu encontrar soluções ótimas para as instâncias de duas cidades situadas na região Nordeste do Brasil e a metaheurística desenvolvida apresentou soluções com qualidades muito próximas as do modelo, viabilizando sua aplicação para instâncias ainda maiores, onde a obtenção da solução ótima pelo modelo é inviável computacionalmente.

**Palavras-chave:** Pesquisa Operacional na área da saúde. COVID-19. Problema de Alocação de Pacientes. Programação Linear Inteira. Busca Local Guiada.

## ABSTRACT

The COVID-19 pandemic, caused by the SARS-COV-2 virus, has spread quickly across many countries and the different variants of the virus have contributed to a high number of hospital admissions. This scenario has overloaded health systems, making hospital resources even more scarce. In addition to investing in the creation of new hospital units in order to provide better care for the population, intelligent strategies are also needed to assist the flow of patient care, since without effective allocation methods, hospitals face the risk of making more costly decisions regarding resource allocation. The aim of this study is to develop an integer linear programming model and a metaheuristic algorithm to optimize the assignment of patients with COVID-19 to hospital units. For this, a mathematical programming model and a Guided Local Search were developed considering specific, relevant aspects of the pandemic with regard to patient care, such as the order of patient priority, the severity of their disease, the distance between their homes and hospitals and referral strategies after resource allocation. The results have demonstrated that the model is able to find optimal solutions for the instances of two cities located in the Northeastern region of Brazil and the developed metaheuristic presented solutions with qualities very close to the model, enabling its application to even larger instances, where obtaining the optimal solution using the model is computationally infeasible.

**Keywords:** Operations Research for Health Care. Covid-19. Patient Bed Assignment Problem. Integer Linear Programming. Guided Local Search

## LISTA DE FIGURAS

Figura 1 – Organização do sistema SEMcTrA . . . . .	12
Figura 2 – Exemplo da abordagem adotada na representação das distâncias . . . . .	25
Figura 3 – Esquema de abordagem . . . . .	28
Figura 4 – Deformação do espaço de soluções provocada pela BLG . . . . .	37
Figura 5 – Representação de uma solução na implementação realizada e as aloca- ções que ela reflete . . . . .	41
Figura 6 – Representação gráfica da primeira estrutura de vizinhança . . . . .	42
Figura 7 – Representação gráfica da segunda estrutura de vizinhança . . . . .	42

## LISTA DE TABELAS

Tabela 1 – Resumo das características e funções objetivo consideradas nos trabalhos analisados. . . . .	20
Tabela 2 – Descrição das variáveis e parâmetros do modelo. . . . .	23
Tabela 3 – Descrição e valores assumidos pelas constantes do modelo. . . . .	24
Tabela 4 – Resultados obtidos com a instância de Mossoró e Fortaleza baseado no PCOVID (pc.) para as duas configurações sob o panorama de número de alocações/encaminhamentos. . . . .	30
Tabela 5 – Resultados obtidos com as instâncias de Mossoró e Fortaleza sob o panorama das zonas de proximidade para as duas configurações. . . . .	30
Tabela 6 – Resultados obtidos com as instâncias fictícias baseado no PCOVID (pc.) para as duas configurações sob o panorama de número de alocações/encaminhamentos. . . . .	31
Tabela 7 – Resultados obtidos com as instâncias fictícias sob o panorama das zonas de proximidade para as duas configurações. . . . .	32
Tabela 8 – Média das funções objetivo de todas as instâncias . . . . .	43
Tabela 9 – Resultados obtidos com todas as instâncias sob o panorama do número de alocações/encaminhamentos. . . . .	44
Tabela 10 – Resultados obtidos com todas as instâncias sob o panorama das alocações/encaminhamentos em cada zona. . . . .	45



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>11</b>
<b>1.1</b>	<b>Objetivos</b>	<b>12</b>
<i>1.1.1</i>	<i>Objetivo Geral</i>	<i>12</i>
<i>1.1.2</i>	<i>Objetivos Específicos</i>	<i>12</i>
<b>1.2</b>	<b>Organização do Trabalho</b>	<b>13</b>
<b>2</b>	<b>O PROBLEMA DE ALOCAÇÃO DE PACIENTES NO CON- TEXTO DA PANDEMIA DE COVID-19</b>	<b>14</b>
<b>2.1</b>	<b>Introdução</b>	<b>14</b>
<b>2.2</b>	<b>Revisão da Literatura</b>	<b>16</b>
<b>2.3</b>	<b>Modelando o Patient Bed Assignment Problem no contexto da pandemia de COVID-19</b>	<b>21</b>
<i>2.3.1</i>	<i>Contextualização do problema da COVID-19 no Brasil</i>	<i>21</i>
<b>2.4</b>	<b>Apresentação do modelo</b>	<b>22</b>
<b>2.5</b>	<b>Resultados</b>	<b>28</b>
<b>2.6</b>	<b>Conclusões</b>	<b>32</b>
<b>3</b>	<b>UMA BUSCA LOCAL GUIADA PARA O PROBLEMA DE ALO- CAÇÃO DE PACIENTES NO CONTEXTO DA PANDEMIA DE COVID-19</b>	<b>34</b>
<b>3.1</b>	<b>Introdução</b>	<b>34</b>
<b>3.2</b>	<b>Revisão da Literatura</b>	<b>35</b>
<b>3.3</b>	<b>Busca Local Guiada</b>	<b>37</b>
<i>3.3.1</i>	<i>Customizações e adaptações ao problema estudado</i>	<i>39</i>
<b>3.4</b>	<b>Resultados</b>	<b>42</b>
<b>3.5</b>	<b>Conclusões</b>	<b>45</b>
<b>4</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS</b>	<b>47</b>
	<b>REFERÊNCIAS</b>	<b>49</b>

## 1 INTRODUÇÃO

A pandemia da COVID-19 foi responsável por milhões de óbitos pelo mundo. Além disso, a vida da população mundial foi drasticamente alterada, dado que, de acordo com Xiong *et al.* (2020), a pandemia causada pelo novo coronavírus trouxe sérios impactos na economia global, afetando vários setores, como o agricultura, turismo, finanças, entre outros, com o número de casos aumentando de forma rápida.

Os sistemas de saúde pelo mundo foram sobrecarregados com mais demanda do que o habitual. Decisões difíceis sobre triagem e alocação surgiram na pandemia de COVID-19, visto que a pandemia e suas sequelas criaram cenários de recursos médicos (leitos, respiradores, equipamentos hospitalares, etc) escassos (KIRKPATRICK *et al.*, 2020), trazendo luz à importância do uso de estratégias para alocação desses recursos de forma otimizada, considerando o fluxo de atendimento da COVID-19.

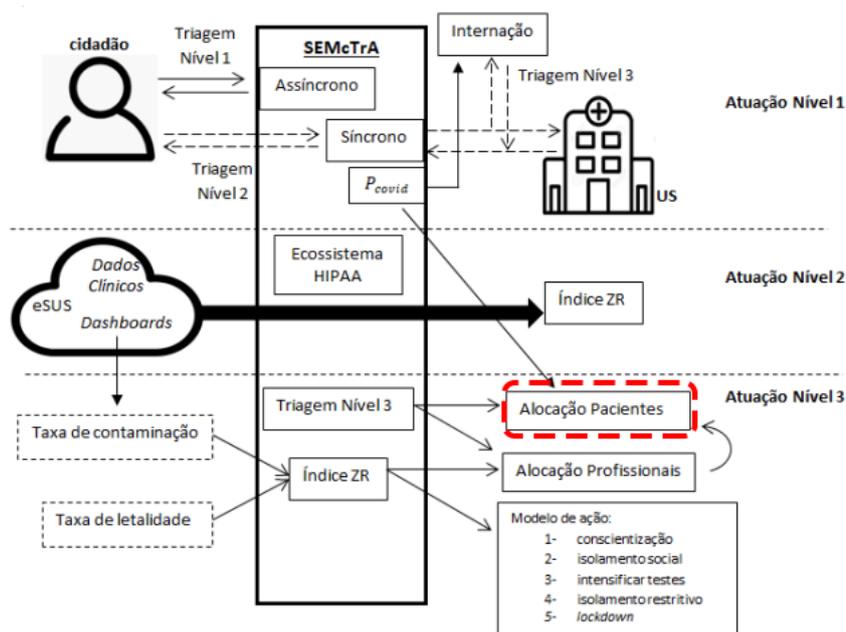
A utilização da telemedicina também pode ajudar na mitigação dos danos causados pela pandemia. O Sistema Especialista Multicamadas de Triagem Remota Inteligente e Alocação (SEMCTrA)<sup>1</sup> é um sistema especialista para triagem classificatória inteligente, que permite a organização dos fluxos de tomada de decisão e o apoio à alocação de recursos para controlar a COVID-19 no sistema público de saúde.

O SEMCTrA trabalha com a automatização inteligente dos protocolos de triagem médica, assíncrona e síncrona a partir das recomendações da triagem inteligente e a alocação dos pacientes às unidades de saúde de forma otimizada, considerando os diferentes níveis de gravidade do COVID-19, às unidades mais próximas e/ou com melhor disponibilidade de pessoal (profissionais da saúde) e de recursos hospitalares. A Figura 1 ilustra a organização e as camadas do SEMCTrA, destacando o módulo de alocação inteligente, onde o presente trabalho irá atuar.

Neste contexto, este trabalho propõe um modelo matemático, assim como uma metaheurística para otimizar a alocação de pacientes com COVID-19 a leitos hospitalares, considerando aspectos intrínsecos da pandemia, como a gravidade da doença no paciente, a distância entre os pacientes e as unidades e a disponibilidade de recursos, buscando combater a COVID-19 através da atuação no módulo de alocação do SEMCTrA.

<sup>1</sup> é um sistema online de agendamento de consultas em vídeochamadas para COVID-19, focado na mitigação de danos causados pela doença, incluindo um módulo de alocação inteligente de recursos hospitalares, no qual o presente trabalho irá atuar.

Figura 1 – Organização do sistema SEMcTrA



Fonte: Adaptado de OLIVEIRA (2020)

A busca pela otimização das alocações preenche uma lacuna encontrada na literatura, visto que não foram identificados trabalhos que buscassem desenvolver um modelo/ algoritmo de alocação de pacientes a leitos que fosse compatível com as dificuldades enfrentadas na assistência a pacientes com COVID-19. Além disso, a partir do possível ganho trazido por essa otimização, será possível mitigar os danos causados pela doença, já que a partir dos métodos desenvolvidos, as alocações serão realizadas tendo como guia aspectos cruciais do fluxo de atendimento.

## 1.1 Objetivos

### 1.1.1 Objetivo Geral

Desenvolver uma estratégia de alocação de pacientes com COVID-19 às unidades hospitalares em um cenário de pandemia, por meio da aplicação de técnicas de otimização.

### 1.1.2 Objetivos Específicos

- Caracterizar o problema de alocação de pacientes com COVID-19 no contexto da pandemia.
- Modelar matematicamente o problema de alocação de pacientes, considerando o

fluxo de atendimento.

- Customizar e implementar uma metaheurística Busca Local Guiada para resolução do problema, visando a aplicação em cidades de grande porte onde o modelo exato é inviável computacionalmente.
- Validar o modelo desenvolvido por meio de instâncias criadas a partir de dados reais.

## **1.2 Organização do Trabalho**

Esta dissertação foi desenvolvida por meio de dois artigos científicos, que se complementam, relacionados ao problema de Alocação de Pacientes às unidades hospitalares no contexto da pandemia de COVID-19. Assim sendo, o Capítulo 2 apresenta o primeiro deles, que aborda o problema, sua caracterização e formulação do modelo matemático desenvolvido bem como os resultados obtidos a partir dele. Na sequência, o Capítulo 3 engloba o segundo artigo, apresentando uma customização da metaheurística Guided Local Search (GLS) e sua implementação proposta, assim como os testes computacionais realizados e a comparação dos resultados obtidos com os do método exato. Por fim, o Capítulo 4 traz as conclusões e propostas de trabalhos futuros.

## 2 O PROBLEMA DE ALOCAÇÃO DE PACIENTES NO CONTEXTO DA PANDEMIA DE COVID-19

Neste capítulo será apresentado o primeiro artigo desta pesquisa, que apresenta um modelo de programação linear inteira para realizar uma alocação otimizada de pacientes com COVID-19 às unidades hospitalares. O modelo considera aspectos particulares e relevantes da pandemia no tocante ao atendimento dos pacientes, como a ordem de prioridade dos pacientes, a gravidade da doença neles, a distância entre suas residências e as unidades hospitalares e as estratégias para encaminhamento após a lotação de recursos.

### 2.1 Introdução

A enfermidade por coronavírus (COVID-19) foi identificada inicialmente em dezembro de 2019, na cidade de Wuhan, na China. Por se tratar de uma doença altamente contagiosa e letal, com rápida propagação, os sistemas de saúde de vários países do mundo, em pouco tempo, ficaram sobrecarregados e entraram em colapso. A Organização Mundial da Saúde (OMS) declarou pandemia de COVID-19, em 11 de março de 2020, depois de mais de 110 mil casos e 4 mil óbitos espalhados por países de todos os continentes (OMS, 2020). Dessa forma, o atendimento dos casos precisou ser realizado de forma ágil e com o menor deslocamento possível (SILVA *et al.*, 2020). De acordo com a (OMS, 2020), até abril de 2020, o quadro mundial de evolução da doença era o seguinte: 80% dos pacientes com COVID-19, apresentaram sintomas leves; 15% evoluíram para casos moderados, necessitando de hospitalização e oxigenoterapia e 5% precisando serem atendidos nas Unidades de Terapia Intensiva (UTI).

Além da rápida propagação do vírus, outro agravante da situação pandêmica de COVID-19 foi o baixo número de leitos equipados e prontos para atendimento em vários países. O estudo realizado por Sen-Crowe *et al.* (2021) mostrou que, de 183 países, 63% apresentaram um número de leitos dentro do intervalo de 0-299 leitos por cem mil habitantes, principalmente países da América do Sul e da África.

Diante da escassez de recursos devido à demanda adicional gerada pela COVID-19 e dos altos custos atrelados à construção de novas unidades hospitalares, vários estudos vêm sendo desenvolvidos com o objetivo de subsidiar a tomada de decisão quanto ao melhor uso possível dos recursos disponíveis. O estudo realizado por Melman *et al.* (2021) ressalta o impacto positivo de estratégias para alocação de recursos no tratamento de

pacientes com COVID-19, realizando simulações sobre o balanceamento de recursos entre cirurgias eletivas e atendimento de pacientes com esta enfermidade.

Além de simulações, outra técnica aplicada na resolução de problemas atrelados a pandemia da COVID-19 é a modelagem matemática. Em Mehrotra *et al.* (2020), é apresentado um modelo matemático para alocação de ventiladores pulmonares, visto que os pacientes com sintomas graves necessitam deste equipamento para o seu tratamento. A formulação desenvolvida trabalha com multi-períodos e diferentes regiões, cada uma com sua demanda.

Em contextos pandêmicos, o desenvolvimento de técnicas aplicadas para otimização do uso de recursos hospitalares ganha ainda mais relevância. Um exemplo disso é a alocação de pacientes a leitos que, se realizada de forma otimizada, proporcionará um melhor atendimento. Sun *et al.* (2014) abordam a otimização na alocação de pacientes no contexto da pandemia do vírus Influenza através da criação de modelos matemáticos, incluindo um multiobjetivo que busca minimizar a distância de acesso entre o paciente e o serviço, além de minimizar a distância máxima percorrida pelo paciente, respeitando a capacidade de recursos hospitalares disponíveis (neste modelo são considerados recursos como: leitos para cuidado intensivo, leitos normais, respiradores pulmonares, médicos e enfermeiros) e outro modelo que também ajuda a prever uma escassez de recursos durante um surto, desta forma contribuindo para a tomada de decisão sobre a solicitação de recursos hospitalares adicionais.

O trabalho de Majtrajt *et al.* (2020) aborda a otimização no contexto da COVID através do desenvolvimento de um modelo matemático acompanhado de algoritmos de busca global para alocação de vacinas. Uma comparação dos resultados é discutida considerando quatro funções-objetivo diferentes: minimização do número total de infecções sintomáticas, minimização do número total de mortes, minimização do número de casos que demandam hospitalização (em unidades de terapia não intensiva) e minimização do número de casos que demandam hospitalização em UTIs.

Uma proposta de otimização direcionada à alocação de pacientes com COVID-19 para leitos deve considerar todas as particularidades da pandemia e as características da doença. Existem discussões sobre a ética na abordagem utilizada na alocação e triagem dos recursos escassos. Alguns exemplos de abordagem são: maximizar benefícios totais (número de vidas salvas ou anos de vida ou anos com boa qualidade de vida), tratar todas as

pessoas igualmente (seleção aleatória ou primeiro a chegar será o primeiro a ser atendido) e favorecer os pacientes em pior estado (priorizar os mais graves ou priorizar os mais novos) (EMANUEL *et al.*, 2020). Assim, essas premissas também podem ser consideradas no desenvolvimento dos modelos de alocação de pacientes com COVID-19.

Os trabalhos encontrados relacionados à aplicação de técnicas de otimização na mitigação dos efeitos da pandemia se concentram nos países da América do Norte, como Estados Unidos e Canadá. Já nos países que possuem menos leitos, na sua maioria africanos e latinos, a quantidade de estudos direcionados a esse tema é bastante limitada.

Neste contexto, este artigo propõe um modelo de programação matemática para alocação otimizada de pacientes com COVID-19 às unidades hospitalares, maximizando o número de atendimentos de forma a priorizar os pacientes em estado mais grave, criando filas de atendimento quando não houver disponibilidade de recursos e considerando a distância entre os pacientes e as unidades. O modelo desenvolvido considera as características próprias do fluxo de atendimento da COVID.

O artigo está dividido da seguinte forma: na Seção 2 é apresentada uma revisão da literatura sobre problemas de alocação de pacientes. A Seção 3 traz a descrição e caracterização do problema além de introduzir e detalhar o modelo proposto. Na Seção 4 os resultados computacionais obtidos são exibidos e discutidos e na Seção 5 são apresentadas as conclusões do artigo.

## 2.2 Revisão da Literatura

Nos últimos anos, no contexto do gerenciamento e planejamento hospitalar, vários estudos focados na alocação de pacientes a leitos foram desenvolvidos. Um dos problemas que aborda essa temática é conhecido, na literatura, como o *Patient Admission Scheduling Problem* (PASP). O objetivo deste problema do PASP é possibilitar um melhor uso dos recursos críticos e maximizar o atendimento aos pacientes, através da designação dos pacientes aos leitos adequados nos departamentos apropriados, conforme a disponibilidade, as restrições médicas, as necessidades e as preferências do paciente (GUPTA; PAIVA, 2020). Na literatura também são encontrados estudos relacionados ao *Patient Bed Assignment Problem* (PBAP), classificado como um subproblema do PASP com o mesmo objetivo. A diferença é que, em algumas modelagens, o PBAP pode não considerar as datas de admissão e de alta de um paciente.

É possível encontrar a alocação de leitos a pacientes sendo abordada sob várias perspectivas diferentes na literatura. Alguns trabalhos consideram salas hospitalares com um número de leitos e fazem a alocação de pacientes a estas salas (como em (DEMEESTER *et al.*, 2010), (CESCHIA; SCHAERF, 2011) e (CESCHIA; SCHAERF, 2012)). Outros alocam diretamente pacientes aos leitos (como em (TARAMASCO *et al.*, 2020) e (ARGUELLO-MONROYA *et al.*, 2021)). Algumas características foram destacadas nos estudos analisados. A disponibilidade de recursos é o aspecto principal deste tipo de problema, sendo importante observar como os modelos abordam essa característica.

Outros aspectos importantes nos modelos e que possuem relação com a situação pandêmica também foram considerados, como a abordagem dos modelos com respeito às unidades hospitalares (se eles trabalham com uma ou múltiplas unidades hospitalares), se a distância é abordada pelos modelos (distância entre as unidades ou entre as unidades e as residências dos pacientes) e também a capacidade do modelo de lidar com isolamento e risco de superlotação. Essas são características que possuem relação com a pandemia de COVID-19. Outros aspectos mais gerais também foram observados, como as transferências e o período de estadia dos pacientes.

Nos estudos identificados e analisados, nove abordam o PASP ((DEMEESTER *et al.*, 2010), (CESCHIA; SCHAERF, 2011), (BILGIN *et al.*, 2012), (CESCHIA; SCHAERF, 2012), (VANCROONENBURG *et al.*, 2013), (RANGE *et al.*, 2014), (CESCHIA; SCHAERF, 2014), (LUSBY *et al.*, 2016), (TURHAN; BILGEN, 2017) e quatro o PBAP ((THOMAS *et al.*, 2013), (GUIDO *et al.*, 2018), (TARAMASCO *et al.*, 2020), (ARGUELLO-MONROYA *et al.*, 2021)). As soluções adotadas são o desenvolvimento de modelos matemáticos (inteiros ou inteiros mistos), além da aplicação de heurísticas e metaheurísticas.

O trabalho de Demeester *et al.* (2010) descreveu e modelou o PASP, propondo restrições *soft* (aquelas que não necessariamente precisam ser satisfeitas, mas é desejável que sejam) e *hard* (aquelas que devem ser satisfeitas para uma solução ser considerada praticável) que representavam bem o problema. O modelo proposto tem como objetivo atender as necessidades dos pacientes por meio da minimização da soma das penalidades atribuídas às restrições não validadas. Para instâncias de grande porte, é apresentada uma metaheurística Busca Tabu como forma de resolução.

O estudo realizado por Ceschia e Schaerf (2011) introduziu o conceito da versão

dinâmica do PASP (onde a data de admissão e de alta do paciente são desconhecidas) e apresentou uma reformulação das restrições da versão clássica do problema, apresentando um novo modelo matemático, bem como um procedimento de busca local em várias vizinhanças. Bilgin *et al.* (2012) propôs uma hiper-heurística aplicada ao PASP e também ao problema do escalonamento de enfermeiros. Outra contribuição foi o desenvolvimento de novas instâncias para o PASP.

O estudo realizado por Ceschia e Schaerf (2012) apresentou um novo modelo matemático reduzido para a admissão de pacientes. A modelagem foi realizada para a versão dinâmica do problema, permitindo a chegada de novos pacientes em momentos imprevisíveis, além de considerar situações em que a admissão de um paciente pode ser adiada, dependendo da gravidade do seu estado. A proposta de solução apresentada consiste em uma implementação do *Simulated Annealing* com quatro vizinhanças de buscas locais.

Vancroonenburg *et al.* (2013) também desenvolveram outra abordagem dinâmica para o problema através de dois modelos de programação linear inteira. O primeiro modelo visa alocações ótimas para pacientes recém chegados, realizando as atribuições antes da chegada dos pacientes e considerando apenas a disponibilidade das salas. Já o segundo modelo considera chegadas futuras que já estão registradas.

Uma ferramenta que auxilia na tomada de decisão de hospitais através de recomendações periódicas sobre alocação de pacientes a leitos foi desenvolvida no trabalho de Thomas *et al.* (2013). O sistema recebe dados em tempo real do hospital e resolve através de um modelo matemático inteiro misto. Range *et al.* (2014) abordou o PASP através do desenvolvimento de uma heurística baseada no *Branch and Bound* e o método de geração de colunas, com agregação dinâmica de restrições para ajudar a reduzir a formulação do problema.

Em Ceschia e Schaerf (2014), os autores revisitam mais uma vez o PASP dinâmico, propondo uma nova reformulação do problema através da adição de restrições da utilização de salas de cirurgia, além de estender o modelo apresentado no trabalho anterior para uma melhor administração do adiamento e incerteza sobre o período de estadia de um paciente. Lusby *et al.* (2016) apresentam uma formulação do PASP dinâmico baseada no trabalho de Ceschia e Schaerf (2012), acrescentando uma heurística gulosa na criação de soluções iniciais.

Turhan e Bilgen (2017) abordaram o PASP através do desenvolvimento de um modelo matemático inteiro misto e duas heurísticas: *Fix-and-Relax* e *Fix-and-Optimize*. As soluções são geradas a partir da decomposição do problema em subproblemas, separando pacientes de acordo com a preferência de cada um e o período de estadia.

O trabalho de Guido *et al.* (2018) apresenta três modelagens diferentes para o PBAP. A primeira apresenta um modelo composto apenas por restrições *hard*. A segunda formulação relaxa algumas dessas restrições, transformando-as em *soft*, objetivando obter um maior conjunto de soluções viáveis. Já o terceiro modelo foi desenvolvido para alocação de pacientes com comorbidade e permanência em períodos consecutivos.

Taramasco *et al.* (2020) apresentam um modelo que trabalha a partir de restrições *soft* de forma que a função objetivo maximize a soma dessas restrições que foram satisfeitas. O diferencial desta formulação reside no fato dela considerar um grupo de hospitais, de forma que, quando não houver disponibilidade de leitos em um hospital, o paciente será encaminhado a outro, utilizando a distância como parâmetro. Entretanto, o modelo não trabalha com distância entre pacientes e hospitais, mas com a distância entre uma unidade “central” e as demais. Além do modelo, também é apresentada uma metaheurística baseada no equilíbrio líquido vapor para resolução do problema

Finalmente, uma maior variedade de maneiras de classificar e priorizar pacientes é apresentada em Arguello-Monroya *et al.* (2021). O modelo desenvolvido também considera vários níveis de isolamento e recursos que podem estar atrelados aos leitos e define pesos para fazer o cálculo de recompensas ao alocar pacientes à leitos considerados ideais. A função objetivo busca maximizar a soma ponderada das recompensas menos as penalidades por não satisfazer as metas do hospital. A Tabela 1 resume as principais características dos trabalhos analisados.

Dentre as características consideradas, dos 13 trabalhos avaliados, todos abordaram a disponibilidade limitada de recursos e 11 consideraram o período de estadia do paciente e as transferências. Um ponto de destaque é o isolamento de alguns pacientes em caso de necessidade, que foi abordado em 5 trabalhos, além do risco de superlotação, incluído em 4 pesquisas.

É importante ressaltar também que alguns aspectos relevantes foram tratados em poucos trabalhos, como é o caso das múltiplas unidades hospitalares, que apareceu somente em um estudo. A distância, que também é um aspecto significativo, só foi considerada em

Tabela 1 – Resumo das características e funções objetivo consideradas nos trabalhos analisados.

Trabalhos	Características						Abordagem de solução	Função objetivo
	Disponibilidade de recursos	Múltiplas unidades hospitalares	Período de estadia do paciente	Distância	Transferências	Isolamento de pacientes		
Demeester <i>et al.</i> (2010)	X		X	X	X		Busca Tabu	Minimizar a soma ponderada da penalidade total incorrida na alocação de pacientes a salas não ideais e o número de transferências
Ceschia e Schaerf (2011)	X		X	X			<i>Simulated Annealing</i>	Minimizar a soma ponderada do custo de cada atribuição de paciente a sala e a penalidade total incorrida por violar as políticas de gênero e o número de transferências.
Ceschia e Schaerf (2012)	X		X	X		X	<i>Simulated Annealing</i>	Minimizar a soma ponderada do custo de cada atribuição de paciente a sala, a penalidade incorrida por violar as políticas de gênero e o risco de superlotação.
Bilgin <i>et al.</i> (2012)	X		X	X			Híper-heurística	Minimizar a soma ponderada da penalidade total incorrida por violações da restrição de gênero, violações da restrição de transferência e violações das restrições de sala
Vancroonenburg <i>et al.</i> (2013)	X		X	X		X	Programação inteira	Minimizar a soma dos custos de atribuição relacionados à adequação de alocar um paciente à uma sala em uma unidade de tempo, com o número de conflitos de gênero e o número de transferências.
Thomas <i>et al.</i> (2013)	X		X	X	X		Programação inteira mista	Maximizar a soma ponderada dos benefícios obtidos com a alocação de pacientes a leitos, menos as penalidades por desviar-se dos requisitos e metas do hospital.
Range <i>et al.</i> (2014)	X		X	X			Geração de colunas	Minimizar a soma das penalidades incorridas na alocação nos horários das salas.
Ceschia e Schaerf (2014)	X		X	X		X	<i>Simulated Annealing</i>	Minimizar o total de penalidades associadas à alocação de pacientes às salas durante sua estadia.
Lusby <i>et al.</i> (2016)	X		X	X		X	Busca adaptativa em grandes vizinhanças	Minimizar as penalidades atribuídas a alocar um paciente à uma sala por uma noite somada, o custo das transferências, o risco de superlotação e as penalidades de atraso de admissão e violação de gênero.
Turhan e Bilgen (2017)	X		X	X	X		Heurísticas baseadas em programação inteira mista	Minimizar o custo total de alocar pacientes a quartos, o custo de violação da política de gênero de quarto e o custo associado a uma transferência.
Guido <i>et al.</i> (2018)	X		X	X			Matheurística.	Minimizar a penalidade incorrida ao alocar um paciente a uma sala com base na compatibilidade com a especialidade do departamento onde o quarto está localizado, o equipamento preferido e a preferência do paciente na categoria de quarto multiplicada pelo número de noites em que o paciente está hospedado.
Taramasco <i>et al.</i> (2020)	X	X		X		X	Algoritmo do equilíbrio líquido-vapor	Maximizar a soma ponderada das restrições soft que foram satisfeitas.
Arguello-Monroya <i>et al.</i> (2021)	X			X	X		Busca Tabu e algoritmo guloso	Maximizar a soma ponderada das recompensas obtidas pela alocação de pacientes a leitos, menos as penalidades por desviar-se das metas do hospital.

Fonte: Autoria Própria (2022)

um trabalho, através da busca pela minimização da distância entre um hospital central e outro hospital que o paciente foi alocado, ou seja, a distância real entre a residência do paciente e a unidade hospitalar não esteve presente em nenhum dos artigos examinados.

Todos os estudos analisados abordaram a alocação eficiente de pacientes aos leitos, objetivando suprir as necessidades dos pacientes e fazer um melhor uso dos recursos hospitalares disponíveis. Entretanto, nenhum trabalho abordou a alocação de pacientes sob a ótica de uma pandemia e, conseqüentemente, para este contexto, vários aspectos importantes não foram abordados por esses trabalhos, como estratégias de priorização e encaminhamento após a lotação de recursos. Além disso, o fluxo de atendimento de pacientes (ordem na fila) com COVID-19 também deve ser modelado de forma que represente a situação real, dado que nenhum dos trabalhos identificados abordou as especificidades dessa doença.

Portanto, considerando a análise destes artigos, foi identificada uma lacuna que o presente estudo pretende explorar, a saber: a falta de um método de otimização para alocação de pacientes que faça o melhor uso dos recursos hospitalares disponíveis e que considere todos os aspectos intrínsecos de uma pandemia, como as diferentes gravidades da doença.

## **2.3 Modelando o Patient Bed Assignment Problem no contexto da pandemia de COVID-19**

Neste tópico será apresentado o modelo desenvolvido para o PBAP no contexto da pandemia de COVID-19, o qual foi testado com três instâncias obtidas a partir das cidades brasileiras Mossoró-RN, Fortaleza-CE e São Paulo-SP, podendo ser aplicado em situações semelhantes.

### ***2.3.1 Contextualização do problema da COVID-19 no Brasil***

A situação no Brasil é particularmente preocupante, já que, de acordo com o MINISTÉRIO DA SAÚDE (2020b), até o dia 31 de dezembro de 2021, foram registrados mais de 22 milhões de casos e mais de 619 mil óbitos. Isso fez com que a demanda gerada pela COVID-19 aumentasse ainda mais a escassez dos serviços e recursos hospitalares. No estudo de Noronha *et al.* (2020), foram realizadas simulações da demanda extra gerada pela doença em diferentes cenários e com diferentes taxas de infecção nas regiões brasileiras. Os resultados mostraram que várias regiões de saúde operariam além de sua capacidade, comprometendo o atendimento dos pacientes com casos mais severos da doença.

Como o Brasil possui o Sistema Único de Saúde (SUS), este exerce um papel importante no combate ao coronavírus. De acordo com Conte *et al.* (2020), o desafio do SUS está associado às desigualdades geográficas, bem como à desproporção de recursos para acesso. Considerando apenas os leitos públicos, vários locais do país apresentam uma quantidade aquém do mínimo que seria necessário (RACHE *et al.*, 2020). Um exemplo é a região Norte, onde mais de 90% dos leitos de UTI pertencem ao setor privado (MINISTÉRIO DA SAÚDE, 2020a).

De acordo com o MINISTÉRIO DA SAÚDE (2020b), os pacientes com COVID-19 estão divididos em 3 (três) níveis de gravidade da doença, os casos leves, moderados e

graves, além dos assintomáticos. Os casos leves são caracterizados pela presença de sintomas não específicos, como tosse, dor de garganta ou coriza, entre outros. Já os casos moderados podem incluir desde sinais leves da doença, como tosse persistente e febre persistente diária, até sinais de piora progressiva de outro sintoma relacionado à COVID-19. Por fim, são considerados casos graves aqueles que apresentam dispneia/desconforto respiratório, pressão persistente no tórax ou saturação de oxigênio menor que 95% em ar ambiente ou coloração azulada de lábios ou rosto.

Além das diferentes gravidades da doença, outro aspecto relevante no fluxo de atendimento é a alocação de pacientes às unidades hospitalares mais próximas da sua residência, para que haja um menor deslocamento (SILVA *et al.*, 2020). Destaca-se ainda a necessidade de priorização de pacientes em estado mais grave e a definição de estratégias para o pós-lotação das unidades. Esses elementos foram estabelecidos como norteadores para o desenvolvimento do modelo e caracterização do problema.

Para representar o problema matematicamente, algumas alterações foram realizadas nas restrições dos estudos analisados, principalmente no trabalho apresentado por Taramasco *et al.* (2020), objetivando obter uma maior adequação ao problema enfrentado. A função objetivo busca estabelecer uma alocação de leitos otimizada para os pacientes, priorizando aqueles que se encontram em estado mais grave, respeitando a ordem de entrada nas filas de cada gravidade, satisfazendo as necessidades de tratamento, considerando a distância entre a residência deles e as unidades de saúde e encaminhando a uma unidade de saúde aqueles pacientes que não conseguiram um leito vago, para que possam conseguir um melhor atendimento médico.

A partir de alterações nas restrições já existentes e adições de novos elementos característicos da situação enfrentada e considerando ainda as lacunas identificadas nos trabalhos analisados, foi possível caracterizar o problema e desenvolver a modelagem matemática para resolução.

## **2.4 Apresentação do modelo**

Na modelagem proposta, os pacientes possuem uma necessidade de recursos hospitalares de acordo com o estado de gravidade da doença, sendo alocados às unidades que são compatíveis com essa necessidade, ou seja, unidades que possuem os recursos necessários para o tratamento.

De acordo com a SECRETARIA MUNICIPAL DE SAUDE DE MOSSORO (2021), cidade localizada na região Nordeste do Brasil, diante do cenário pandêmico atual vivenciado pela pandemia da COVID-19, os pacientes com sintomas leves são alocados às Unidades Básicas de Saúde (UBS), pacientes com sintomas moderados são designados aos Centros de Referência e os pacientes com sintomas graves são alocados às Unidades de Pronto Atendimento (UPAs). No modelo, cada unidade hospitalar apresenta uma disponibilidade de vagas, que podem ser de mais de um tipo (UBS, Centro de Referência ou UPAs), ou seja, uma mesma unidade pode oferecer recursos para pacientes com sintomas leves, moderados e graves, por exemplo.

As seguintes premissas foram consideradas para a modelagem do problema: (i) aspectos que podem agravar os sintomas da COVID-19, como idade e comorbidade do paciente devem estar representadas na gravidade de cada paciente; (ii) quando uma unidade hospitalar sinalizar a disponibilidade de um leito é entendido que recursos como equipamentos hospitalares e profissionais da área médica também estão disponíveis. As variáveis e parâmetros do modelo são apresentados na Tabela 2.

Tabela 2 – Descrição das variáveis e parâmetros do modelo.

<b>Conjuntos</b>	
<b>Descrição</b>	<b>Nomenclatura</b>
Conjunto de todas as unidades de saúde	$M = \{1, 2, \dots, m\}$
Conjunto de todos os tipos de recurso	$S = \{1, 2, \dots, s\}$
Conjunto dos recursos existentes na unidade $h$	$U_h$ , com $h = 1 \dots m$
Conjunto de todos os pacientes	$N = \{1, 2, \dots, n\}$
<b>Constantes</b>	
<b>Descrição</b>	<b>Nomenclatura</b>
Desconto no custo da função objetivo quando os pacientes são encaminhados às unidades de saúde	$\alpha$ , com $0 < \alpha < 1$
Recurso do tipo $t$ na unidade $h$	$R_{ht}$ , com $h = 1 \dots m$ e $t = 1 \dots s$
Disponibilidade do recurso do tipo $t$ na unidade $h$	$C_{ht}$ , com $h = 1 \dots m$ e $t = 1 \dots s$
Gravidade da doença no paciente $p$	$PCOVID_p$ , com $p = 1 \dots n$
Zona de proximidade do paciente $p$ para a unidade $h$	$D_{hp}$ , com $h = 1 \dots m$ e $p = 1 \dots n$
<b>Variáveis de decisão</b>	
<b>Descrição</b>	<b>Nomenclatura</b>
Paciente $p$ é alocado a uma vaga de leito do tipo $t$ na unidade $h$ .	$x_{htp}$ , com $h = 1 \dots m$ , $t = 1 \dots s$ e $p = 1 \dots n$
Paciente $p$ é encaminhado para a fila de um leito do tipo $t$ na unidade $h$ .	$y_{htp}$ , com $h = 1 \dots m$ , $t = 1 \dots s$ e $p = 1 \dots n$

A modelagem considera duas variáveis binárias. A primeira delas ( $x_{htp}$ ) visa alocar os pacientes às vagas priorizando aqueles que apresentarem um estado mais grave, respeitando a ordem e considerando a distância entre as residências dos pacientes e as unidades hospitalares. A segunda variável ( $y_{htp}$ ) estabelece uma fila para atendimento nas unidades hospitalares daqueles pacientes que não conseguiram ser alocados às vagas, ao encaminhá-los para estruturas compatíveis com suas necessidades, tendo como critério a distância.

A variável binária  $x_{htp}$ , que assumirá o valor 1 quando o paciente  $p$  é alocado a uma vaga num leito do tipo  $t$  da unidade  $h$  ou 0 caso contrário. De forma semelhante, em situações onde há excesso de pacientes, a variável binária  $y_{htp}$  assumirá o valor 1 quando o paciente  $p$  é encaminhado para a fila de um leito do tipo  $t$  na unidade  $h$  ou 0 caso contrário.

Cada unidade tem seus recursos definidos em  $R_{ht}$ , de forma que se uma unidade possuir um determinado recurso, a matriz terá o valor do recurso no índice do recurso, isto é, caso a unidade 1 possua o recurso do tipo 2,  $R_{12}$  terá o valor 2. Caso contrário, a constante terá o valor 0 naquele índice. A disponibilidade desses recursos é representada em  $C_{ht}$ , com a quantidade de leitos disponíveis. O parâmetro  $PCOVID_p$  varia entre 1 e 3, definindo a gravidade da doença em cada paciente. A Tabela 3 ilustra os valores que cada constante pode assumir.

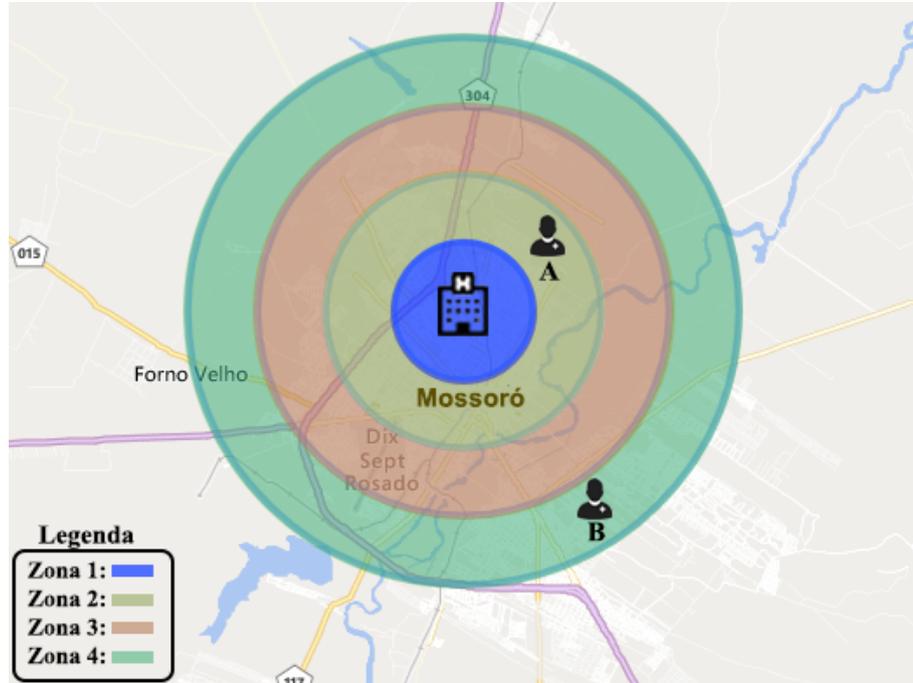
Tabela 3 – Descrição e valores assumidos pelas constantes do modelo.

Constante	Valores	Descrição
$R_{ht}$	1, 2 ou 3	Os valores irão representar se aquela unidade atende as necessidades de um determinado recurso. No caso específico da COVID, 1 está representando recursos para casos leves, 2 está representando recursos para casos moderados e 3 está representando recursos para casos graves.
$C_{ht}$	0 e números inteiros positivos	Os valores irão representar a quantidade de leitos de um determinado recurso na unidade.
$PCOVID_p$	1, 2 ou 3	Os valores irão representar a gravidade da doença em cada paciente. No caso específico da COVID, 1 está representando sintomas leves, 2 sintomas moderados e 3 sintomas graves
$D_{hp}$	1, 2, 3, 4 ou 5	Os valores irão representar a zona de proximidade entre um determinado paciente e uma unidade. Enquanto menor o valor, mais próximo o paciente se encontra da unidade

As distâncias entre as unidades e os pacientes são representadas através de zonas de proximidade, definidas pelo parâmetro  $D_{ht}$ . Cada zona assume um valor, que representa um raio de distância a partir de cada unidade, de forma que cada paciente estará dentro de determinada zona para cada unidade hospitalar. Um exemplo dessa abordagem de zonas apresentado na Figura 2, com 5 zonas, onde o paciente A está na zona 2 da unidade e o paciente B está na zona 4 da unidade. Um paciente estará na zona 5 caso ele não esteja em

nenhuma das outras.

Figura 2 – Exemplo da abordagem adotada na representação das distâncias



Fonte: Autoria Própria (2022)

A representação das distâncias através de zonas foi adotada objetivando balancear a função objetivo, visto que utilizando as distâncias representadas por quilômetros poderia desequilibrar o modelo, fazendo com que ele considerasse mais a distância do que outros aspectos (no caso de pacientes próximos) ou considerasse outros aspectos sem dar relevância para as distâncias (no caso de pacientes distantes).

O modelo matemático considera o seguinte problema de programação linear inteira:

*Maximizar*

$$\sum_{h \in M} \sum_{t \in U_h} \sum_{p \in N} (n^{PCOVID_p} - p)(x_{htp} + \alpha y_{htp}) + \sum_{h \in M} \sum_{t \in U_h} \sum_{p \in N} \frac{1}{pD_{hp}}(x_{htp} + \alpha y_{htp}) \quad (2.1)$$

*S.T*

$$\sum_{h \in M} \sum_{t \in U_h} (x_{htp} + y_{htp}) = 1 \quad \forall p \in N \quad (2.2)$$

$$PCOVID_p(x_{htp} + y_{htp}) = R_{ht}(x_{htp} + y_{htp}) \quad \forall p \in N, \forall t \in U_h, \forall h \in M \quad (2.3)$$

$$\sum_{p \in N} x_{htp} \leq C_{ht} \quad \forall t \in U_h, \forall h \in M \quad (2.4)$$

$$x_{htp} \in \{0, 1\} \quad \forall h \in M, \forall t \in U_h, \forall p \in N \quad (2.5)$$

$$y_{htp} \in \{0, 1\} \quad \forall h \in M, \forall t \in U_h, \forall p \in N \quad (2.6)$$

A função objetivo apresentada na Equação (2.1) possui dois termos com finalidades distintas. O primeiro visa maximizar as alocações de pacientes com COVID-19, respeitando a ordem de entrada no sistema dentro de cada grupo de gravidade da doença e priorizando os mais graves. Os pacientes excedentes são encaminhados para filas na unidade compatível mais próxima respeitando os mesmos critérios dos pacientes alocados às vagas. O segundo termo inclui a distância do paciente para a unidade de saúde tanto para alocação quanto para encaminhamento para as filas das unidades, mantendo sempre a ordem de entrada no sistema.

A priorização dos pacientes mais graves é realizada através da exponenciação entre o número de pacientes e o *PCOVID* de cada paciente, pois, desta forma, o modelo entenderá que os casos mais graves serão favorecidos. Já a ordem de chegada é priorizada com a subtração entre a exponenciação e a ordem de chegada do paciente. Por fim, o parâmetro  $0 < \alpha < 1$ , será uma penalização para que o modelo priorize alocações em vez de encaminhamentos.

Vale ressaltar que o segundo termo da função objetivo não vai se sobrepor ao primeiro, visto que ele sempre terá um valor muito pequeno devido a fração com o número 1 de numerador e valores mais altos no denominador, servindo apenas como desempate, ou seja, a distância entre o paciente e a unidade não irá decidir quem será alocado e encaminhado, mas irá otimizar o conjunto definido pelo primeiro termo.

A Restrição (2.2) garantem que cada paciente  $p$  será alocado a uma vaga em uma unidade ou encaminhado a uma fila. As Restrições (2.3) asseguram que um paciente  $p$  só será alocado ou encaminhado a uma determinada unidade de saúde  $h$  se o tipo de recurso  $R_{ht}$  dessa unidade for compatível com a necessidade dele, representada pelo *PCOVID* <sub>$p$</sub> . As Restrições (2.4) garantem que cada unidade de saúde  $h$  só poderá alocar um número de

pacientes que seja menor ou igual a sua capacidade (quantidade de vagas)  $C_{ht}$ . Finalmente, as Restrições (2.5) e (2.6) garantem que as variáveis de decisão  $x_{htp}$  e  $y_{htp}$  só poderão assumir valores binários.

O modelo trabalha com duas configurações no tocante à alocação de pacientes às unidades com recursos compatíveis. Estas diferentes configurações são obtidos com a alteração em uma das restrições do modelo. Optando pela restrição com a igualdade entre gravidade do paciente e o nível de recurso da unidade (conjunto de Restrições 2.3), o modelo realiza as alocações/encaminhamentos de forma que um paciente só será alocado/encaminhado a uma unidade se ela possuir o recurso que trata exclusivamente sua gravidade. Já a restrição tendo a condição de menor igual, que são as Restrições (2.7) descritas a seguir, uma nova configuração de alocações é explorada, pois um paciente pode ser alocado a mais de um tipo de unidade, desde que ela possua recursos que tratem sua gravidade da doença ou com uma gravidade superior. Vale destacar que o modelo não irá perder a característica de priorização dos pacientes em estado mais grave.

$$PCOVID_p(x_{htp} + y_{htp}) \leq R_{ht} \quad \forall p \in N, \forall t \in U_h, \forall h \in M \quad (2.7)$$

Alguns pré-processamentos foram feitos no modelo para reduzir o gasto de memória durante a resolução. O conjunto dos tipos de recurso foi reduzido de forma que uma variável só será alocada na memória caso a unidade representada na variável possua determinado recurso. Além disso, foram feitos pré-processamentos específicos para cada configuração de alocação, onde o conjunto dos pacientes foi reduzido de acordo com a restrição de alocação utilizada.

O modelo matemático foi implementado por meio do Cplex Concert Technology C++. A versão 20.10 do Cplex foi utilizada para resolver o modelo.

A Figura 3 ilustra como o modelo matemático funciona e sua importância na tomada de decisão relacionada à alocação de leitos para pacientes com COVID-19. A partir da localização e disponibilidade dos leitos das unidades de saúde e da localização e gravidade dos pacientes, o modelo fornece a melhor combinação que: (i) respeita a ordem de entrada dos pacientes em cada grupo de gravidade; (ii) respeita as necessidades e limitações das unidades de saúde e; (iii) considera a distância e encaminha pacientes excedentes para filas em unidades compatíveis próximas.

Figura 3 – Esquema de abordagem



Fonte: Autoria Própria (2022)

## 2.5 Resultados

Objetivando testar o modelo, foram criadas instâncias baseadas em dados reais das cidades brasileiras de Mossoró-RN, Fortaleza-CE e São Paulo-SP. Essas instâncias são de diferentes tamanhos, possibilitando uma observação do comportamento do modelo com diferentes volumes de dados. Para auxiliar na criação, foi desenvolvido um gerador de instâncias.

Quanto à localização, o gerador calcula a distância entre coordenadas geográficas e, a partir desse cálculo e dos raios desejados, gera as zonas de distância entre as unidades e os pacientes. O gerador também consegue escolher coordenadas aleatórias dentro de um retângulo, útil para espalhar pacientes/unidades em uma determinada cidade usando como parâmetro as coordenadas que delimitam aquela cidade.

Para geração do PCOVID dos pacientes, o gerador trabalha com a estatística da OMS, ou seja, a partir do número de pacientes, são criados 80% deles com sintomas leves, 15% com sintomas moderados e 5% com sintomas graves. Além disso, a ordem de entrada dos pacientes é feita de forma aleatória (OMS, 2020).

Como as instâncias representam um dia de alocação, o número de pacientes de cada instância foi definido como um pico no número de casos de COVID-19 na cidade que é representada pela instância. Além disso, no caso das UBS, na prática, elas não trabalham com uma capacidade de pacientes, elas atendem pacientes na medida que eles forem chegando, respeitando a ordem. Devido a essa particularidade, todas as UBS foram representadas nas instâncias com capacidade igual a 0, dessa forma, o modelo encaminha pacientes para as filas nas UBS.

A primeira instância é baseada nos dados reais da cidade de Mossoró-RN. Foram coletadas junto às unidades de saúde as capacidades totais de leitos disponibilizados ao

tratamento de COVID-19 bem como as suas coordenadas geográficas. A instância é composta por 230 pacientes, pico de casos que ocorreu no dia 13 de abril de 2021 e pelas unidades públicas de Mossoró que proveem atendimento ao coronavírus: 33 UBS, 1 Centro de Referência (que está localizado junto à uma UPA) e 3 UPAs. O local da residência dos pacientes é simulado através da geração de pontos espalhados por Mossoró no gerador de instância. Foram consideradas cinco zonas de distância, com os raios variando em 1.5 quilômetros.

Objetivando observar o comportamento do modelo com um volume de dados maior do que a instância de Mossoró, foi desenvolvida uma instância baseada nos dados da cidade de Fortaleza-CE. A instância é composta por 7994 pacientes, pico de casos que ocorreu no dia 10 de abril de 2021 e por 124 unidades de saúde, sendo 113 UBS, 6 Centros de Referência e 5 UPAs. As localizações das unidades e dos pacientes foram geradas de forma aleatória e espalhadas pela cidade. As disponibilidades das UPAs são dados reais, retirados do site da Câmara Municipal de Fortaleza. As disponibilidades dos Centros de Referência foram geradas de forma aleatória, variando entre 60 e 80. Foram consideradas cinco zonas de distância, com os raios variando em 5 quilômetros.

Vale destacar que a diferença de valores entre os raios das zonas de Mossoró e de Fortaleza é devido a área de Mossoró ser de aproximadamente 2100 km<sup>2</sup>, enquanto que a de Fortaleza é de aproximadamente 312441 km<sup>2</sup>.

Para visualizar a resolução do modelo em uma cidade de maior porte, foi desenvolvida uma instância baseada na cidade de São Paulo. A instância é composta por 484 unidades de saúde, sendo 449 UBS, 20 Centros de Referência e 15 UPAs, e 8646 pacientes, pico registrado no dia 01 de abril de 2021. A cidade de São Paulo possui um total de 469 UBS. Na definição da instância, foram assumidas 20 dessas unidades como Centros de Referência. As localizações das unidades e dos pacientes foram definidas aleatoriamente, a partir de pontos espalhados pela cidade. Foram consideradas cinco zonas de distância, com os raios variando em 12 quilômetros. Na disponibilidade, valores aleatórios foram utilizados, onde a disponibilidade dos Centros de Referência variava entre 40 e 60 e a disponibilidade das UPAs variava entre 20 e 30.

Nos testes realizados, foram considerados as duas configurações, de forma que a diferença entre cada configuração consiste na mudança no grupo de Restrições (3) pelo (7). Todos os testes foram executados utilizando Cplex 10.20 em um computador com

processador Intel i5 8400, 16GB de memória RAM e 1TB de HD. O sistema operacional foi o Windows 10, 64 bits.

A Tabela 4 ilustra os resultados obtidos com as instâncias de Mossoró e Fortaleza sob o panorama do número de alocações/encaminhamentos nas duas configurações e a Tabela 5 apresenta os resultados sob o panorama das zonas de proximidade nas duas configurações. Para o caso da cidade de São Paulo, o Cplex não conseguiu resolver a instância devido a um erro causado pela falta de memória.

Tabela 4 – Resultados obtidos com a instância de Mossoró e Fortaleza baseado no PCOVID (pc.) para as duas configurações sob o panorama de número de alocações/encaminhamentos.

Instância	Configuração 1						Configuração 2					
	Alocações			Encaminhamentos			Alocações			Encaminhamentos		
	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3
Mossoró	0	23	9	184	11	3	0	23	9	184	11	3
Fortaleza	0	426	170	6395	773	230	0	426	170	6395	773	230

Fonte: Autoria Própria (2022)

Tabela 5 – Resultados obtidos com as instâncias de Mossoró e Fortaleza sob o panorama das zonas de proximidade para as duas configurações.

Instância	Configuração 1					Configuração 2				
	Alocações/ Encaminhamentos					Alocações/ Encaminhamentos				
	Zona 1	Zona 2	Zona 3	Zona 4	Zona 5	Zona 1	Zona 2	Zona 3	Zona 4	Zona 5
Mossoró	163	44	8	10	5	165	46	6	9	4
Fortaleza	7182	673	81	46	12	7376	494	71	38	15

Fonte: Autoria Própria (2022)

A Tabela 4 mostra o número de alocações/encaminhamentos por gravidade do paciente nas duas instâncias e a partir dela é possível visualizar que os resultados nas duas instâncias para as duas configurações apresentaram resultados iguais. Essa igualdade dos resultados ocorreu porque o objetivo com a mudança na restrição de alocação não é possibilitar um maior número de alocações e sim mais opções para que o modelo consiga minimizar ainda mais a distância. Desta forma, é importante que em ambas as configurações o número de alocações/encaminhamentos seja igual pois mostra que os resultados obtidos são válidos.

Um fator importante que pode ser diferente nas duas configurações são as distâncias de alocação dos pacientes, a Tabela 5 ilustra os resultados sob essa ótica e mostra que o modelo está conseguindo otimizar esta parte, visto que, nas duas instâncias, a maior parte dos pacientes foram alocados/encaminhados a unidades bem próximas de suas

residências. Vale ressaltar que a configuração 2 conseguiu otimizar ainda mais a distância, principalmente para a instância de Fortaleza, que obteve um aumento no número de pacientes 194 pacientes em zonas de proximidade 1 com relação a configuração 1.

Por fim, nos testes com a instância baseada em São Paulo, o modelo deu erro de falta de memória na resolução, não sendo possível chegar a nenhuma solução viável para esta instância. Portanto, se faz necessário um método baseado no modelo desenvolvido que consiga resolver instâncias de grande porte.

Visto que entre as instâncias existem grandes intervalos no número de unidades hospitalares/pacientes, foram desenvolvidas instâncias fictícias objetivando visualizar o comportamento do modelo de forma mais progressiva e com instâncias que possuem diferentes características.

Para preencher o intervalo entre as instâncias de foram criadas a FICT45 com 45 unidades e 2000 pacientes, a FICT60 com 60 unidades e 2500 pacientes e a FICT90 com 90 unidades e 5000 pacientes. Já para o intervalo entre as instância de Fortaleza e São Paulo, foi criada a instância FICT150, com 150 unidades e 8000 pacientes. Vale ressaltar que como um dos objetivos visualizar os resultados obtidos com instâncias que possuíssem características distintas das testadas anteriormente, as capacidades das UBS não foram preenchidas com o valor 0 e a estatística da OMS não foi seguida, em vez disso foram utilizadas distribuições uniformes. A Tabela 6 ilustra os resultados obtidos com as instâncias fictícias trazendo o número de alocações/encaminhamentos. Já a Tabela 7 mostra os resultados obtidos com as instâncias fictícias sob o panorama das zonas de proximidade. Para a instância FICT150, o modelo não conseguiu resolver devido a um erro causado pela falta de memória, indicando que instâncias do tamanho da de Fortaleza são o limite máximo do modelo.

Tabela 6 – Resultados obtidos com as instâncias fictícias baseado no PCOVID (pc.) para as duas configurações sob o panorama de número de alocações/encaminhamentos.

Instância	Configuração 1						Configuração 2					
	Alocados			Encaminhados			Alocados			Encaminhados		
	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3
FICT45	61	221	278	599	519	322	61	221	278	599	519	322
FICT60	145	182	248	680	743	502	145	182	248	680	743	502
FICT90	455	267	128	1195	1583	1372	455	267	128	1195	1583	1372

A partir dos resultados da Tabela 6, é possível destacar que o comportamento do modelo com as instâncias fictícias se manteve correto, com um número de alocações/enca-

Tabela 7 – Resultados obtidos com as instâncias fictícias sob o panorama das zonas de proximidade para as duas configurações.

Instância	Configuração 1					Configuração 2				
	Alocados/ Encaminhados					Alocados/ Encaminhados				
	Zona 1	Zona 2	Zona 3	Zona 4	Zona 5	Zona 1	Zona 2	Zona 3	Zona 4	Zona 5
FICT45	1848	97	18	17	20	1857	88	18	17	20
FICT60	2335	114	28	16	7	2402	47	28	16	7
FICT90	4859	109	18	6	8	4892	76	18	6	8

minhamentos válido. Além disso, a Tabela 7 mostra que o modelo conseguiu produzir um resultado com as características semelhantes ao resultado das instâncias baseadas em dados reais, com a configuração 2 tendo mais pacientes alocados/encaminhados para unidades em zonas de proximidade 1. Estes resultados são relevantes pois mostram que o modelo também produz soluções otimizadas para instâncias de tamanho de uma cidade de médio porte.

## 2.6 Conclusões

A alocação de pacientes com COVID-19 a leitos hospitalares é um problema complexo, que envolve recursos escassos e estratégias de priorização. Diante desse cenário, este trabalho propôs um modelo matemático para otimizar essa alocação, considerando aspectos particulares importantes desta pandemia.

Vale destacar que algumas características presentes no modelo podem ser adaptadas para ajudar no combate a outras doenças contagiosas, no que diz respeito a alocação de pacientes às unidades hospitalares. O primeiro termo da função objetivo pode ser aproveitado no desenvolvimento de outras estratégias aplicadas a outras enfermidades, principalmente quando houver uma escassez de recursos hospitalares. O segundo termo também pode ser utilizado em outras situações visto que a importância da distância de locomoção do paciente é um fator considerável em várias situações.

Além disso, a forma de representar a gravidade da doença em um paciente também pode ser adaptada para outras doenças contagiosas, bastando redefinir o parâmetro PCOVID para um que englobe todas as possibilidades de gravidades da situação enfrentada.

O modelo matemático desenvolvido representa um dia de alocação e trabalha com três gravidades da doença em pacientes, além de múltiplas unidades de saúde equipadas com três diferentes graus de recursos. A ordem de chegada dos pacientes foi sempre respeitada e também foram adotadas estratégias de priorização dos pacientes em estado mais grave. A distância entre as residências dos pacientes e as unidades de saúde foi utili-

zada como um importante critério nas alocações/encaminhamentos, visto que possibilitar deslocamentos menores foi entendido como um fator importante. Além disso, também foi implementado o encaminhamento de pacientes que não conseguiram vagas diretas.

Outro aspecto relevante adicionado ao modelo foi a opção de alteração entre diferentes critérios na realização da alocação, possibilitando a adaptação do modelo a situações diferentes, através da busca em diferentes espaços de solução, sem perder as características importantes para mitigação da pandemia.

O principal desafio que o modelo apresenta para sua implantação é a obtenção e manutenção de todos os dados necessários. Vale ressaltar que esses dados necessitam de atualização a cada execução do modelo para que a disponibilidade de recursos seja corrigida. Além dos recursos, também é preciso que todas as informações de distância entre as unidades e os pacientes, definida através de zonas (que podem variar de acordo com o tamanho da cidade) estejam definidas.

Foram desenvolvidas instâncias, de diferentes tamanhos, baseadas em dados reais de cidades brasileiras. A partir dessas instâncias, foram obtidos os resultados computacionais que mostraram que o modelo conseguiu realizar alocações, nas duas configurações diferentes, de forma que a maioria dos pacientes foram alocados para unidades próximas de suas residências.

Entretanto, uma limitação encontrada no modelo foi que em instâncias com grandes volumes de dados faltou memória na resolução, devido ao grande número de variáveis e restrições do problema. Apesar do erro por falta de memória com a instância baseada na cidade de São Paulo, vale destacar que o modelo, além de funcionar corretamente para cidades de pequeno e médio porte, consegue atender as demandas de uma cidade de grande porte, como mostrado com a instância baseada na cidade de Fortaleza, que possui mais de 2,6 milhões de habitantes.

Devido a essa limitação, o próximo passo desta pesquisa é desenvolver uma metaheurística aplicada ao problema, para que haja um método de otimização que consiga soluções praticáveis em um tempo computacional realizável para um grande volume de dados.

### **3 UMA BUSCA LOCAL GUIADA PARA O PROBLEMA DE ALOCAÇÃO DE PACIENTES NO CONTEXTO DA PANDEMIA DE COVID-19**

Neste capítulo será apresentado uma implementação da metaheurística Busca Local Guiada (BLG) customizada e aplicada ao problema de alocação de pacientes com COVID-19 a leitos hospitalares, seguindo o modelo apresentado no Capítulo 2. A implementação tem como objetivo trabalhar com grandes instâncias do problema

#### **3.1 Introdução**

Quando a computação é aplicada na resolução de um problema real com dados reais, existem casos onde a complexidade computacional em termos de tempo de processamento e de memória é muito elevada. De acordo com Dokeroglu *et al.* (2019), algoritmos exatos são, na sua maioria, não polinomiais e, apesar de proverem a melhor solução, geralmente, possuem tempos de execução e/ou requerimentos computacionais impraticáveis para instâncias de grande porte. Devido a este fato, foram desenvolvidas várias técnicas que buscam resolver um problema computacionalmente complexo com menos recursos. As metaheurísticas se enquadram como uma dessas técnicas, já que elas sacrificam a garantia do melhor resultado para conseguir um resultado satisfatório, mas em um tempo computacional praticável. Além de ser possível resolver problemas complexos sem a necessidade de grandes recursos computacionais.

No desenvolvimento de uma metaheurística é preciso considerar dois fatores cruciais para que resultados satisfatórios sejam obtidos: a exploração do espaço de busca (diversificação) e a exploração das melhores soluções encontradas (intensificação) (TALBI, 2009). Na diversificação, regiões não exploradas serão visitadas com o objetivo de ter a certeza que todas as regiões do espaço de busca foram consideradas igualmente. Já na intensificação, a preocupação é examinar regiões promissoras de forma mais minuciosa, na esperança de encontrar soluções ainda melhores.

A metaheurística Busca Local Guiada, proposta inicialmente por Voudouris e Tsang (1996), é uma técnica de otimização geral e compacta adequada para uma ampla gama de problemas de otimização combinatória. O método trabalha com a evolução de uma única solução e utiliza as informações relacionadas ao problema e a partir de penalizações aplicadas aos atributos da solução corrente, guia procedimentos de melhoria em um espaço de busca. Isso é possível através da introdução de uma função de custo do problema, que

contabiliza as penalizações já aplicadas na solução.

No cenário de pandemia que se instalou no mundo em 2019 com o vírus SARS-CoV-2, diversos pesquisadores têm dedicado atenção a técnicas que minimizem os danos causados pelo vírus. Na utilização de metaheurísticas em problemas deste contexto, a literatura apresenta o trabalho de Rodrigues e Lima (2022), onde os autores propõem uma metaheurística baseada numa adaptação do GRASP com *Variable Neighborhood Descent* (VND) aplicada na distribuição de vacinas da COVID-19. O algoritmo desenvolvido é baseado em um modelo matemático que estende a formulação clássica do Problema de Roteamento de Veículos com Múltiplos Depósitos.

No que se refere ao PBAP aplicado a pacientes com COVID-19 para alocá-los a leitos hospitalares, foi apresentado no Capítulo 2 um modelo de programação linear inteira que produz soluções ótimas, considerando a gravidade da doença em cada paciente, a fila de entrada em cada uma das gravidades e a distância entre os pacientes e as unidades hospitalares. Entretanto, uma das limitações apresentadas no modelo é o erro por estouro de memória trabalhando com instâncias de grande porte, dada a característica NP-difícil do problema. Portanto, este trabalho apresenta uma Busca Local Guiada aplicada ao PBAP no contexto de pandemia de COVID-19.

### 3.2 Revisão da Literatura

De acordo com Ribeiro *et al.* (2007), as metaheurísticas são procedimentos de alto nível que coordenam heurísticas e regras simples para encontrar boas (muitas vezes ótimas) soluções para problemas de otimização combinatória computacionalmente difíceis. Essas técnicas são utilizadas para resolução de problemas que possuem uma complexidade que torna inviável a aplicação de métodos exatos para instâncias de grande porte.

Uma característica importante das metaheurísticas é a adaptabilidade a diferentes problemas. De acordo com Boussaid *et al.* (2013), as metaheurísticas são algoritmos projetados para resolver de forma aproximada uma ampla variedade de problemas de otimização sem que seja necessária uma grande adaptação para cada problema específico.

Dentre as metaheurísticas baseadas em trajetória, a BLG se mostra capaz de produzir resultados satisfatórios para diversos problemas. Na literatura é possível encontrar várias implementações da BLG aplicada a vários problemas de Otimização Combinatória. Voudouris e Tsang (2003) propõem uma implementação da BLG para resolução do

Problema Quadrático de Alocação. A vizinhança de busca local utilizada é o conjunto de permutações possíveis resultantes da permutação atual com quaisquer dois dos elementos transpostos. Além disso, a introdução de novos movimentos na BLG é discutida.

O estudo de Silva e Silva (2015) apresenta uma implementação da BLG para o problema de escala de motoristas de ônibus urbanos. A metaheurística utiliza a heurística VND como procedimento melhoria, que funciona através da realização de realocações e trocas de tarefas entre as jornadas. A implementação foi testada com dados reais de uma empresa da cidade de Belo Horizonte e os resultados computacionais obtidos foram similares a alguns da literatura.

Uma metaheurística híbrida que combina um Algoritmo Evolutivo Multiobjetivo baseado em decomposição com BLG é proposto em Alhindi *et al.* (2018). O método funciona através da otimização de múltiplos subproblemas de objetivo único de forma colaborativa, definido uma estrutura de vizinhança entre eles. A BLG alterna entre os subproblemas e ajuda a escapar dos ótimos locais. Os resultados mostraram que essa hibridização supera a versão sem o BLG para o problema do caixeiro viajante multiobjetivo.

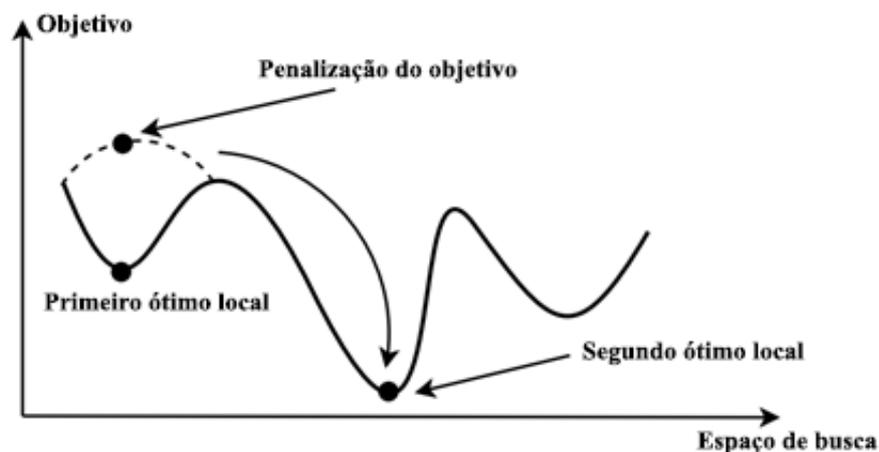
O trabalho de Touat *et al.* (2019) desenvolveu uma BLG aplicada ao problema de *Single Machine Schedule with Preventive Maintenance*. A abordagem proposta considera também a restrição de recursos humanos, que são caracterizadas por períodos de disponibilidade e níveis de competência. A metaheurística desenvolvida trabalha com três heurísticas de busca local e dois tipos de atributos para cada atividade de produção e de manutenção. Além disso, objetivando visualizar as possíveis diferenças, o parâmetro  $\lambda$  foi implementado de forma estática e de forma dinâmica. Nos testes realizados, a metaheurística apresentou bons resultados, chegando a encontrar o ótimo em alguns casos.

Uma BLG aplicada ao problema de *Resource Constrained Project Scheduling* é apresentada em Hu *et al.* (2019). Na fase de busca local foi utilizada uma estratégia de *first improvement*. O algoritmo foi testado com três classes de instâncias, sendo duas adaptadas de bibliotecas de instâncias disponíveis na literatura e uma terceira derivada de dados reais de produção. Os resultados obtidos demonstraram a capacidade da implementação proposta na busca por resultados ótimos.

### 3.3 Busca Local Guiada

A metaheurística BLG adiciona atributos (*features*) na solução para que seja possível caracterizá-las e penalizá-las. Estes atributos são cruciais para o funcionamento correto da metaheurística visto que eles vão prover informações importantes de cada solução obtida que serão utilizadas para guiar o funcionamento do algoritmo. De acordo com Glover e Kochenberger (2003) quando a busca local utilizada pela BLG estiver presa em um ótimo local, certos atributos são selecionados e penalizados. Dessa forma, a busca local pesquisa usando a função objetivo aumentada pelas penalidades acumuladas, tendendo explorar novas soluções, fugindo de mínimos locais. Uma ilustração do impacto da penalização da função objetivo utilizada pela BLG é apresentada na Figura 4. A partir da deformação do espaço de buscas com a função objetivo penalizada, o algoritmo consegue escapar de ótimos locais.

Figura 4 – Deformação do espaço de soluções provocada pela BLG



Fonte: Adaptado de (TALBI, 2009)

Para utilização da BLG é preciso definir atributos para o problema. Esses atributos são específicos de cada problema e devem possuir um custo, o qual é definido, geralmente, a partir da função objetivo. Os atributos ajudam na informação sobre o processo de busca e os mínimos locais encontrados. Para problemas de alocação, é possível encontrar na literatura os atributos sendo definidos como um par  $(i, k)$  onde  $i$  representa o objeto e  $k$  representa a localização. Desta forma, se um objeto  $i$  está alocado a um local  $k$ , o custo será dado por  $c_{ik}$ .

As penalidades  $(p_i)$  iniciam em 0 e serão incrementadas somente quando a busca

chegar em um mínimo local. Dada uma função  $g$  que mapeia cada solução candidata para um valor real, a BLG definirá a seguinte função  $h$  (chamada função de custo aumentado) que será utilizada nos procedimentos de busca locais:

$$h(s) = g(s) + \lambda \cdot \sum_{i \in F} p_i \cdot I_i(s) \quad (3.1)$$

onde  $s$  é a solução candidata,  $\lambda$  é o parâmetro de regularização,  $F$  é o número de atributos definidos,  $p_i$  é a penalidade de cada atributo e  $I_i$  é uma indicação se  $s$  possui o atributo  $i$ :

$$I_i(s) = \begin{cases} 1 & \text{solução } s \text{ possui a propriedade } i \\ 0 & \text{caso contrário} \end{cases} \quad (3.2)$$

A metaheurística guia procedimentos de busca local para encontrar melhores resultados no espaço de solução. Como estratégia para fugir de ótimos locais, a BLG aumenta o valor da função objetivo através da adição de penalidades aos atributos selecionados da solução. O diferencial dessa técnica é a forma com que ela seleciona estes atributos. A metaheurística busca atributos que possuam uma forte influência na função objetivo (com custos altos) para penalizá-los. Entretanto, outro fator também considerado é o valor atual da penalização de cada atributo. A utilidade em penalizar um atributo  $i$  pertencente a uma solução local  $s'$  é definida da seguinte forma:

$$util_i(s') = I_i(s') \times \frac{c_i}{1 + p_i} \quad (3.3)$$

Onde  $c_i$  é o custo de  $i$  na função objetivo e  $p_i$  é o valor atual da penalização de  $i$ . Esta equação faz com que se uma solução não possuir um determinado atributo, a utilidade em penalizá-lo será zero, visto que ele não estará indicado em  $I_i$ . A partir desta equação a BLG também consegue penalizar os atributos com maior custo. Mas, quanto maior o número de vezes que um determinado atributo foi penalizado, menor será a utilidade em penalizá-lo novamente. Isto serve para que haja uma maior diversificação na seleção dos atributos, de forma que atributos com custos menores também possam ser penalizados, embora em frequência menor. No algoritmo, o atributo penalizado será aquele com o util máximo. O pseudocódigo da metaheurística BLG é apresentado no Algoritmo 1.

---

**Algoritmo 1:** Pseudocódigo da BLG
 

---

```

input :  $S$ ,  $g$ ,  $\lambda$ ,  $[I_1, \dots, I_N]$ ,  $[c_1, \dots, c_N]$ ,  $F$ 
1  $k = 0$ ;
2  $S_0 =$  Solução aleatória em  $S$ ;
3 for  $i \leftarrow 1$  to  $F$  do
4   |  $p_i = 0$ ;
5 end
6  $h = g + \lambda * \sum p_i * I_i$ ;
7 while condicaoParada do
8   |  $S_{k+1} = BuscaLocal(S_k, h)$ ;
9   | for  $i = 1$  to  $F$  do
10  |   |  $util = I_i(S_{k+1}) * c_i / (1 + p_i)$ ;
11  |   | end
12  |   | forall  $i$  tal que  $util_i$  é máximo do
13  |   |   |  $p_i = p_i + 1$ ;
14  |   |   | end
15  |   |  $k = k + 1$ ;
16 end
17  $s^* =$  Melhor solução com relação a  $g$ ;

```

---

Na primeira iteração, com todas as penalizações iniciando em zero, os procedimentos de busca local irão chegar a um mínimo local. A partir disso, o algoritmo modifica a função objetivo e novamente refaz os procedimentos de busca local, tomando o mínimo local encontrado como ponto de partida. A modificação consiste em aumentar a penalização de um ou mais atributos da solução encontrada no mínimo local. Como as buscas locais consideram a função objetivo aumentada, é esperado que elas consigam escapar dos mínimos locais, já que irão sofrer influência das penalizações aplicadas. Desta forma, a BLG utiliza a informação que é gradualmente inserida na função objetivo aumentada a partir da seleção e penalização dos atributos para conseguir, assim, concentrar sua busca em regiões promissoras.

### 3.3.1 Customizações e adaptações ao problema estudado

Nesta seção, serão exibidos os aspectos relevantes utilizados na implementação da metaheurística BLG aplicada ao problema de alocação de pacientes a leitos no contexto da COVID. O algoritmo desenvolvido é baseado no modelo proposto no Capítulo 2. A escolha dessa metaheurística é justificada pelo fato de que para problemas de alocação, a definição dos atributos é feita de maneira trivial, não sendo necessário nenhum tipo de adaptação, facilitando a implementação (TALBI, 2009). O problema estudado consiste em,

a partir da disponibilidade de cada recurso nas unidades, das necessidades dos pacientes e de uma matriz representando a proximidade entre unidades e pacientes, estabelecer uma alocação otimizada, considerando aspectos relevantes da pandemia.

Considerando um conjunto de unidades de saúde  $M = \{1, 2, \dots, m\}$ , um conjunto de recursos  $S = \{1, 2, \dots, s\}$ , um conjunto de pacientes  $N = \{1, 2, \dots, n\}$ , um conjunto dos recursos existentes na unidade  $U_h$  com  $h = 1 \dots m$ . Com as gravidades da doença nos pacientes representadas por  $PCOVID_p$  e as zonas de proximidade do paciente  $p$  para a unidade  $h$  por  $D_{hp}$ , e sendo  $x_{htp}$  uma variável de decisão que irá receber 1 quando o paciente  $p$  é alocado a uma vaga de leito do tipo  $t$  da unidade  $h$  e 0 caso o contrário e  $y_{htp}$  outra variável de decisão que irá receber 1 quando o paciente  $p$  é encaminhado para a fila de um leito do tipo  $t$  da unidade  $h$  e 0 caso contrário.

A alocação de um paciente  $p$  a um leito do tipo  $t$  de uma unidade  $h$  foi definido como os atributos de uma solução, visto que é a característica mais importante do problema. Além disso, algumas adaptações foram feitas na BLG implementada para que o problema fosse abordado de forma mais apropriada, visto que se trata de um problema de maximização. A utilidade em penalizar um atributo  $i$  pertencente a uma solução local  $s'$  passou a ser definida da seguinte forma:

$$util_i(s') = I_i(s') \times \frac{\frac{1}{c_i}}{1 + p_i} \quad (3.4)$$

A partir dessa alteração, o algoritmo implementado terá o efeito normal da BLG, já que o numerador da fração tem como propósito identificar atributos que impactam fortemente o valor da função objetivo.

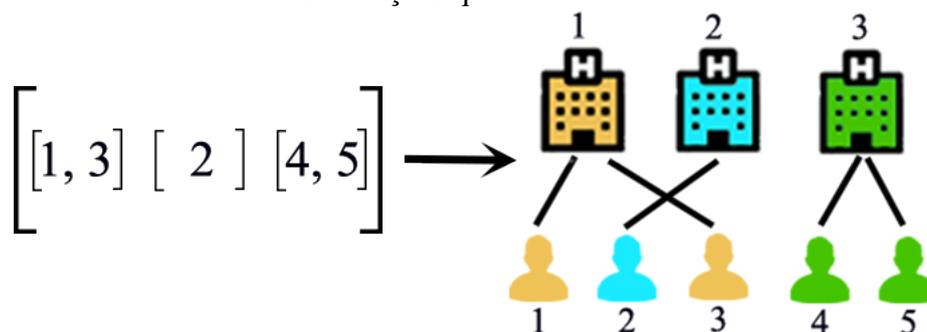
No cálculo da função objetivo aumentada também foi realizada uma alteração. Na implementação proposta, o valor da penalização aplicada é subtraído do valor da função objetivo original, já que estamos aplicando para um problema de maximização. Desta forma, a nova função  $h$  ficou da seguinte forma:

$$h(s) = g(s) - \lambda \cdot \sum_{i \in F} p_i \cdot I_i(s) \quad (3.5)$$

A forma de representação adotada foi utilizar um vetor de tamanho  $m$ , sendo  $m$  o número de unidades e cada elemento deste vetor é constituído pelos pacientes alocados/encaminhados a respectiva unidade. Uma outra alternativa seria utilizar uma matriz

com valores binários, entretanto, a forma adotada foi escolhida visando simplificar a representação, visto que no caso da matriz de binários, cada unidade teria  $n$  colunas, sendo  $n$  o número total de pacientes e a grande maioria desses valores seria 0. A Figura 5 ilustra como é a representação de uma solução onde os pacientes 1 e 3 estão alocados na primeira unidade, o paciente 2 está alocado na segunda unidade e os pacientes 4 e 5 estão alocados na terceira unidade.

Figura 5 – Representação de uma solução na implementação realizada e as alocações que ela reflete



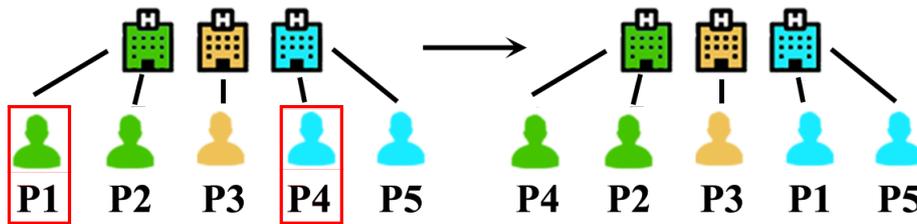
Fonte: Autoria Própria (2022)

Na construção da solução inicial, são definidos quais pacientes serão alocados e quais serão encaminhados através de um critério guloso. Como o modelo busca dar prioridade para aqueles pacientes que chegaram antes, na construção da solução são contados o número de vagas de cada tipo de recurso e também o número de pacientes de cada *PCOVID*. A partir disso, a alocação é feita de forma em uma unidade hospitalar aleatória que possua disponibilidade e seja compatível com a necessidade do paciente. Após essa etapa, temos uma solução inicial criada com os pacientes alocados e encaminhados já definidos, mas sem considerar a distância.

Os processos de melhoria implementados são baseados em trocas de pacientes para que um novo espaço de soluções seja explorado. As melhorias na função objetivo são feitas através de dois movimentos diferentes. Duas estruturas foram desenvolvidas, uma mais simples e outra mais complexa. Ambas são exploradas pelo VND.

Na primeira estrutura de vizinhança, uma dupla de pacientes aleatórios é escolhida e é feita a troca de unidade entre eles. Considerando que para instâncias de grande porte apenas uma troca poderia ser inefetiva, esse movimento foi implementado de forma que a quantidade de duplas escolhidas é parametrizada, ou seja, é possível realizar várias trocas. A Figura 6 ilustra esse processo de troca entre os pacientes P1 e P4.

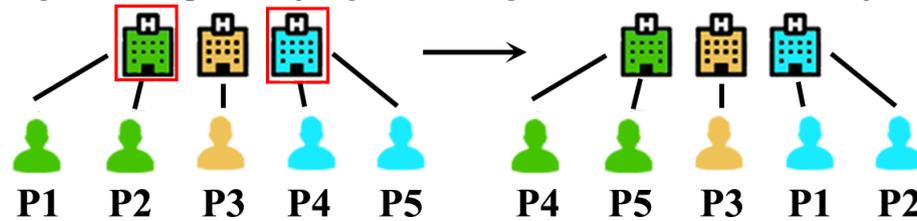
Figura 6 – Representação gráfica da primeira estrutura de vizinhança



Fonte: Autoria Própria (2022)

Já a segunda estrutura de vizinhança consiste em escolher duas unidades aleatórias e realizar trocas entre todos os pacientes das unidades escolhidas, de forma que no decorrer do procedimento só são mantidas as trocas que acarretam em um ganho na função objetivo enquanto que as outras são desfeitas. A Figura 7 ilustra esse processo com a troca dos pacientes da primeira com a terceira unidade.

Figura 7 – Representação gráfica da segunda estrutura de vizinhança



Fonte: Autoria Própria (2022)

### 3.4 Resultados

Objetivando testar a metaheurística desenvolvida, foram realizados testes com as instâncias baseadas em dados reais de cidades brasileiras e com as instâncias fictícias desenvolvidas. Esses testes possibilitaram uma visualização do comportamento da metaheurística com instâncias de diferentes tamanhos. Nos testes realizados, foram consideradas duas configurações, de forma que a diferença entre cada configuração consiste na mudança das Restrições (2.3) pelas (2.7). Todos os testes foram executados em um computador com processador Intel i5 8400, 16GB de memória RAM e 1TB de HD. O sistema operacional foi um Windows 10 64 bits.

Uma parte que influencia diretamente na obtenção de bons resultados é a definição dos valores dos parâmetros da metaheurística. Para o valor de  $\lambda$ , foi utilizada a abordagem dinâmica proposta por Voudouris e Tsang (2003), onde o valor é calculado a cada iteração e recebe o valor da função objetivo daquele ótimo local dividido pelo número de atributos

daquela solução. Para o número de iterações foram utilizadas 50.

A Tabela 8 ilustra a média e o melhor valor obtido na função objetivo da BLG implementada. Para cada instância o algoritmo foi executado 30 vezes.

Tabela 8 – Média das funções objetivo de todas as instâncias

<b>Configuração 1</b>			
<b>Instância</b>	<b>BLG</b>		<b>Solução Exata</b>
<b>Cidade</b>	<b>Melhor</b>	<b>Média</b>	<b>Solução obtida</b>
Mossoró	129267760.75	129267760.75	129267760.75
FICT45	3513921613839.3	3513921613838.5	3513921613841.6
FICT60	7800333933873.5	7800333933872.9	7800333933876.4
FICT90	101776461295812.3	101776461295812.1	101776461295815.5
Fortaleza	145643857335956.84	145643857335956.8	145643857335956.9
FICT150	753775324309628.0	753775324309627.8	-
São Paulo	265723303739974.1	265723303739973.9	-
<b>Configuração 2</b>			
<b>Instância</b>	<b>BLG</b>		<b>Solução Exata</b>
<b>Cidade</b>	<b>Melhor</b>	<b>Média</b>	<b>Solução obtida</b>
Mossoró	129267760.75	129267760.75	129267760.75
FICT45	3513921613839.4	3513921613838.6	3513921613841.6
FICT60	7800333933873.8	7800333933873.1	7800333933876.4
FICT90	101776461295812.7	101776461295812.3	101776461295815.5
Fortaleza	145643857335956.84	145643857335956.8	145643857335956.91
FICT150	753775324309628.4	753775324309628.0	-
São Paulo	265723303739974.1	265723303739974.0	-

Fonte: Autoria Própria (2022)

A partir desses resultados é possível destacar que a metaheurística desenvolvida consegue resultados bem competitivos. Na instância de Mossoró, o ótimo foi encontrado em todas as execuções. Já na de Fortaleza, o melhor resultado obtido se aproximou muito do ótimo global e a média apresentada mostra que o algoritmo se manteve consistente, desvios baixos. Por fim, na instância de São Paulo, a implementação proposta conseguiu resultados válidos e também manteve consistência. Além de exibir o valor da função objetivo, outras formas para apresentar os resultados foram estabelecidas.

Para uma melhor visualização e entendimento dos resultados obtidos, foram definidos dois indicadores para realizar a comparação com os resultados obtidos pelo modelo exato. O primeiro indicador é o número de alocações e encaminhamentos para os pacientes de cada tipo. Já o segundo indicador é o número de pacientes que está sendo alocado/encaminhado a unidades em diferentes zonas de proximidade. Ambos os indicadores são relevantes pois sintetizam dois aspectos importantes das soluções encontradas pelo algoritmo: se estas soluções estão priorizando a alocação/encaminhamento da mesma

forma que o modelo, inclusive favorecendo os pacientes que chegaram antes, e se as alocações/encaminhamentos estão sendo escolhidas de forma que a distância seja um critério, ainda que de desempate, considerado.

A Tabela 9 ilustra os resultados obtidos com todas as instâncias desenvolvidas sob a perspectiva do indicador de número de alocações/encaminhamentos para cada tipo de paciente (pc) e a Tabela 10 exibe os resultados sob a perspectiva do número de pacientes que está sendo alocado/encaminhado a cada zona de proximidade. Em ambas as tabelas foram consideradas a melhor solução encontrada pela metaheurística.

Tabela 9 – Resultados obtidos com todas as instâncias sob o panorama do número de alocações/encaminhamentos.

Configuração 1												
Instância	BLG						Solução Exata					
	Alocados			Encaminhados			Alocados			Encaminhados		
	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3
Mossoró	0	23	9	184	11	3	0	23	9	184	11	3
FICT45	61	221	278	599	519	322	61	221	278	599	519	322
FICT60	145	182	248	680	743	502	145	182	248	680	743	502
FICT90	455	267	128	1195	1583	1372	455	267	128	1195	1583	1372
Fortaleza	0	426	170	6395	773	230	0	426	170	6395	773	230
FICT150	617	519	544	2023	2441	1856	-	-	-	-	-	-
São Paulo	0	1029	390	6917	268	42	-	-	-	-	-	-

Configuração 2												
Instância	BLG						Solução Exata					
	Alocados			Encaminhados			Alocados			Encaminhados		
	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3	Pc. 1	Pc. 2	Pc. 3
Mossoró	0	23	9	184	11	3	0	23	9	184	11	3
FICT45	61	221	278	599	519	322	61	221	278	599	519	322
FICT60	145	182	248	680	743	502	145	182	248	680	743	502
FICT90	455	267	128	1195	1583	1372	455	267	128	1195	1583	1372
Fortaleza	0	426	170	6395	773	230	0	426	170	6395	773	230
FICT150	617	519	544	2023	2441	1856	-	-	-	-	-	-
São Paulo	0	1029	390	6917	268	42	-	-	-	-	-	-

Fonte: Autoria Própria (2022)

Analisando os resultados dos indicadores, pode-se observar que a BLG implementada conseguiu realizar o mesmo número de alocações/encaminhamentos da solução exata, isto é importante pois demonstra que o algoritmo está conseguindo manter o balanceamento entre alocações e encaminhamentos e gerando soluções válidas. Também é possível destacar que na instância de Mossoró, os resultados de alocações/encaminhamentos por zona foram iguais aos da solução exata em todas as execuções. Nas instâncias de Fortaleza e nas fictícias, apesar do resultado não ser o ótimo, pode-se notar que o algoritmo conseguiu alocar/encaminhar grande parte dos pacientes nas zonas 1 e 2, ou seja, considerou bem o

Tabela 10 – Resultados obtidos com todas as instâncias sob o panorama das alocações/encaminhamentos em cada zona.

Configuração 1										
Instância	BLG					Solução Exata				
Cidade	Alocados/ Encaminhados					Alocados/ Encaminhados				
	Zona 1	Zona 2	Zona 3	Zona 4	Zona 5	Zona 1	Zona 2	Zona 3	Zona 4	Zona 5
Mossoró	163	44	8	10	5	163	44	8	10	5
FICT45	1510	176	135	68	111	1848	97	18	17	20
FICT60	1935	240	104	93	128	2335	114	28	16	7
FICT90	4243	258	184	165	150	4859	109	18	6	8
Fortaleza	7018	667	159	89	61	7182	673	81	46	12
FICT150	6499	323	375	346	457	-	-	-	-	-
São Paulo	7365	430	430	248	173	-	-	-	-	-
Configuração 2										
Instância	BLG					Solução Exata				
Cidade	Alocados/ Encaminhados					Alocados/ Encaminhados				
	Zona 1	Zona 2	Zona 3	Zona 4	Zona 5	Zona 1	Zona 2	Zona 3	Zona 4	Zona 5
Mossoró	165	46	6	9	4	165	46	6	9	4
FICT45	1514	162	118	86	120	1857	88	18	17	20
FICT60	2032	138	116	93	121	2402	47	28	16	7
FICT90	4249	227	193	145	186	4892	76	18	6	8
Fortaleza	7215	467	163	91	58	7376	494	71	38	15
FICT150	6491	337	363	337	472	-	-	-	-	-
São Paulo	7428	408	411	225	174	-	-	-	-	-

Fonte: Autoria Própria (2022)

aspecto da distância. Já na instância de maior porte, a de São Paulo, o algoritmo também realizou alocações/encaminhamentos de forma que a grande maioria dos pacientes ficou na zona 1.

### 3.5 Conclusões

Realizar a alocação de pacientes com COVID-19 a leitos hospitalares se mostrou uma tarefa que necessita de muitos recursos computacionais, principalmente quando se trabalha com uma instância que possui grande volume de dados. Diante desse cenário, este trabalho apresentou uma metaheurística BLG customizada e adaptada para o problema estudado.

O algoritmo desenvolvido segue as restrições do modelo apresentado no Capítulo 2, considerando também múltiplas unidades de saúde, estratégia de priorização dos mais graves e ordem de chegada dos pacientes. Quando não há mais disponibilidade de leitos, o algoritmo realiza o encaminhamento, além de conseguir soluções para as duas configurações.

Com o objetivo de validar a metaheurística desenvolvida, experimentos computacionais foram realizados utilizando as instâncias criadas e descritas no capítulo anterior. O algoritmo foi executado 30 vezes sobre cada uma dessas instâncias e os resultados compu-

tacionais foram coletados e avaliados sob a perspectiva de dois indicadores que tornaram a comparação com o método exato mais fácil de entender, dividindo o desempenho em dois aspectos importantes: o número de alocações/encaminhamentos para cada tipo de paciente e as zonas de proximidade dessas alocações.

A análise dos resultados mostrou que a utilização da metaheurística BLG foi uma boa alternativa, conseguindo produzir resultados competitivos com os do método exato e factíveis até para a instância de maior porte. Posto isto, conclui-se que os resultados obtidos neste trabalho e os algoritmos utilizados se mostraram satisfatórios.

## 4 CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho, apresentou-se uma proposta de resolução para o problema de alocação de pacientes no contexto da Covid-19, utilizando-se de uma abordagem exata e uma abordagem metaheurística. Ambas as abordagens trabalham com duas configurações de alocação, visando a exploração de um maior espaço de busca e uma adaptabilidade de acordo com a situação enfrentada. Na abordagem exata, foi desenvolvido um modelo matemático linear inteiro que considera aspectos cruciais do fluxo de atendimento da doença, priorizando os pacientes em estado mais grave, respeitando a ordem de chegada, considerando o aspecto da distância entre as unidades e as residências dos pacientes e trazendo uma estratégia para a pós-lotação de recursos.

Para os testes computacionais, foram desenvolvidas três instâncias baseadas em dados reais de cidades do Brasil. Cada instância possui um porte diferente, desta forma foi possível observar o comportamento do modelo com um volume pequeno, médio e grande de dados. Nas duas primeiras instâncias, o modelo conseguiu soluções válidas para ambas as configurações. Entretanto, na instância de São Paulo, o método exato encontrou uma limitação visto que não conseguiu chegar a uma solução válida devido ao problema de falta de memória, revelando assim uma necessidade de outra forma de resolução que conseguisse trabalhar também com um volume grande de dados.

Como proposta de metaheurística, foi implementada uma Busca Local Guiada aplicada ao problema, trazendo as mesmas características essenciais do modelo desenvolvido. O algoritmo adapta algumas equações da BLG original, já que se trata de um problema de otimização. Os testes computacionais foram realizados com as mesmas instâncias da solução exata para que houvesse parâmetros de comparação dos resultados obtidos pelo algoritmo. Os resultados foram analisados sob duas perspectivas, além do valor da função objetivo. As análises mostraram que o algoritmo conseguiu bons resultados, realizando o mesmo número de alocações/direcionamentos que o modelo e alocando/direcionando grande parte dos pacientes em zonas próximas de suas residências. Além disso, também foi possível obter uma solução válida para a instância de São Paulo através da aplicação da metaheurística desenvolvida. Desta forma, a lacuna deixada pelo modelo foi preenchida.

A inserção deste modelo e algoritmo ao sistema de triagem SEMcTA contribuirá para oferecer a sociedade uma ferramenta inteligente que facilitará o acesso aos recursos do sistema de saúde nos momentos em que o cidadão buscar por um atendimento médico.

Esta ferramenta inteligente também contribuirá para que o governo tenha uma melhor gestão sobre os recursos disponíveis.

Como proposta de trabalhos futuros pode-se citar a expansão do modelo para que se possa trabalhar com multi-períodos, bem como desenvolver e testar novas técnicas de busca local e novas metaheurísticas aplicadas ao problema estudado para realização de um estudo comparativo entre os resultados obtidos a partir de várias técnicas.

## REFERÊNCIAS

- ALHINDI, A.; ALHINDI, A.; ALHEJALI, A.; ALSHEDDY, A.; TAIRAN, N.; ALHAKAMI, H. Moea/d-gls: a multiobjective memetic algorithm using decomposition and guided local search. *Soft Computing*, 2018.
- ARGUELLO-MONROYA, A. C.; CASTELLANOS-RAMIREZ, V.; GONZÁLEZ-NEIRA, E. M.; OTERO-CAICEDO, R. F.; DELGADILLO-SÁNCHEZ, V. P. A greedy-tabu approach to the patient bed assignment problem in the hospital universitario san ignacio. *Decision Science Letters*, 2021.
- BILGIN, B.; DEMEESTER, P.; MISIR, M.; W, V.; G, V.-B. One hyper-heuristic approach to two timetabling problems in health care. *Journal of Heuristics*. *Journal of Heuristics*, p. 401–434, 2012.
- BOUSSAID, I.; LEPAGNOT, J.; SIARRY, P. A survey on optimization metaheuristics. *Information Sciences*, p. 82–117, 2013.
- CESCHIA, S.; SCHAERF, A. Local search and lower bounds for the patient admission scheduling problem. *Computers and Operations Research*, p. 1452–1463, 2011.
- CESCHIA, S.; SCHAERF, A. Modeling and solving the dynamic patient admission scheduling problem under uncertainty. *Artificial Intelligence in Medicine*, p. 199–205, 2012.
- CESCHIA, S.; SCHAERF, A. Dynamic patient admission scheduling with operating room constraints, flexible horizons, and patient delays. *Journal of Scheduling*, p. 377–389, 2014.
- CONTE, D.; BAHIA, L.; CARVALHO, E. L.; CARDOSO, A. M.; SOUZA, P. M. Oferta pública e privada de leitos e acesso aos cuidados à saúde na pandemia de covid-19 no brasil. *Scielo*, 2020.
- DEMEESTER, P.; SOUFFRIAU, W.; CAUSMAECKER, P. D.; VANDEN-BERGHE, G. A hybrid tabu search algorithm for automatically assigning patients to beds. *Artificial Intelligence in Medicine*, p. 61–70, 2010.
- DOKEROGLU, T.; SEVINC, E.; KUCUKYILMAZ, T.; COSAR, A. A survey on new generation metaheuristic algorithms. *Computers Industrial Engineering*, 2019.
- EMANUEL, E. J.; PERSAD, G.; UPSHUR, R.; THOME, B.; PARKER, M.; GLICKMAN, A.; ZHANG, C.; BOYLE, C.; SMITH, M.; PHILIPS, J. P. Fair allocation of scarce medical resources in the time of covid-19. *New England Journal of Medicine*, p. 2049–2055, 2020.
- GLOVER, F.; KOCHENBERGER, G. **Handbook of metaheuristics**. [S.l.]: Kluwer Academic Publishers, 2003.
- GUIDO, R.; GROCCIA, M. C.; CONFORTI, D. An efficient metaheuristic for offline patient-to-bed assignment problems. *European Journal of Operational Research*, p. 486–503, 2018.
- GUPTA, N.; PAIVA, S. **IoT and ICT for Healthcare Applications**. [S.l.]: EAI/Springer Innovations in Communication and Computing, 2020. ISBN 978-3-030-42934-8.

HU, S.; ZHANG, Z.; WANG, S.; KAO, Y.; ITO, T. A project scheduling problem with spatial resource constraints and a corresponding guided local search algorithm. *Journal of the Operational Research Society*, p. 1349–1361, 2019.

KIRKPATRICK, J.; HULL, S.; FEDSON, S.; MULLEN, B.; GOODLIN, S. Scarce-resource allocation and patient triage during the covid-19 pandemic. *Journal of the American College of Cardiology*, p. 85–92, 2020.

LUSBY, R.; SCHWIERZ, M.; RANGE, T. M.; LARSEN, J. An adaptive large neighborhood search procedure applied to the dynamic patient admission scheduling problem. *Artificial Intelligence in Medicine*, p. 21–31, 2016.

MAJTRAJT, L.; EATON, J.; LEUNG, T.; BROWN, E. R. Vaccine optimization for covid-19: Who to vaccinate first? *Science Advances*, 2020.

MEHROTRA, S.; RAHIMIAN, H.; BARAH, M.; LUO, F.; SCHANTZ, K. A model of supply-chain decisions for resource sharing with an application to ventilator allocation to combat covid-19. *Naval Research Logistics*, p. 303–320, 2020.

MELMAN, G.; PARLIKAD, A.; CAMERON, E. Balancing scarce hospital resources during the covid-19 pandemic using discrete-event simulation. *Health Care Management Science*, p. 356–374, 2021.

MINISTERIO DA SAUDE. **Departamento de Informática do Sistema Único de Saúde (Datasus)**. 2020.

MINISTERIO DA SAUDE. **Secretaria de Vigilância em Saúde (SVS): Guia de Vigilância Epidemiológica do COVID-19**. 2020.

NORONHA, K. V.; GUEDES, G. R.; TURRA, C. M.; ANDRADE, M. V.; BOTEGA, L.; NOGUEIRA, D. Pandemia por covid-19 no brasil: análise da demanda e da oferta de leitos hospitalares e equipamentos de ventilação assistida segundo diferentes cenários. *Cadernos De Saúde Pública*, 2020.

OLIVEIRA, L. C. **Edital CAPES de Seleção Emergencial III 12/2020**. 2020. Disponível em: <<https://in.gov.br/web/dou/-/edital-n-12/2020-resultado-final-do-edital-de-selecao-emergencial-267056891>>.

RACHE, B.; NUNES, L.; ROCHA, R.; SPINOLA, P.; MALIK, A. M.; MASSUDA, A. Necessidades de infraestrutura do sus em preparo à covid-19: leitos de uti, respiradores e ocupação hospitalar. Instituto de Estudos para Políticas de Saúde, 2020.

RANGE, T.; LUSBY, R. M.; LARSEN, J. A column generation approach for solving the patient admission scheduling problem. *European Journal of Operational Research*, p. 252–264, 2014.

RIBEIRO, C. C.; MARTINS, S. L.; ROSSETI, I. Metaheuristics for optimization problems in computer communications. *Computer Communications*, p. 656–669, 2007.

RODRIGUES, A.; LIMA, G. A metaheuristic to support the distribution of covid-19 vaccines. *Scielo*, 2022.

SECRETARIA MUNICIPAL DE SAUDE DE MOSSORO. **Manual do atendimento do coronavírus a partir da atenção básica**. 2021.

SEN-CROWE, B.; SUTHERLAND, M.; MCKENNEY, M.; ELKBULI, A. A closer look into global hospital beds capacity and resource shortages during the covid-19 pandemic. *Journal of Surgical Research*, p. 56–63, 2021.

SILVA, K. R.; G, S. F.; F, R. F.; C, F. S. M.; F, P. B. C.; A, V. Allocation of resources for health care in covid-19 pandemic times: integrative review. *Revista Brasileira de Enfermagem*, 2020.

SILVA, T.; SILVA, G. O uso da metaheurística guided local search para resolver o problema de escala de motoristas de ônibus urbano. *Transportes*, 2015.

SUN, L.; DEPUY, G. W.; EVANS, G. W. Multi-objective optimization models for patient allocation during a pandemic influenza outbreak. *Computers Operations Research*, p. 350–359, 2014.

TALBI, E. **Metaheuristics: From Design to Implementation**. [S.l.]: Wiley, 2009. ISBN 978-0-470-27858-1.

TARAMASCO, C.; CRAWFORD, B.; SOTO, R.; CORTES-TORO, E. M.; OLIVARES, R. A new metaheuristic based on vapor-liquid equilibrium for solving a new patient bed assignment problem. *Expert Systems with Applications*, 2020.

THOMAS, B. G.; BOLLAPRAGADA, S.; AKBAY, K.; TOLEDANO, D.; KATLIC, P.; DULGEROGLU, O.; YANG, D. Automated bed assignments in a complex and dynamic hospital environment. *Interfaces*, p. 435–448, 2013.

TOUAT, M.; TAYEB, F.; BENHAMOU, B.; SADEG, L.; AKLIL, S.; KARAOUI, M. An integrated guided local search considering human resource constraints for the single-machine scheduling problem with preventive maintenance. *IEEE International Conference on Systems, Man and Cybernetics (SMC)*, 2019.

TURHAN, A. M.; BILGEN, B. Mixed integer programming based heuristics for the patient admission scheduling problem. *Computers and Operations Research*, p. 38–49, 2017.

VANCROONENBURG, W.; CAUSMAECKER, P.; SPIEKSMAN, F.; VANDEN-BERGHE, G. Scheduling elective patient admissions considering room assignment and operating theatre capacity constraints. *Applied Operational Research*, p. 153–158, 2013.

VOUDOURIS, C.; TSANG, E. P. K. Partial constraint satisfaction problems and guided local search. *Proceedings of Second International Conference on Practical Application of Constraint Technology*, 1996.

VOUDOURIS, C.; TSANG, E. P. K. Guided local search. In: \_\_\_\_\_. [S.l.: s.n.], 2003. p. 185–21.

XIONG, J.; LIPSITZ, O.; NASRI, F.; LUI, L. M. W.; GILL, H.; PHAN, L.; CHEN-LI, D.; IACOBUCCI, M.; HO, R.; MAJEED, A.; MCINTYRE, R. S. Impact of covid-19 pandemic on mental health in the general population: a systematic review. *Journal of Affective Disorders*, p. 55–64, 2020.