

UM MODELO DE PROGRAMAÇÃO LINEAR INTEIRA PARA ALOCAÇÃO DE PACIENTES COM COVID-19 ÀS UNIDADES HOSPITALARES

Sebastião Mateus Marques de Menezes

Universidade do Estado do Rio Grande do Norte (UERN)
mateusmarques200@gmail.com

Dario José Aloise

Universidade do Estado do Rio Grande do Norte (UERN)
darioalose@uern.br

Fábio Francisco Costa Fontes

Universidade Federal Rural do Semi-Árido (UFERSA)
fabio_fontes@ufersa.edu.br

Breno Barros Telles do Carmo

Universidade Federal do Ceará (UFC)
brenobarros@ufc.br

Andrea Taborda Ribas da Cunha

Universidade Federal Rural do Semi-Árido (UFERSA)
andrea.taborda@ufersa.edu.br

RESUMO

Este trabalho propõe um modelo de programação linear inteira para realizar a alocação otimizada de pacientes com Covid-19 às unidades hospitalares. O modelo foi desenvolvido considerando as características da pandemia de COVID-19, além de adotar critérios concordantes com a situação real. O modelo foi validado através da aplicação em uma instância composta por dados simulados a partir de um estudo de caso na cidade de Mossoró e instâncias fictícias. Os testes realizados mostraram que o modelo conseguiu produzir soluções ótimas aplicáveis, no tamanho das instâncias consideradas.

PALAVRAS-CHAVE. Covid-19, Alocação de pacientes, Programação Linear Inteira.

PO na Área de Saúde; Programação Matemática.

ABSTRACT

This work proposes an integer linear programming model to perform the optimal allocation of patients with Covid-19 to hospital units. The model was developed considering the characteristics of the COVID-19 pandemic, adopting criteria consistent with the real situation. The model was validated by applying it to an instance composed of simulated data from a case study in the city of Mossoró and fictitious instances. The tests performed showed that the model was able to produce applicable optimal solutions, in the size of the considered instances.

KEYWORDS. Covid-19, Patient allocation, Integer Linear Programming

OR in the Health Area; Mathematical Programming.

1. Introdução

A Covid-19 foi identificada inicialmente em dezembro de 2019, na cidade de Wuhan, na China. Como se trata de uma doença altamente contagiosa e com rápida propagação, os sistemas de saúde de vários países do mundo entraram em colapso. A Organização Mundial da Saúde (OMS) declarou a 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].

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-Crowee et al. 2021] mostrou que, de 183 países, 63% apresentaram um número de leitos no intervalo de 0-299 por cem mil habitantes, principalmente países da América do Sul e da África. Assim, considerando a escassez dos recursos hospitalares, constata-se a importância de se ter uma estratégia inteligente/eficiente na alocação de pacientes aos leitos.

A situação no Brasil foi particularmente preocupante, já que, de acordo com o [Ministério da Saúde 2020], o país é um dos líderes mundiais de casos e óbitos registrados, apresentando, até o dia 12 de março de 2022 (dois anos após o registro do primeiro óbito no país), um total de mais de 29 milhões de casos e mais de 650 mil óbitos. Além das internações diretamente ligadas à Covid-19, pacientes com outras complicações de saúde não relacionadas à Covid-19 tiveram seus atendimentos comprometidos devido à saturação do sistema de saúde brasileiro, visto que a demanda gerada por outras doenças não deixou de existir nem de ser atendida.

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 foram 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 na 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], um modelo matemático é apresentado 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 de ventiladores pulmonares.

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, além dos leitos disponíveis na rede de saúde. 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 devem ser consideradas no desenvolvimento de modelos de alocação de pacientes com Covid-19.

Os trabalhos encontrados relacionados à aplicação de modelagem matemática e técnicas de otimização na mitigação dos efeitos da pandemia se concentram, em sua maioria, nos países da América do Norte. Já nos países que possuíam menos leitos, normalmente africanos e latinos, a quantidade de estudos direcionados a esse tema foi bastante reduzida.

Neste contexto, este trabalho propõe um modelo de programação matemática para alocação otimizada de pacientes com Covid-19 às unidades hospitalares, maximizando o número de atendimentos, priorizando 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 hospitalares.

O trabalho 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 metodologia seguida pelo trabalho. Na seção 4 é apresentado e detalhado o modelo proposto. Na seção 5 os resultados computacionais obtidos são exibidos e discutidos e na seção 6 são apresentadas as conclusões do trabalho.

2. Revisão da Literatura

Nos últimos anos, no contexto de gerenciamento e planejamento hospitalar, vários estudos focados na alocação de pacientes aos leitos foram desenvolvidos. O *Patient Admission Scheduling Problem* (PASP) possibilita um melhor uso de recursos críticos e maximização do atendimento aos pacientes. O objetivo deste problema é designar pacientes aos leitos adequados nos departamentos apropriados, conforme a disponibilidade, as restrições médicas, as necessidades e as preferências do paciente. 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.

Foram identificados 13 trabalhos na literatura sobre este tema, dentro os quais, 10 abordam o PASP e 3 o PBAP. As abordagens de soluções adotadas são o desenvolvimento de modelos matemáticos (inteiros ou inteiros mistos), além da aplicação de heurísticas e metaheurísticas. Abaixo são destacados os principais aspectos de cada proposta.

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 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 desenvolveu 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 o problema 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 propõe um modelo composto apenas por restrições *hard*. A segunda formulação relaxa algumas dessas restrições, transformando-as em *soft* (restrições que não precisam ser satisfeitas para que a solução seja válida, entretanto quando violadas, penalizam a função objetivo), tentando explorar um maior espaço de soluções válidas. 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 de considerar um grupo de hospitais, de forma que, quando não houver disponibilidade de leitos em um hospital, o paciente será direcionado 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.

Finalmente, uma maior variedade de maneiras de classificar e priorizar pacientes são apresentadas 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 aos leitos considerados ideais. A função objetivo busca maximizar a soma ponderada das recompensas menos as penalidades por não satisfazer as metas do hospital.


Alguns aspectos importantes em um contexto de pandemia, não foram abordados por esses trabalhos, como estratégias de priorização e direcionamento após a lotação de recursos. Além disso, o fluxo de atendimento de pacientes 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 este presente estudo pretende explorar: a falta de um método de otimização para alocação de pacientes com Covid-19 que faça o melhor uso dos recursos hospitalares disponíveis e que considere todos os aspectos intrínsecos da pandemia, como as diferentes gravidades da doença.

3. Metodologia

Este tópico apresenta a metodologia proposta para o desenvolvimento do modelo matemático de Programação Linear Inteira, para alocar pacientes com Covid-19 aos leitos disponíveis, sendo organizado em três etapas: caracterização do problema, desenvolvimento do modelo matemático e a validação do modelo desenvolvido através de testes com instâncias. A Figura 1 apresenta o processo utilizado neste trabalho.

Figura 1: Estrutura da metodologia utilizada



Fonte: Autoria própria (2021).

A **primeira etapa** teve como objetivo definir o problema estudado por meio da análise de estudos sobre a alocação de pacientes aos leitos e do entendimento de como se dá o fluxo de atendimento aos pacientes com Covid-19. Além disso, foi possível identificar os aspectos mais relevantes da pandemia e as lacunas identificadas nos modelos apresentados na literatura. Tais observações foram cruciais para o desenvolvimento de uma abordagem condizente com o problema enfrentado.

De acordo com o [Ministério da Saúde 2020], os pacientes com Covid-19 estão divididos em três níveis de gravidade da doença, além do assintomático. 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 a unidades hospitalares mais próximas da sua residência, para que haja um menor deslocamento [Silva et al. 2020].

A **segunda etapa** da metodologia adotada consiste no desenvolvimento da modelagem matemática. Para isto, foram realizadas adaptações em algumas restrições dos modelos de alocação clássicos, objetivando obter uma maior adequação à situação enfrentada. Como resultado, o modelo estabelece uma alocação de leitos otimizada para os pacientes, priorizando os que se encontram em estado mais grave, respeitando a ordem de entrada nas filas pela gravidade, satisfazendo as necessidades de tratamento, considerando a distância entre a residência deles e as unidades hospitalares e encaminhando a uma unidade hospitalar, aqueles pacientes que não conseguiram um leito vago, para que possam conseguir um atendimento médico.

As seguintes características foram incluídas na 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 estarão disponíveis.

A **etapa final** da metodologia consiste na validação do modelo desenvolvido. Dessa forma, instâncias baseadas em dados reais foram criadas, compostas de unidades hospitalares e pacientes da cidade de Mossoró, Brasil. As unidades hospitalares consideradas nas simulações são de três tipos: Unidade Básicas de Saúde (UBS), Centros de Referência e Unidade de Pronto Atendimento (UPA). No caso dos pacientes, eles são classificados em três níveis, de acordo com o

quadro de gravidade: o tipo 1, representando aqueles com sintomas leves, o tipo 2, com sintomas moderados e o tipo 3, com sintomas graves. Além disso, foi desenvolvido um gerador de instâncias para a realização de testes com um maior volume de dados.

4. Modelo proposto

Diante do cenário pandêmico vivenciado pela pandemia da Covid-19, os pacientes com sintomas leves foram direcionados às UBS, pacientes com sintomas moderados foram alocados aos Centros de Referência e os pacientes com sintomas graves às UPAs, conforme estabelecido em [Cunha et al. 2021].

Na modelagem matemática proposta, os pacientes possuem uma necessidade de recursos hospitalares de acordo com o estado de gravidade da doença, sendo alocados às unidades hospitalares que são compatíveis com essa necessidade, ou seja, unidades que possuem os recursos necessários para o tratamento. No modelo, cada unidade hospitalar apresenta uma disponibilidade de vagas, que poderá ser de mais de um tipo, ou seja, uma mesma unidade pode oferecer recursos para pacientes moderados e graves, por exemplo.

A modelagem considera duas variáveis: por meio da primeira variável (X_{htp}), o modelo matemático aloca o número máximo de pacientes às vagas priorizando os que apresentarem um estado mais grave, respeitando a ordem e considerando a distância entre as residências dos pacientes e as unidades hospitalares. Por meio da segunda variável (Y_{htp}), o modelo cria uma fila para atendimento nas unidades ao direcionar os pacientes para estruturas compatíveis com suas necessidades, tendo como critério a distância.

O modelo apresenta as seguintes variáveis e parâmetros: conjunto de unidades de saúde M , conjunto de recursos S e conjunto de pacientes N . A gravidade da doença nos pacientes é representada pelo parâmetro $PCOVID_p$, que pode assumir valores 1, 2 e 3, de forma que enquanto maior o valor, mais grave é o estado do paciente. O parâmetro R_{ht} representa a presença do recurso do tipo t na unidade h . Já C_{ht} representa a disponibilidade do recurso t na unidade. As zonas de proximidade do paciente p para a unidade h são representadas por D_{hp} . X_{htp} é 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 direcionado para a fila de um leito do tipo t da unidade h e 0 caso contrário. A formulação de programação linear inteira binária para este problema é apresentada a seguir.

$$\begin{aligned} \text{Maximizar} \quad & \sum_{h \in M} \sum_{t \in S} \sum_{p \in N} (n^{PCOVID_p} - p) \left(x_{htp} + \frac{y_{htp}}{2} \right) \\ & + \sum_{h \in M} \sum_{t \in S} \sum_{p \in N} \frac{1}{pD_{hp}} \left(x_{htp} + \frac{y_{htp}}{2} \right) \end{aligned} \quad (1)$$

Sujeito a:

$$\sum_{h \in M} \sum_{t \in S} (x_{htp} + y_{htp}) = 1 \quad (2)$$

$$\forall p \in N$$

$$PCOVID_p(x_{htp} + y_{htp}) = R_{ht}(x_{htp} + y_{htp}) \quad (3)$$

$$\forall p \in N, \forall t \in S, \forall h \in M$$

$$\sum_{p \in N} x_{htp} \leq C_{ht} \quad (4)$$

$$\forall t \in S, \forall h \in M$$

$$x_{htp} \in \{0,1\} \quad (5)$$

$$\forall h \in M, \forall t \in S, \forall p \in N$$

$$y_{htp} \in \{0,1\} \quad (6)$$

$$\forall h \in M, \forall t \in S, \forall p \in N$$

A função objetivo, apresentada na equação (1), possui dois termos com finalidades diferentes. O primeiro termo visa maximizar as alocações de pacientes com Covid-19, respeitando a ordem de entrada na fila dentro de cada grupo de gravidade da doença e priorizando os mais graves. Já o segundo termo inclui a distância do paciente para a unidade de saúde nas alocações, mantendo a ordem de entrada. Além disso, os pacientes excedentes são direcionados para filas na unidade compatível mais próxima.

As restrições da equação (2) garantem que cada paciente p será alocado a uma vaga em uma unidade ou direcionado a uma fila. As restrições representadas por (3) asseguram que um paciente p só será alocado ou direcionado a uma determinada unidade de saúde h se o tipo de recurso R_{ht} dessa unidade for compatível com a necessidade dele, representada pelo $PCOVID_p$. As restrições em (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} e as restrições das equações (5) e (6) garantem que as variáveis de decisão x_{htp} e y_{htp} só poderão assumir valores binários.

Objetivando visualizar um novo cenário de alocações, a equação (7) foi desenvolvida de forma que permite que um paciente seja alocado a mais de um tipo de unidade se ela satisfizer suas necessidades. Assim, realizando a substituição da equação (3) pela equação (7), o modelo realiza as alocações de forma diferente, já que um paciente com sintomas leves pode ser alocado à vaga de um Centro de Referência ou uma UPA, por exemplo. Entretanto, o modelo não irá perder a característica de priorização dos pacientes em estado mais grave.

$$PCOVID_p(x_{htp} + y_{htp}) \leq R_{ht} \quad \forall p \in N, \forall t \in S, \forall h \in M \quad (7)$$

5. Resultados computacionais

A fim de validar o modelo matemático desenvolvido, foram criadas instâncias com dados simulados, utilizando uma distribuição uniforme, a partir de uma base real da cidade de Mossoró. Foram coletadas junto às unidades de saúde as capacidades totais de leitos direcionados ao tratamento de Covid-19 bem como as suas coordenadas geográficas.

A instância é composta pelas unidades públicas de Mossoró que providenciam atendimento ao coronavírus: 33 UBS, 1 Centro de Referência (cuja unidade de saúde também é compartilhada por uma UPA) e 3 UPAs. 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 criou filas de pacientes para as UBS.

Como a instância representa um dia de alocação, na definição do número de pacientes foi realizada uma consulta aos dados da Secretaria de Saúde Pública (SESAP) do Rio Grande do Norte a fim de identificar um pico no número de casos de Covid-19 na cidade de Mossoró, o qual aconteceu em 1 de abril de 2021, com 230 novos casos. Na estimativa de gravidade da doença nos pacientes, foi seguida a estatística da OMS, que estabelece 80% de pacientes com sintomas leves, o qual corresponde a 184 pacientes, 15% de pacientes com sintomas moderados, o qual corresponde a 34 pacientes e 5% de casos graves, que corresponde a 12 pacientes. Para as localizações dos pacientes foram gerados pontos aleatórios distribuídos por toda a cidade de Mossoró.

Nos testes realizados, foram considerados dois cenários, de forma que a diferença entre cada cenário consiste na mudança da restrição (3) pela (7). No primeiro cenário, o modelo só permite a alocação de pacientes aos leitos que tratam apenas de sua gravidade. Já no segundo cenário, um paciente pode ser atendido por mais de um tipo de unidade, desde que suas necessidades sejam satisfeitas. Além disso, foram consideradas cinco zonas de distância, com os raios variando em 1.5 quilômetros.

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 era um Windows 10 64 bits. Os resultados obtidos com a instância de Mossoró mostraram que o modelo conseguiu resultados válidos e que realizou o mesmo número de alocações e direcionamentos em ambos os cenários, divergindo um pouco apenas no tempo de execução, sendo 0.05 segundo no cenário 1 e 0.06 segundo no cenário 2.

Essa igualdade dos resultados ocorreu devido à baixa quantidade de leitos do tipo 3, que foi esgotada apenas com os pacientes com sintomas graves, não sendo possível alocar nenhum paciente com outros sintomas a esses leitos no cenário 2. Isso também ocorreu devido à escassez de recursos do tipo 2, que não possibilitou que pacientes com sintomas leves fossem alocados a esses leitos restantes. Com isso, o cenário 2 apenas repetiu as mesmas alocações do cenário 1.


Outro fator importante que pode ser diferente nos dois cenários são as distâncias de alocação dos pacientes. Para a instância de Mossoró, a distância de alocação dos pacientes também permaneceu igual. Vale ressaltar que o modelo conseguiu realizar alocações de forma que 62.5% dos pacientes ficaram a, no máximo, 4.5 quilômetros da unidade hospitalar, com 37,5% deles sendo alocados às unidades em um raio de, no máximo, 3 quilômetros.

Considerando que a instância de Mossoró é de pequeno porte e objetivando testar o comportamento do modelo desenvolvido para instâncias de maior porte, foi desenvolvido um gerador de instâncias fictícias para teste. A capacidade total das unidades é definida como uma porcentagem aleatória entre 70% e 85% da demanda dos pacientes, dessa forma toda instância gerada sempre terá mais pacientes do que recursos disponíveis. O gerador trabalha com 2500 pacientes e atribui a gravidade de acordo com a estatística da OMS. Visto que essa instância lida com localizações mais distantes, as distâncias são representadas a partir de cinco zonas, com os raios variando de 50 em 50 quilômetros.

A fim de experimentar o modelo proposto, o gerador foi utilizado na criação de duas instâncias: uma com 130 unidades hospitalares e outra com 150. Os testes foram realizados nos dois cenários descritos anteriormente. Os resultados mostraram que na instância 130FICT houveram 1160 alocações no primeiro cenário (com um tempo de execução de 7.25 segundos), já no segundo cenário houveram 1950 alocações (com um tempo de execução de 47.28 segundos) e, conseqüentemente, menos direcionamentos. Esse aumento se deve ao fato que recursos para atender pacientes do tipo 2 e 3 sobraram e recursos para atender pacientes do tipo 1 faltaram. Logo, estes que ficaram sem vaga e foram direcionados às filas no cenário 1, no cenário 2 foram alocados nas vagas remanescentes dos outros tipos. A partir desse resultado, podemos concluir que a

variação na restrição utilizada no cenário 2 consegue, dependendo das características da instância, alocar mais pacientes. A Figura 2 apresenta a diferença nas alocações entre os cenários analisando as distâncias das alocações.

Figura 2 – Comparação entre os cenários sob a perspectiva da distância de alocação.



Fonte: Autoria própria (2021).

A partir da Figura 2, pode-se observar que, para a instância 130FICT, o modelo, no cenário 2, conseguiu minimizar ainda mais a distância das alocações realizadas, com um aumento no número de pacientes alocados a unidades muito próximas de suas residências, enquanto da zona 2 em diante os números permaneceram semelhantes ao do cenário 1.

O modelo não conseguiu obter um resultado para a instância 150FICT em nenhum dos dois cenários propostos. Apesar da resolução em um bom tempo computacional, uma limitação identificada no modelo para instâncias de grande porte é a falta de memória no momento da resolução. Logo, se faz necessário outro método de otimização que possa ser desenvolvido a partir do modelo e que consiga soluções praticáveis em um tempo computacional realizável para um grande volume de dados.

A partir da validação com a instância de Mossoró e os testes com as instâncias compostas de dados fictícios, foi possível constatar que o modelo desenvolvido consegue obter resultados válidos e otimizados na alocação de pacientes com Covid-19 aos leitos das unidades hospitalares em dois cenários diferentes. Tais resultados são obtidos de forma que consideram aspectos importantes do contexto pandêmico.

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 para otimizar essa alocação, considerando aspectos particulares importantes desta pandemia.

O modelo desenvolvido representa um dia de alocação e trabalha com três gravidades de 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 utilizada como um importante critério nas alocações/direcionamentos, visto que possibilitar o menor deslocamento possível foi entendido como um fator importante. Além disso, também foi implementado o direcionamento 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, adicionando a possibilidade de adaptação do modelo a situações diferentes, através da busca em diferentes espaços de solução, sem perder as características importantes da pandemia.

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. Diante dessa limitação, fica como trabalho futuro o desenvolvimento de um método que consiga soluções praticáveis para instâncias de grande porte em um tempo computacional realizável.

Agradecimentos

Este estudo foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES 23038.013980/2020-31).

Referências

- Arguello-Monroya, A. C., Castellanos-Ramirez, V., González-Neira, E. M., Otero-Caicedo, R. F., Delgadillo-Sánchez, V. P. (2021). A greedy-tabu approach to the patient bed assignment problem in the Hospital Universitario San Ignacio. *Decision Science Letters*, 21-38. <https://doi.org/10.5267/j.dsl.2020.10.006>
- Bilgin, B., Demeester, P. Misir, M., Vancroonenburg, W., Berghe, G. V. (2012) One hyper-heuristic approach to two timetabling problems in health care. *Journal of Heuristics*, 401-434.
- Ceschia, S., & Schaerf, A. (2011). Local search and lower bounds for the patient admission scheduling problem. *Computers and Operations Research*, 38(10), 1452–1463. <https://doi.org/10.1016/j.cor.2011.01.007>
- Ceschia, S., & Schaerf, A. (2012). Modeling and solving the dynamic patient admission scheduling problem under uncertainty. *Artificial Intelligence in Medicine*, 56(3), 199–205. <https://doi.org/10.1016/j.artmed.2012.09.001>
- Ceschia, S., & Schaerf, A. (2014). Dynamic patient admission scheduling with operating room constraints, flexible horizons, and patient delays. *Journal of Scheduling*, 19(4), 377–389. <https://doi.org/10.1007/s10951-014-0407-8>
- Cote, M. J. (2000). Understanding patient flow. *Decision Line*, 31, 8-13.
- Cunha, A. T. R., Vale, J., Vasconcelos, D. A. R., Lima, V., Solano, L. C. (2021) Manual de Manejo COVID 19 na Atenção Primária à Saúde de Mossoró.

Demeester, P., Souffriau, W., De Causmaecker, P., & Vanden Berghe, G. (2010). A hybrid tabu search algorithm for automatically assigning patients to beds. *Artificial Intelligence in Medicine*, 48(1), 61–70.

Emanuel, E. J., Persad, G., Upshur, R., Thome, B., Parker, M., Glickman, A., Zhang, C., Boyle, C., Smith, M., Phillips, J. P. (2020). Fair Allocation of Scarce Medical Resources in the Time of Covid-19. *New England Journal of Medicine*, 382(21), 2049–2055. <https://doi.org/10.1056/nejmsb2005114>

Guido, R., Groccia, M. C., & Conforti, D. (2018). An efficient matheuristic for offline patient-to-bed assignment problems. *European Journal of Operational Research*, 268(2), 486–503. <https://doi.org/10.1016/j.ejor.2018.02.007>

Lusby, R., Schwierz, M., Range, T. M., Larsen, J. (2016). An adaptive large neighborhood search procedure applied to the dynamic patient admission scheduling problem. *Artificial Intelligence in Medicine*, 21–31.

Mehrotra, S., Rahimian, H., Barah, M., Luo, F., Schantz, K. (2020). A model of supply-chain decisions for resource sharing with an application to ventilator allocation to combat COVID-19. *Naval Research Logistics (NRL)*, 67(5), 303–320. <https://doi.org/10.1002/nav.21905>

Melman, G., Parlikad, A. & Cameron, E. (2021). Balancing scarce hospital resources during the COVID-19 pandemic using discrete-event simulation. *Health Care Manag Sci* 24, 356–374. <https://doi.org/10.1007/s10729-021-09548-2>

Ministério da Saúde (Brasil). (2020). Departamento de Informática do Sistema Único de Saúde (Datasus). Brasília, DF: Informações de saúde. Rede Assistencial.

Organização Mundial da Saúde (2020). Oxygen sources and distribution for COVID-19 treatment centres: interim guidance.

Range, T. M., Lusby, R. M., & Larsen, J. (2014). A column generation approach for solving the patient admission scheduling problem. *European Journal of Operational Research*, 235(1), 252–264. <https://doi.org/10.1016/j.ejor.2013.10.050>

Sen-Crowe, B., Sutherland, M., McKenney, M., Elkbuli, A. (2021). A Closer Look Into Global Hospital Beds Capacity and Resource Shortages During the COVID-19 Pandemic. *Journal of Surgical Research*, 260, 56–63. <https://doi.org/10.1016/j.jss.2020.11.062>

Silva K. R, Souza F. G, Roquete F. F, Faria S. M. C, Peixoto B. C. F., Vieira A. (2020). Allocation of resources for health care in COVID-19 pandemic times: integrative review. *Rev Bras Enferm*.

Taramasco, C., Crawford, B., Soto, R., Cortés-Toro, E. M., e Olivares, R. (2020). A new metaheuristic based on vapor-liquid equilibrium for solving a new patient bed assignment problem. *Expert Systems with Applications*, 158, 113506. <https://doi.org/10.1016/j.eswa.2020.113506>

Thomas, B. G., Bollapragada, S., Akbay, K., Toledano, D., Katlic, P., Dulgeroglu, O., & Yang, D. (2013). Automated bed assignments in a complex and dynamic hospital environment. *Interfaces*, 43(5), 435–448.

Turhan, A. M., & Bilgen, B. (2017). Mixed integer programming based heuristics for the Patient Admission Scheduling problem. *Computers and Operations Research*, 80, 38–49. <https://doi.org/10.1016/j.cor.2016.11.016>

Vancroonenburg, W., Causmaecker, P. De, Spieksma, F., & Vanden Berghe, G. (2013). Scheduling elective patient admissions considering room assignment and operating theatre capacity constraints. *Lecture Notes in Management Science. 5th International Conference on Applied Operational Research, Proceedings*, 5, 153–158.