

APLICAÇÃO DE PROGRAMAÇÃO LINEAR INTEIRA MISTA PARA ALOCÇÃO ÓTIMA DE ANALISTA DA QUALIDADE EM PROGRAMAS DE SEGURANÇA HOSPITALAR UTILIZANDO *PYTHON*

Michele Ferreira Moreira

Instituto Prevent Senior (IPS)

Avenida Brigadeiro Luís Antônio, 3521 - Jardim Paulista, São Paulo / SP

michelefmoreira@gmail.com

Fábio Henrique Martins Queiroz

Universidade Federal Fluminense (UFF)

Rua Passo da Pátria, 156 – São Domingos, Niterói / RJ

fabiohmartins@gmail.com

Silmara Scontre

Universidade Federal Fluminense (UFF)

Rua Passo da Pátria, 156 – São Domingos, Niterói / RJ

silmara.scontre@gmail.com

Ana Cláudia Luna Cândido

Instituto Prevent Senior (IPS)

Avenida Brigadeiro Luís Antônio, 3521 - Jardim Paulista, São Paulo / SP

luna.anaclaudia@gmail.com

Miguel Ângelo Lellis Moreira

Universidade Federal Fluminense (UFF)

Rua Passo da Pátria, 156 – São Domingos, Niterói / RJ

miguellellis@hotmail.com

Antonio Sergio da Silva

Universidade Federal Fluminense (UFF)

Rua Passo da Pátria, 156 – São Domingos, Niterói / RJ

tao281168@gmail.com

Marcos dos Santos

Instituto Militar de Engenharia (IME)

Praça General Tibúrcio, 80 - Praia Vermelha – Urca / RJ

marcosdossantos_doutorado_uff@yahoo.com.br

RESUMO

Este estudo propõe um modelo de Programação Linear Inteira Mista (MILP) para otimizar a alocação de analistas de qualidade em unidades hospitalares de um sistema de saúde verticalizado. O modelo considera a distância euclidiana e a criticidade das unidades, combinadas em uma matriz de custo ponderada baseada em indicadores de segurança institucional. A implementação foi realizada em *Python*, utilizando o solucionador CBC (*COIN-OR Branch e Cut*) no *Google Colab*, assegurando acessibilidade e reprodutibilidade. O modelo respeita restrições institucionais como exclusividade em unidades críticas, carga de trabalho e total de analistas disponíveis, utilizando a mediana da criticidade como critério de balanceamento. Os resultados apontam para uma alocação eficiente, equitativa e alinhada às prioridades estratégicas da

instituição. Ao integrar modelagem matemática com ferramentas de código aberto, a abordagem reforça a governança baseada em evidências e contribui para a segurança do paciente por meio da gestão estratégica de recursos humanos especializados.

PALAVRAS CHAVE. Otimização Matemática, Distribuição da Força de Trabalho, Segurança do Paciente.

Tópicos (PO aplicada à Saúde. Gestão Hospitalar. Otimização Matemática)

ABSTRACT

This study proposes a Mixed-Integer Linear Programming (MILP) model to optimize the allocation of quality analysts across hospital units within a vertically integrated healthcare system. The model incorporates euclidean distance and unit criticality into a weighted cost matrix, derived from institutional safety indicators. It was implemented in Python using the CBC (COIN-OR Branch and Cut) solver on Google Colab, ensuring accessibility and reproducibility. The optimization respects institutional constraints, including exclusive assignment to high-criticality units, workload limits, and full allocation of available analysts. A median criticality score was used as a classification threshold to enable balanced, data-driven decision-making. The resulting allocation was efficient, equitable, and strategically aligned with patient safety priorities. By using mathematical modeling and open-source technologies, the suggested method helps make decisions based on evidence, improves how institutions are managed, and leads to safer and stronger healthcare operations by effectively using skilled workers.

KEYWORDS. Mathematical Optimization, Workforce Distribution, Patient Safety.

Paper topics (OR applied to Health. Hospital Management. Mathematical Optimization)

1. Introdução

A segurança do paciente emergiu como um imperativo global na busca contínua da qualidade nos sistemas de saúde. Definido pela Organização Mundial da Saúde (OMS) como a prevenção de erros e efeitos adversos aos pacientes associados aos cuidados de saúde, este domínio enfatiza estratégias proativas para reduzir danos, promover a confiabilidade e promover uma cultura de segurança em todos os níveis de atendimento [Montoya 2010]. Em ambientes hospitalares caracterizados por processos dinâmicos, intervenções de alto risco e colaboração interprofissional complexa, garantir a correta alocação de recursos humanos qualificados é essencial para mitigar riscos e gerenciar eventos críticos de forma eficaz.

Entre os principais pilares que sustentam a segurança do paciente está o dimensionamento estratégico e a distribuição de equipes especializadas, particularmente analistas da qualidade que atuam nos núcleos de segurança do paciente (NSP) institucionais. Esses profissionais são vitais para monitorar eventos adversos, analisar as causas e implementar ações preventivas [Montoya 2010]. No entanto, a distribuição equitativa e eficiente desses profissionais em várias unidades de saúde continua sendo um desafio significativo, especialmente quando limitada pela dispersão geográfica, perfis de demanda heterogêneos e variações na criticidade institucional [Pereira et al. 2022, Costa et al. 2021].

Para enfrentar esses desafios, a aplicação da Pesquisa Operacional (PO) tem ganhado cada vez mais destaque na tomada de decisões em saúde. Entre as diversas técnicas de PO, a Programação Linear Inteira Mista (MILP) oferece uma estrutura robusta para otimizar problemas complexos de alocação [Soares et al. 2021]. O MILP permite que os tomadores de decisão modelem várias restrições, minimizem custos ou distâncias e derivem configurações ideais com precisão matemática. Seu uso na área da saúde se expandiu na última década, apoiando o planejamento do *layout* do hospital, agendamento de pessoal, transporte de pacientes e alocação de recursos sob incerteza [Rodrigues et al. 2021, Maêda et al. 2021].

Complementando os recursos de modelagem do MILP está o uso do *Python*, uma linguagem de programação de alto nível amplamente adotada na computação científica. O extenso ecossistema de bibliotecas do *Python*, como *PuLP*, *SciPy* e *OR-Tools*, fornece ferramentas para formular, resolver e visualizar modelos de otimização, tornando-o um recurso acessível e flexível para pesquisadores e profissionais em gestão de saúde [Costa et al. 2021, Moreira et al. 2022].

Este estudo propõe um modelo baseado em MILP implementado em *Python* para otimizar a alocação de analistas da qualidade no núcleo de segurança do paciente em 16 unidades hospitalares pertencentes a um sistema de saúde verticalmente integrado em São Paulo, Brasil. O objetivo principal é alocar cada analista em unidades hospitalares mais próximas de seu local de residência, respeitando restrições operacionais críticas. Ao apresentar esse caso do mundo real, o estudo contribui com uma abordagem estruturada, replicável e baseada em dados para a distribuição da força de trabalho na área da saúde. A solução proposta não só potencializa a utilização racional dos recursos humanos, como também reforça as estratégias institucionais de segurança do paciente e apoia a tomada de decisão baseada em evidências em sistemas de saúde complexos.

Ao longo do artigo, a seção 2 apresenta em detalhes a metodologia adotada, incluindo as etapas de formulação do modelo MILP, o pré-processamento dos dados e a implementação computacional em *Python*. Na seção 3, são descritos e analisados os resultados obtidos, com destaque para a avaliação da alocação proposta frente às restrições institucionais e indicadores de criticidade. Por fim, a seção 4 reúne as considerações finais, discutindo as contribuições do estudo, suas limitações e potenciais caminhos para trabalhos futuros.

2. Metodologia

O estudo integrou técnicas de programação matemática e modelagem computacional aplicadas à gestão de serviços de saúde [Lopes et al. 2024, Soares et al. 2021].

O modelo foi implementado em *Python* utilizando a biblioteca *PuLP* e resolvido pelo *solver* CBC (*COIN-OR Branch and Cut*) no ambiente *Google Colab*, garantindo reprodutibilidade, escalabilidade e viabilidade prática.

A abordagem incorporou variáveis de distância geográfica, calculadas a partir de coordenadas reais e indicadores de criticidade institucional, derivados da média ponderada dos eventos adversos ocorridos em 2024. Esses dados foram pré-processados e estruturados em uma matriz de custos, base para a formulação do problema.

O processo metodológico foi organizado em três etapas principais:

1. **Definição de premissas:** número total de analistas, unidades hospitalares e restrições institucionais (carga de trabalho, criticidade e cobertura mínima).
2. **Preparação do banco de dados:** consolidação das matrizes de distância e criticidade em uma matriz de custo única.
3. **Modelagem computacional:** formulação do modelo MILP para minimizar o custo total ponderado, implementada no *PuLP* e resolvida pelo CBC no *Google Colab*. As variáveis de decisão, matriz de custos e restrições foram geradas dinamicamente a partir de dados reais, com monitoramento do tempo de execução e da convergência da solução para assegurar aplicabilidade prática. A formulação proposta foi resolvida em aproximadamente 2 segundos, evidenciando alta eficiência computacional para o porte da instância analisada.

O uso do *Python* e do CBC superou as limitações das ferramentas tradicionais baseadas em planilhas, oferecendo flexibilidade, portabilidade e reprodutibilidade dos experimentos computacionais, permitindo lidar com a complexidade combinatória do problema e garantindo rastreabilidade dos resultados. A figura 1 apresenta o fluxograma do processo metodológico desenvolvido.




Figura 1. Fluxograma do processo metodológico do modelo de alocação otimizada

2.1 Estruturação do Problema

O problema de otimização abordado neste estudo consiste em alocar 10 analistas de qualidade a 16 unidades hospitalares localizadas na cidade de São Paulo, Brasil, considerando simultaneamente restrições institucionais e operacionais. A formulação utiliza indicadores de

criticidade institucional, calculados a partir de taxas de eventos adversos (danos leves, moderados, graves e óbitos) ponderadas por gravidade e frequência, combinados com distâncias geográficas obtidas por coordenadas reais, resultando em uma matriz de custo ponderada.

A variável criticidade foi definida pela média ponderada do total de eventos adversos registrados em 2024 em cada unidade hospitalar, atribuindo-se pesos arbitrários definidos pelo gestor da área conforme a gravidade de cada tipo de evento. Em seguida, criou-se a variável *matriz_custo*, calculada como:

$$Matriz_Custo_{ij} = Distância_{ij} \times (1 + Criticidade_j) \quad (1)$$

Onde:

- $Distância_{ij}$ é a distância do analista i até a unidade hospitalar j ;
- $Criticidade_j$ é o índice de criticidade da unidade j , definido pela média ponderada dos eventos adversos.

Após a definição dos custos ponderados entre os analistas da qualidade e as unidades hospitalares, é gerada uma matriz de variáveis (2), representando os respectivos custos de alocação C_{ij} .

A matriz de custos é expressa como:

$$\begin{pmatrix} c_{11} & c_{12} & c_{13} & \cdots & c_{1n} \\ c_{21} & c_{22} & c_{23} & \cdots & c_{2n} \\ c_{31} & c_{32} & c_{33} & \cdots & c_{3n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ c_{m1} & c_{m2} & c_{m3} & \cdots & c_{mn} \end{pmatrix} \quad (2)$$

Por fim, calculou-se a mediana da *matriz_custo* para classificar as unidades hospitalares como de baixa ou alta criticidade, classificação utilizada como parâmetro central na formulação das restrições do modelo (Figura 2).




Figura 2. Boxplot da *matriz_custo* e mediana para classificação da criticidade

Trata-se de uma variante do problema clássico de designação com múltiplas restrições, classificado como NP-difícil (*NP-hard*), cuja complexidade computacional cresce exponencialmente com o número de unidades e profissionais envolvidos. Tal característica inviabiliza abordagens exaustivas para instâncias de maior porte e justifica o uso de Programação Linear Inteira Mista (MILP) resolvida com *solvers* especializados, capazes de obter soluções ótimas em tempo computacional viável.

Na realidade operacional da instituição, os analistas atuam em regime administrativo, de segunda a sexta-feira, das 8h às 18h, sem turnos alternados. O objetivo principal da alocação é reduzir o deslocamento diário, atendendo a uma demanda recorrente da equipe para que fossem designados a unidades mais próximas de suas residências. Como existem 16 unidades hospitalares e apenas 10 analistas disponíveis, é inevitável que alguns profissionais sejam alocados a mais de uma unidade. Para evitar sobrecarga e garantir que nenhuma unidade fique sem cobertura, foi estabelecida a regra de que um analista pode ser designado a no máximo duas unidades, sendo obrigatoriamente uma de alta criticidade e outra de baixa criticidade. Adicionalmente, os analistas designados a apenas uma unidade hospitalar devem absorver demandas complementares no núcleo de segurança do paciente (NSP), de forma a manter a distribuição das atividades equilibrada entre todos os membros da equipe.

Estudos prévios têm abordado problemas de alocação de recursos humanos em saúde utilizando diferentes estratégias. Modelos exatos baseados em MILP já foram aplicados à programação de turnos médicos [Rodrigues et al., 2021], à distribuição de equipes de enfermagem [Lopes et al., 2024] e à gestão de equipes de auditoria hospitalar [Costa et al., 2021]. Alternativamente, heurísticas e meta-heurísticas como algoritmos genéticos, *simulated annealing* e busca tabu têm sido exploradas para lidar com instâncias de grande escala ou alta variabilidade operacional [Maêda et al., 2021]. Experiências internacionais incluem aplicações na rede pública canadense e em sistemas hospitalares europeus, voltadas à otimização de rotas e cobertura de plantões [Soares et al., 2021]. No Brasil, ainda são raras as aplicações documentadas, com destaque para iniciativas voltadas à alocação de equipes na atenção básica e à otimização de visitas domiciliares [Moreira et al., 2022].

A formulação matemática dessas restrições, bem como a representação formal das variáveis e parâmetros, é apresentada na subseção seguinte referente ao processo axiomático.

2.2 Processo axiomático

O problema de alocação de recursos abordado neste estudo é estruturado de acordo com os princípios de modelagem axiomática da programação matemática [Soares et al. 2021]. No presente caso, o objetivo é atribuir um conjunto de analistas da qualidade às unidades hospitalares de forma a minimizar o custo global de alocação, considerando distâncias geográficas e níveis de criticidade institucional.

A perspectiva de modelagem adotada é planar, utilizando a distância euclidiana como base para o cálculo da proximidade espacial entre cada analista e unidade hospitalar (Figura 3). Cada analista i e unidade j está associado a uma coordenada geográfica, permitindo que a distância seja calculada pela fórmula (3): $(x, y)d_{ij}$




Figura 3. Distância entre duas localidades

$$d_{ij}(I, J) = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \quad (3)$$

Onde I e J representam, respectivamente, os conjuntos de analistas da qualidade e de unidades hospitalares, conforme definidos na subseção 2.1.

Essa distância é ajustada ainda pela pontuação de criticidade de cada unidade, gerando um custo de alocação ponderado, definido conforme descrito na equação (1).

Embora a métrica euclidiana seja amplamente utilizada em modelos de otimização por sua simplicidade e baixo custo computacional, reconhece-se que recursos de *softwares* de georreferenciamento e mapas digitais permitem estimar distâncias reais, considerando trajetos viários e condições geográficas. Essa abordagem não foi testada neste estudo, mas é recomendada para trabalhos futuros, pois pode fornecer maior acurácia à modelagem, especialmente em cenários onde a malha viária influencia significativamente o tempo e custo de deslocamento.

Uma vez estabelecida a matriz de custos, o processo de tomada de decisão envolve a atribuição de analistas às unidades, respeitando um conjunto de restrições operacionais e institucionais. Variáveis de decisão binárias, reintroduzidas para representar se o analista i é atribuído à unidade j . O objetivo de otimização é expresso como: $x_{ij} \in \{0,1\}$

$$\text{Minimizar } Z = \sum_i \sum_j cij \cdot x_{ij} \quad (4)$$

Sujeito às seguintes restrições:

- (C1) Alocação única: cada unidade hospitalar deve receber exatamente um analista.

$$\sum_i x_{ij} = 1 \quad \forall j \quad (5)$$

- (C2) Restrição de capacidade: cada analista pode ser alocado em no máximo duas unidades.

$$\sum_j x_{ij} \leq 2 \quad \forall i \quad (6)$$

- (C3) Restrição de alta criticidade: um analista não pode ser alocado a duas unidades classificadas como sendo de alta criticidade.

$$x_{ij_1} + x_{ij_2} \leq 1 \text{ Se } j_1, j_2 \in \text{Alta_Criticidade}, \forall i \quad (7)$$

- (C4) Participação plena: todos os analistas devem estar alocados em pelo menos uma unidade hospitalar.

$$\sum_j x_{ij} \geq 1 \quad \forall i \quad (8)$$

Essa estratégia de modelagem visa alcançar uma distribuição ótima da força de trabalho, preservando as políticas organizacionais e garantindo que as unidades de alta complexidade recebam cobertura profissional distinta e dedicada. O modelo matemático é implementado usando MILP (Programação Linear Inteira Mista) e resolvido através das técnicas computacionais descritas anteriormente.

3. Resultados e Discussão

A implementação do modelo Programação Linear Inteira Mista (MILP), desenvolvido em *Python* e resolvido usando o solucionador CBC no ambiente *Google Colab*, produziu uma alocação coerente e otimizada de analistas da qualidade entre unidades hospitalares em um sistema de saúde verticalmente integrado [Lopes et al. 2024]. A função de custo integrou a distância euclidiana entre as localizações residenciais dos analistas e as unidades hospitalares, ponderada por um escore de criticidade institucional normalizado, resultando em uma estrutura que equilibrou a eficiência geográfica e o risco à segurança do paciente (Tabela 1).

Tabela 1. Distância x Criticidade entre analistas e unidades hospitalares

Unidade	Criticidade	Analista A	Analista B	Analista C	Analista D	Analista E	Analista F	Analista G	Analista H	Analista I	Analista J
U1	4,46	23,9	27,0	10,0	35,7	16,7	19,2	9,8	7,5	14,7	47,7
U2	1,04	13,3	22,0	39,2	24,4	15,8	12,0	44,2	36,5	31,6	26,9
U3	1,17	6,4	13,7	25,8	20,1	8,9	4,3	29,5	24,5	21,8	23,5
U4	0,83	24,0	12,7	49,9	39,0	21,6	14,6	31,0	28,1	22,5	39,7
U5	1,16	18,0	22,7	15,8	32,5	20,8	10,5	15,7	12,8	10,6	33,2
U6	1,50	8,5	10,7	25,0	22,4	11,9	1,2	29,7	26,5	20,8	29,0
U7	15,26	25,7	27,8	11,7	38,9	33,4	19,7	8,9	5,4	9,1	50,9
U8	0,70	10,0	16,0	21,6	24,5	14,2	4,8	22,5	21,4	16,5	27,5
U9	34,60	11,0	16,5	21,0	24,9	14,9	5,6	24,5	20,3	15,7	28,0
U10	4,04	9,5	14,5	22,0	23,7	12,5	3,6	23,2	22,3	17,7	26,5
U11	2,14	15,5	18,8	18,7	26,6	15,8	7,2	21,4	18,3	13,7	30,0
U12	3,38	17,0	14,6	21,7	23,9	19,5	7,9	20,1	17,4	11,5	36,0
U13	3,40	18,8	21,5	14,6	30,3	20,5	12,7	16,4	9,0	17,8	36,4
U14	9,92	13,5	18,5	18,7	28,0	16,3	8,5	19,9	17,5	20,3	31,7
U15	5,05	17,0	22,0	15,0	32,0	20,0	12,0	16,0	12,0	9,8	35,0
U16	9,62	14,0	19,0	19,0	11,0	18,0	7,7	20,0	18,0	15,0	31,0

O modelo respeitou todas as restrições impostas: cada unidade recebeu exatamente um analista; nenhum analista foi designado para mais de duas unidades; e nenhum analista foi responsável por duas unidades classificadas como de alta criticidade. A classificação da criticidade da unidade foi estabelecida utilizando-se como ponto de corte o valor da mediana de todos os escores de risco institucionais (Tabela 2). As unidades com escores acima da mediana foram consideradas de alta criticidade. Essa abordagem estatisticamente fundamentada permitiu uma diferenciação objetiva das necessidades de supervisão em todo o sistema.

Tabela 2 – Estatística descritiva da criticidade da unidade hospitalar

Estatística	Valor
Média	36,85
Desvio padrão	34,43
Mínimo	07,00
1º quartil (Q1)	11,57
Mediana (Q2)	33,65
3º quartil (Q3)	45,28
Máximo	147,20
Amplitude	140,20
Coefficiente de variação (%)	93,44

Os resultados confirmam que o modelo proposto foi eficaz na minimização do custo total ponderado de alocação. Os analistas foram preferencialmente designados a unidades geograficamente próximas, o que contribuiu para a redução dos encargos associados aos deslocamentos. Adicionalmente, a imposição da restrição que impede a alocação simultânea de um mesmo analista a múltiplas unidades classificadas como de alta criticidade assegurou uma distribuição equitativa das responsabilidades operacionais (Tabela 3). A alocação final dos analistas pode ser visualizada graficamente na figura 4, a qual apresenta a distribuição espacial dos analistas em relação às unidades assistenciais, conforme resultado do modelo de otimização. As cores indicam o nível de criticidade das unidades (alta ou baixa), e os marcadores representam os pontos de alocação dos analistas, priorizando proximidade geográfica e respeitando a restrição de não sobreposição em unidades de alta criticidade.

Tabela 3 – Alocação final dos analistas da qualidade nas unidades hospitalares

Unidade	Analista A	Analista B	Analista C	Analista D	Analista E	Analista F	Analista G	Analista H	Analista I	Analista J
U1	0	0	0	0	0	0	1	0	0	0
U2	0	0	0	0	0	0	0	0	0	1
U3	0	0	0	0	1	0	0	0	0	0
U4	0	1	0	0	0	0	0	0	0	0
U5	0	0	0	0	0	0	0	1	0	0
U6	0	1	0	0	0	0	0	0	0	0
U7	0	0	0	0	0	0	0	1	0	0
U8	1	0	0	0	0	0	0	0	0	0
U9	0	0	0	0	0	1	0	0	0	0
U10	0	0	0	0	1	0	0	0	0	0
U11	0	0	0	0	0	1	0	0	0	0
U12	0	0	0	0	0	0	0	0	1	0
U13	0	0	1	0	0	0	0	0	0	0
U14	1	0	0	0	0	0	0	0	0	0
U15	0	0	0	0	0	0	0	0	1	0
U16	0	0	0	1	0	0	0	0	0	0




Figura 4. Mapa geográfico de alocação dos analistas nas unidades hospitalares

As unidades como a unidade 3 e a unidade 4, classificadas como de baixo risco com base em critérios institucionais, foram usadas para equilibrar as alocações de analistas que também foram designados para unidades mais centrais ou moderadamente críticas. Todos os analistas foram utilizados sem violar quaisquer restrições, reforçando a viabilidade prática do modelo e o alinhamento com os objetivos institucionais de gestão da força de trabalho.

Do ponto de vista operacional, os resultados ressaltam a relevância estratégica do uso da programação matemática para apoiar a tomada de decisão em ambientes de saúde [Drumond et al. 2021, Moreira et al. 2022]. O modelo proposto proporcionou uma distribuição equitativa de profissionais e respeitou as principais prioridades institucionais relacionadas à segurança e sustentabilidade da força de trabalho, oferecendo uma estratégia de alocação transparente e replicável baseada em dados [Soares et al. 2021, Silva et al. 2023].

Apesar de sua eficácia, o modelo apresenta algumas limitações. Não incorpora variáveis qualitativas, como experiência profissional, habilidades específicas ou preferências pessoais. Além disso, a classificação binária de criticidade, embora operacionalmente robusta, pode ser aprimorada por meio de modelos de análise de decisão multicritério ou lógica *fuzzy* que reflitam com mais precisão a complexidade do risco institucional. Iterações futuras do modelo também podem integrar recursos dinâmicos, como atualizações em tempo real ou simulação de realocações de emergência. No entanto, vale a pena notar que os analistas desempenham um papel ativo na governança em nível de unidade, participando de investigações de incidentes, iniciativas de melhoria de processos e atividades de treinamento. Isso reforça a relevância de sua alocação estratégica não apenas do ponto de vista logístico, mas como parte de uma cultura institucional mais ampla de segurança e qualidade.

4. Conclusão

Este estudo apresentou a aplicação de um modelo de Programação Linear Inteira Mista (MILP), implementado em *Python*, para otimizar a alocação de analistas da qualidade entre unidades hospitalares em um sistema de saúde verticalmente integrado. Fundamentado nos princípios de segurança do paciente e eficiência operacional, o modelo incorporou indicadores de criticidade institucional e distâncias geográficas para orientar a tomada de decisão sob rígidas

restrições de alocação. Os resultados obtidos confirmaram a viabilidade técnica do modelo e seu potencial para apoiar a tomada de decisões do mundo real em ambientes complexos de saúde. Ao garantir que cada unidade hospitalar recebesse exatamente um analista, evitando a atribuição simultânea de unidades de alta criticidade ao mesmo profissional e minimizando os custos totais de alocação, a solução demonstrou total conformidade com as diretrizes institucionais e aprimorou a utilização de recursos. A utilização da mediana como ponto de corte para classificar a criticidade das unidades hospitalares constituiu um mecanismo estatisticamente robusto, permitindo identificar aquelas com maior risco. Essa abordagem viabilizou um equilíbrio mais eficiente na distribuição da carga de trabalho e fortaleceu a supervisão direcionada nos locais com maior necessidade de intervenção.

Do ponto de vista da gestão, o modelo contribui para um planejamento de recursos humanos mais claro, transparente e fácil de replicar, além de poder ser aplicado em outras unidades ou departamentos da instituição. Ele também fortalece o compromisso com a segurança do paciente, ao garantir que os profissionais responsáveis por monitorar eventos adversos, implementar ações preventivas e apoiar a melhoria da qualidade sejam distribuídos de forma estratégica, com base em critérios objetivos. No entanto, apesar de eficaz, o modelo apresentou limitações que indicam caminhos para pesquisas futuras. A versão atual não considera fatores qualitativos relevantes, como o nível de experiência dos analistas, suas habilidades específicas ou a familiaridade com determinadas unidades. Além disso, a classificação das unidades em apenas dois níveis de criticidade (alta ou baixa) é uma simplificação que pode ser aprimorada. Outra possível evolução metodológica consiste em substituir a distância euclidiana por distâncias reais obtidas por *softwares* de georreferenciamento, capazes de refletir com maior precisão a malha viária e o tempo efetivo de deslocamento. Métodos de apoio à decisão multicritério podem ser incorporados para representar melhor a complexidade dos riscos institucionais. Futuramente, o modelo também pode ser expandido para simular cenários como realocação temporária de profissionais, aumento emergencial da demanda ou ausências imprevistas na equipe.

Este estudo apresenta uma solução metodologicamente sólida, de código aberto e passível de replicação, voltada à otimização da alocação de profissionais em programas de segurança do paciente. O modelo proposto integra critérios objetivos ao processo decisório, ampliando a transparência na gestão e oferecendo uma abordagem prática para enfrentar os desafios relacionados à distribuição equitativa da força de trabalho em contextos complexos e com recursos limitados. Ao adotar uma lógica de priorização fundamentada em dados, a ferramenta favorece a tomada de decisões mais assertivas e alinhadas aos princípios da qualidade assistencial e da vigilância em saúde. Além de aprimorar a capacidade de planejamento institucional, a aplicação deste modelo fortalece a governança organizacional ao promover uma cultura de decisões orientadas por evidências. A distribuição estratégica dos profissionais, baseada em parâmetros objetivos de criticidade, contribui diretamente para a mitigação de riscos assistenciais e para o fortalecimento da resiliência dos serviços de saúde. Nesse sentido, a proposta aqui desenvolvida se configura como um instrumento relevante para apoiar políticas institucionais voltadas à segurança do paciente, podendo ser adaptada a diferentes realidades organizacionais e ampliada por meio de futuras evoluções metodológicas.

Referências

Costa, I. P. A., Basílio, M. P., Maêda, S. M. N., Rodrigues, M. V. G., Moreira, M. Â. L., Gomes, C. F. S. e Santos, M. (2021). Seleção de algoritmos para classificação de aprendizado de máquina: uma aplicação do método multicritério MELCHIOR. *Fronteiras em Inteligência Artificial e Aplicações*, 341:154–161. <https://doi.org/10.3233/FAIA210243>.

Costa, I. P. A., Sanseverino, A. M., Barcelos, M. R. S., Belderrain, M. C. N., Gomes, C. F. S. e Santos, M. (2021). Escolhendo hospitais voadores no combate à pandemia de COVID-19:

estruturando e modelando um problema complexo usando os métodos VFT e ELECTRE-MOr. *Transações IEEE América Latina*, 19(6):1099–1106. <https://doi.org/10.1109/TLA.2021.9451257>.

Drumond, P., Basílio, M. P., Costa, I. P. A., Pereira, D. A. M., Gomes, C. F. S. e Santos, M. (2021). Análise multicritério em manufatura aditiva: uma abordagem baseada em ELECTRE-MOr. *Fronteiras em Inteligência Artificial e Aplicações*, 341:126–132. <https://doi.org/10.3233/FAIA210240>.

Lopes, C. C. G., Cunha Filho, R. S., Padovani, F. H., Figueiredo, R., Felipe, M. C. B. G., Silva, A. S., Moreira, M. Â. L., Costa, A. P. A. e Santos, M. (2024). Estratégia para otimização do acesso ambulatorial para pacientes crônicos em uma operadora de planos de saúde. *Revista Internacional de Gestão em Saúde*. <https://doi.org/10.1080/20479700.2024.2400438>.

Maêda, S. M. N., Basílio, M. P., Costa, I. P. A., Moreira, M. Â. L., Santos, M., Gomes, C. F. S., Almeida, I. D. P. e Costa, A. P. A. (2021). Investimentos em tempos de pandemia: uma abordagem pelo método SAPEVO-M-NC. *Fronteiras em Inteligência Artificial e Aplicações*, 341:162–168. <https://doi.org/10.3233/FAIA210244>.

Montoya, I. D. (2010). Segurança do paciente e melhoria da qualidade: uma avaliação de políticas. *Ciência de Laboratório Clínico*, 23(4):212–218. PMID: 21140794.

Moreira, M. Â. L., Gomes, C. F. S., Santos, M., Silva Júnior, A. C. e Costa, I. P. A. (2022). Análise de sensibilidade pelo método PROMETHEE-GAIA: avaliação de algoritmos para previsão de COVID-19. *Procedia Ciência da Computação*, 199:431–438. <https://doi.org/10.1016/j.procs.2022.01.052>.

Moreira, M. Â. L., Rocha Júnior, C. S., Silva, D. F. L., Castro Júnior, M. A. P., Costa, I. P. A., Gomes, C. F. S. e Santos, M. (2022). Análise exploratória e implementação de técnicas de aprendizado de máquina para avaliação preditiva de fraude em sistemas bancários. *Procedia Ciência da Computação*, 214:117–124. <https://doi.org/10.1016/j.procs.2022.11.156>.

Pereira, R. C. A., Moreira, M. Â. L., Costa, I. P. A., Tenório, F. M., Barud, N. A., Fávero, L. P., Al-Qudah, A. A., Gomes, C. F. S. e Santos, M. (2022). Viabilidade de um Sistema de Informação Hospitalar para uma Organização Pública Militar à luz da Análise Multicritério. *Saúde*, 10(11):2147. <https://doi.org/10.3390/healthcare10112147>.

Rodrigues, M. V. G., Duarte, T. E., Santos, M. e Gomes, C. F. S. (2021). Análise de cenários prospectivos: impacto na demanda por petróleo e seus derivados após a pandemia de COVID-19. *Revista Brasileira de Gestão de Operações e Produção*, 18(2):1–15. <https://doi.org/10.14488/BJOPM.2021.039>.

Silva, N. F., Santos, M., Gomes, C. F. S. e Andrade, L. P. (2023). Uma abordagem integrada de CRITIC e Análise Relacional Cinza para seleção de portfólio de investimentos. *Revista de Análise de Decisão*, 8:100285. <https://doi.org/10.1016/j.dajour.2023.100285>.

Soares, L. M. B., Moreira, M. Â. L., Basílio, M. P., Gomes, C. F. S., Santos, M. e Costa, I. P. A. (2021). Análise estratégica para a instalação de hospitais de campanha para controle da COVID-19: uma abordagem baseada no modelo P-mediana. In: *Anais do MMBD/MLIS 2021*, p. 112–118.