

Modelagem Matemática para a Alocação de Leitos de UTI com Diferentes Tipos de Leitos e Taxa de Ocupação

Carlos Eduardo V. Gomes¹, Glaubos Clímaco¹, João Augusto F. Nunes de Carvalho¹,
Darlan Bruno Pontes Quintanilha¹

¹Departamento de Informática – Universidade Federal do Maranhão (UFMA)
– São Luís – MA – Brazil

{carlos.evg, augusto.joao}@discente.ufma.br

{francisco.glaubos, darlan.quintanilha}@ufma.br

Abstract. *This work addresses an Intensive Care Unit (ICU) bed allocation problem, which considers different types of beds and an ideal occupancy rate. This problem arises from the difficulty of healthcare professionals in choosing which patients to allocate to ICU beds, due to the number of factors under consideration. Therefore, a new mathematical modeling is proposed that integrates different types of beds and ideal occupancy rate, while maximizing patient survival rates. To validate the model, computational simulation experiments were carried out using real data from the University Hospital of the Federal University of Maranhão (HU-UFMA), and the results highlight the importance of the model especially in high demand situations.*

Resumo. *Este trabalho aborda um problema de alocação de leitos de Unidade de Terapia Intensiva (UTI), em que se considera diferentes tipos de leitos e uma taxa de ocupação ideal. Tal problema surge da dificuldade de profissionais da saúde em escolher quais pacientes alocar em leitos de UTI, devido à quantidade de fatores em consideração. Dessa forma, é proposta uma nova modelagem matemática que integra diferentes tipos de leitos e taxa de ocupação ideal, enquanto maximiza a taxa de sobrevivência dos pacientes. Para a validação do modelo, experimentos computacionais de simulação foram realizados a partir de dados reais do Hospital Universitário da Universidade Federal do Maranhão (HU-UFMA), e os resultados destacam a importância do modelo principalmente em situações de alta demanda.*

1. Introdução

A pandemia de COVID-19 trouxe desafios sem precedentes para os sistemas de saúde globalmente, exacerbando a necessidade de alocação eficiente de leitos de Unidades de Terapia Intensiva (UTI). A alocação de leitos de UTI, crucial para garantir o tratamento adequado aos pacientes críticos, torna-se um problema complexo diante de incertezas como a taxa de chegada de pacientes e a demanda por ventilação mecânica. Neste contexto, a literatura recente tem explorado diversas estratégias e modelos para otimizar a utilização desses recursos limitados.

[Aquino et al. 2022] realiza uma análise comparativa crítica das diretrizes de triagem de UTI durante a pandemia, destacando a variação nos conceitos éticos e princípios

que orientam as decisões difíceis nos cuidados críticos. A experiência da Itália, como epicentro europeu da crise, oferece lições valiosas sobre a gestão da capacidade de UTI em tempos de demanda sem precedentes, conforme discutido em [Craxì et al. 2020] e [Dieteren et al. 2022], em que se aborda a importância de diretrizes claras e a opinião pública na alocação de leitos.

A utilização de técnicas de otimização combinatória como programação linear (PL), programação não-linear (PNL) e programação linear inteira (PLI) [Dantzig 2002, Wolsey 2020] tem se tornado cada vez mais significativa na alocação eficiente de leitos de Unidade de Terapia Intensiva, oferecendo soluções estruturadas para gerenciar as complexidades dos recursos de saúde sob rigorosas restrições. A programação linear permite a formulação de problemas de otimização por meio de funções objetivo e restrições, otimizando a utilização dos leitos de UTI em relação à entrada variável de pacientes. Essas técnicas de otimização combinatória buscam explorar permutações e combinações de distribuição de recursos, facilitando a tomada de decisão discreta para necessidades específicas do paciente, como, por exemplo, na otimização do agendamento de cirurgias e na alocação de recursos [King et al. 2019, Wang and Wang 2008].

[Frej et al. 2021] introduziram um modelo matemático que utiliza seleção de portfólio e Teoria da Utilidade, para otimizar a alocação de leitos de UTI, aproveitando o julgamento de especialistas e simulações de Monte-Carlo. Essa abordagem aborda o desafio de tomar decisões de alocação em meio à incerteza dos resultados de sobrevivência dos pacientes. Recentemente, [Frej et al. 2023] investigaram os dilemas éticos e operacionais que os gestores de saúde enfrentam em relação às admissões na UTI, oferecendo uma solução que mescla a Teoria da Utilidade Esperada com a análise de decisão bayesiana, usando a pontuação *Sequential Organ Failure Assessment* (SOFA) para prever as probabilidades de sobrevivência dos pacientes.

O objetivo deste trabalho é propor um novo modelo matemático para resolver um problema de alocação de leitos de UTI, baseando-se no recente estudo de [Frej et al. 2023]. A inovação do modelo proposto está no seu processo de tomada de decisão, que considera diferentes tipos de leitos de UTI (adulto, pediátrico, e neonatal) além de um requisito de taxa de ocupação, que deve estar em torno de uma certa porcentagem ideal.

Uma taxa de ocupação adequada assegura que haja capacidade suficiente para acomodar variações na demanda, como surtos de doenças ou acidentes em massa, sem comprometer a qualidade do atendimento. Além disso, otimiza o uso dos recursos hospitalares, incluindo pessoal, equipamentos e instalações, permitindo um equilíbrio entre a eficiência operacional e a prontidão para emergências.

Dada a discussão ampla na literatura sobre a melhor maneira de realizar esse tipo de alocação, este trabalho também se propõe a analisar diferentes estratégias de alocação, e seus impactos na taxa de sobrevivência dos pacientes. Para validar a proposta, experimentos de simulação foram realizados a partir de dados reais do Hospital Universitário da Universidade Federal do Maranhão (HU-UFMA).

O restante deste trabalho está organizado da seguinte forma: na Seção 2 são apresentados trabalhos relacionados ao tema da proposta. A modelagem matemática proposta é introduzida na Seção 3. Na Seção 4 são descritos os procedimentos para a criação de

cenários de simulação. Os experimentos e análise de resultados são mostrados na Seção 5. Por fim, na Seção 6, algumas considerações finais são feitas e trabalhos futuros são sugeridos.

2. Trabalhos Relacionados

Este trabalho insere-se num contexto de pesquisa amplamente explorado, especialmente durante e após a pandemia de COVID-19, que evidenciou a importância crítica da gestão de capacidade em Unidades de Terapia Intensiva (UTI). A seguir, destacamos algumas pesquisas relacionadas que formam a base teórica e metodológica para o desenvolvimento do nosso modelo matemático adaptado aos desafios do sistema de saúde brasileiro.

Em [Frej et al. 2021], é proposto um modelo de decisão para alocação de leitos de unidade de terapia intensiva (UTI) com recursos escassos nos sistemas de saúde durante a pandemia de COVID-19, que se baseia em uma abordagem de seleção de portfólio sob os conceitos da teoria da utilidade. [White et al. 2021] discutem uma estrutura de alocação de múltiplos princípios para leitos de UTI e ventiladores, que inclui quatro critérios: chances de sobrevivência, prognóstico a curto prazo, prioridade para trabalhadores essenciais da linha de frente e prioridade para pacientes mais jovens.

[Schmidt et al. 2021] forneceram aos hospitais um modelo de planejamento para alocar recursos para UTIs, dada uma certa incidência de casos de COVID-19, e a análise de 334 casos de quatro condados adjacentes a sudoeste de Munique. Em [de Vicuña Bilbao and de Vicuña Bilbao 2022], foi desenvolvido um modelo de simulação de eventos discretos (DES) para analisar e melhorar as decisões de admissão e alta de pacientes em uma unidade de terapia intensiva (UTI), o que é especialmente relevante em situações de alta ocupação da UTI, ao poderem levar à alta precoce de um paciente internado ou o redirecionamento de um recém-chegado.

Em [Frej et al. 2023] uma abordagem de seleção de portfólio é proposta para apoiar o enfrentamento do problema de alocação de UTI usando a Teoria da Utilidade Esperada, e a análise de decisão Bayesiana para estimar as chances de sobrevivência dos pacientes. Um protocolo estruturado foi proposto em conjunto com os médicos, com base na pontuação SOFA (Avaliação Sequencial de Falha de Órgãos). [Murray et al. 2023] desenvolveram um modelo autorregressivo de série temporal de média móvel integrada, que prevê a chegada de pacientes à UTI e um modelo de sobrevivência usando MODS, NEMS e outros fatores para estimar o tempo de permanência do paciente.

A pandemia de COVID-19 evidenciou a importância crucial da gestão de leitos de UTI. Diversos modelos focam na alocação de recursos escassos [Frej et al. 2021, White et al. 2021], no planejamento para diferentes cenários de COVID-19 [Schmidt et al. 2021], ou na análise de decisões de admissão e alta de pacientes [de Vicuña Bilbao and de Vicuña Bilbao 2022]. Existem também pesquisas que abordam a atribuição de leitos a pacientes com base em estimativas de sobrevivência e custos [Karboub and Tabaa 2023], na otimização da saída de pacientes da UTI [Valeva et al. 2023], e na previsão da demanda e do tempo de permanência [Frej et al. 2023, Murray et al. 2023]. A proposta deste trabalho se insere nesse contexto, mas se diferencia por considerar a alocação em diferentes tipos de leitos e uma taxa de ocupação ideal, além de realizar simulações com diferentes níveis demandas.

3. Modelagem Matemática

O modelo de alocação de leitos de UTI foi formulado a partir de um conjunto de restrições, que delimitam o escopo do problema, e três funções objetivo, para analisar diferentes estratégias de alocação (Equações 1, 2, 3). Inicialmente, definimos os conjuntos e os parâmetros utilizados no modelo, nas Tabelas 1 e 2, respectivamente.

Símbolo	Descrição
I	Conjunto de pacientes
I_n	Subconjunto de pacientes neonatais
I_c	Subconjunto de pacientes crianças
I_a	Subconjunto de pacientes adultos
J	Conjunto de tipos de leitos

Tabela 1. Conjuntos utilizados na modelagem.

Parâmetro	Descrição
Q_j	Quantidade de leitos do tipo j disponíveis
P_{in}^i	Probabilidade de sobrevivência do paciente i dentro da UTI
P_{out}^i	Probabilidade de sobrevivência do paciente i fora da UTI
TO	Taxa ideal de ocupação dos leitos de UTI

Tabela 2. Parâmetros utilizados na modelagem.

Já para as variáveis de decisão do modelo, definiu-se $x_{ij} \in B^{|I| \times |J|}$ como sendo uma variável binária que indica se o paciente i é alocado no leito de tipo j ($x_{ij} = 1$) ou não ($x_{ij} = 0$). Dessa forma, a três funções objetivos seguem:

3.1. MSG: Maximizar a expectativa de sobrevivência geral

$$\text{Maximizar } z = \sum_{i=1}^I \sum_{j=1}^J x_{ij} \times P_{in}^i + \sum_{i=1}^I \left(1 - \sum_{j=1}^J x_{ij} \right) \times P_{out}^i - M \times \left(\frac{\sum_{i=1}^I \sum_{j=1}^J x_{ij}}{|Q|} - TO \right)^2 \quad (1)$$

Nesta função objetivo, busca-se maximizar o número total esperado de pacientes sobreviventes considerando suas probabilidades de sobrevivência dentro e fora da UTI. A primeira parcela da expressão consiste em uma soma ponderada das probabilidades de sobrevivência dos pacientes alocados nos leitos de UTI. Na segunda parcela, é considerada uma soma ponderada das probabilidades de sobrevivência dos pacientes não alocados na UTI.

A terceira parcela penaliza a função objetivo com base na taxa de ocupação dos leitos, incentivando a utilização mais eficiente dos mesmos. Dado o número total de leitos $|Q|$ e uma taxa de ocupação ideal $TO \in [0.1, 1.0]$ definida pelo hospital, busca-se penalizar a função objetivo multiplicando a diferença entre a taxa alocada e a taxa ideal, por uma constante grande o suficiente M .

3.2. LSF: *Least Serious First*

$$\text{Maximizar } z = \sum_{i=1}^I \sum_{j=1}^J x_{ij} \times P_{in}^i - M \times \left(\frac{\sum_{i=1}^I \sum_{j=1}^J x_{ij}}{|Q|} - TO \right)^2 \quad (2)$$

A função objetivo LSF prioriza pacientes com menos gravidade para ocupação de leitos, com base na premissa de que pacientes menos graves têm maior probabilidade de sobreviver dentro da UTI (P_{in}). A otimização visa maximizar as chances de sobrevivência desses pacientes, enquanto ainda penaliza pela ocupação dos leitos de maneira que ultrapasse ou não atinja a taxa de ocupação ideal estabelecida pelo hospital. É uma estratégia que pode ser eficaz quando os recursos são suficientes para atender a todos os pacientes graves e menos graves, mas requer um equilíbrio cuidadoso para evitar a subutilização de recursos.

3.3. MSF: *Most Serious First*

$$\text{Minimizar } z = \sum_{i=1}^I \sum_{j=1}^J x_{ij} \times P_{in}^i - M \times \left(\frac{\sum_{i=1}^I \sum_{j=1}^J x_{ij}}{|Q|} - TO \right)^2 \quad (3)$$

A função objetivo MSF tem o foco oposto ao LSF, buscando minimizar o número de pacientes com situação menos grave que permanecem dentro da UTI (P_{in}), dando prioridade a pacientes em situação mais grave, aumentando potencialmente as taxas de sobrevivência aos pacientes não alocados.

3.4. Restrições

Uma vez definido as funções objetivo a serem analisadas, temos as seguintes restrições do problema. A primeira restrição (Eq. 4) assegura que a quantidade de pacientes alocados em cada tipo de leito não exceda a capacidade disponível desse tipo de leito.

$$\sum_{i=1}^I x_{ij} \leq Q_j, \quad \forall j \in J \quad (4)$$

A segunda restrição (Eq. 5) garante que cada paciente seja alocado em no máximo um leito.

$$\sum_{j=1}^J x_{ij} \leq 1, \quad \forall i \in I \quad (5)$$

As demais restrições (Eq. 6 a 8) especificam a alocação para subconjuntos de pacientes (neonatais, crianças e adultos), garantindo que certos tipos de leitos sejam exclusivamente alocados para determinadas faixas etárias.

$$x_{i,0} = 0 \quad \forall i \notin I_n \quad (6)$$

$$x_{i,1} = 0 \quad \forall i \notin I_c \quad (7)$$

$$x_{i,2} = 0 \quad \forall i \notin I_a \quad (8)$$

3.5. FCFS: *First Come-First Served*

Além da modelagem matemática, para fins de simulação, desenvolveu-se um algoritmo para simular uma estratégia FCFS. Trata-se de uma estratégia de atendimento não discriminatório baseado na ordem de chegada. Nesta abordagem, os pacientes são alocados aos leitos de UTI simplesmente pela sequência com que se apresentam para o atendimento, independentemente da gravidade de sua condição ou da probabilidade de sobrevivência. Isso significa que o primeiro paciente na fila receberá o próximo leito disponível.

4. Cenários de Simulação

Para validar as abordagens propostas, foi desenvolvido um algoritmo capaz de reproduzir cenários realistas de UTI. Esse algoritmo permite a manipulação das taxas de chegada de pacientes, distribuições etárias e prevalência de condições médicas específicas. Para atribuir prioridades realistas aos pacientes, foi utilizado o protocolo apresentado em [Frej et al. 2023].

Esse protocolo foi desenvolvido em colaboração com médicos para avaliar as chances de sobrevivência de pacientes em estado crítico. Ele se baseia na pontuação *Sequential Organ Failure Assessment* (SOFA), que mede quantitativamente o grau de falência ou disfunção de órgãos. A pontuação SOFA é calculada a partir de parâmetros fisiológicos, sendo reconhecida como um sistema apropriado para avaliação de morbidade aguda em doenças críticas. O protocolo considera diversas variáveis clínicas importantes, incluindo:

- Condição respiratória: Medida pela eficiência da oxigenação e pela necessidade de suporte ventilatório.
- Condição cardiovascular: Avaliada pela necessidade de uso de medicações vasoativas.
- Coagulação sanguínea: Analisada mediante exames específicos.
- Função renal: Verificada pela taxa de creatinina.
- Função hepática: Avaliada através da taxa de bilirrubina.
- Saturação de oxigênio no sangue.

O protocolo cruza a pontuação SOFA com esses fatores críticos, gerando uma estimativa da probabilidade do paciente sobreviver tanto dentro quanto fora da UTI. Com essas informações, é possível tomar decisões mais embasadas sobre a alocação de leitos de terapia intensiva.

Para a criação dos cenários, foi implementado o pseudocódigo do Algoritmo 1. Na linha 3, inicia-se gerando um número aleatório de pacientes no intervalo $[\alpha \times |Q|, \beta \times |Q|]$ conforme o nível d , em que Q corresponde ao conjunto de leitos, enquanto α e β são determinados conforme um nível de demanda d pré-definido que varia de 1 a 6. Em

seguida, na linha 5, preenche-se aleatoriamente os conjuntos de idades (A), gravidades de pacientes (G) e pontuações SOFA (S).

Para cada um dos pacientes, a função `aplica_protocolo` calcula as probabilidades de sobrevivência na UTI e fora dela com base em idade (A_i), gravidade (G_i) e pontuação SOFA (S_i) de cada paciente i (linhas 7 a 10). Posteriormente, nas linhas 12 a 14, distribuem-se esses pacientes pelos leitos disponíveis de forma aleatória, respeitando a quantidade de leitos de cada tipo (neonatal, infantil e adulto). Por fim, define-se a taxa de ocupação global do cenário, sendo a métrica de eficiência do uso de leitos (linha 16), e retorna-se o cenário criado na linha 17.

Algoritmo 1: Gerar_Cenario(A, Q, TO, d)

```

1:  $cenario \leftarrow \{\}$ ,  $A[] \leftarrow \emptyset$ ,  $G[] \leftarrow \emptyset$ ,  $S[] \leftarrow \emptyset$ 
2: * Gerando n° de pacientes conforme nivel da demanda *
3:  $nPacientes \leftarrow \text{random}(d)$ 
4: * Gerando aleatoriamente os conjuntos *
5:  $A, G, S \leftarrow \text{random}(nPacientes)$ 
6: * Gerando as probabilidades para cada paciente *
7: Para  $i \in nPacientes$  Faça
8:    $P\_in_i, P\_out_i \leftarrow \text{aplicar\_protocolo}(A_i, G_i, S_i)$ 
9:    $cenario.P \leftarrow cenario.P \cup \{P\_in_i, P\_out_i\}$ 
10: Fim Para
11: * Distribuindo pacientes aleatoriamente conforme o leito *
12: Para  $j \in J$  Faça
13:    $cenario.leitos_j \leftarrow \text{DistribuirAleatorio}(pacientes, Q_j)$ 
14: Fim Para
15: * Definindo taxa de ocupação *
16:  $cenario.TO \leftarrow TO$ 
17: return  $instancia$ 

```

5. Resultados e Discussões

Nesta seção, apresentam-se os experimentos computacionais para a validação da nova modelagem matemática proposta. Os algoritmos foram codificados em Python, em um ambiente Manjaro Linux, utilizando o solver Gurobi [Gurobi Optimization 2023] em um computador *Intel®Core™ i3-5005U* com 8 GiB de memória RAM. Com o intuito de avaliar a eficácia de diferentes estratégias ao lidar com o problema de alocação de UTIs considerando diferentes tipos de leitos, e sua influência na preservação de vidas, implementamos um procedimento de simulação (Algoritmo 2), baseado no trabalho de [Frej et al. 2023].

A simulação é realizada ao longo de várias rodadas ($n_rodadas$), cada uma representando uma situação específica de demanda de pacientes baseada em dados do HU-UFMA [EBSERH 2022] durante a pandemia de COVID-19, e com α e β variando de 1,0 a 3,8 para simular os níveis de demanda. Além disso, conforme dados obtidos pelo HU-UFMA, a quantidade total de leitos disponíveis $|Q|$ foi definida como 77, sendo 35 leitos neonatais, 16 leitos pediátricos e 26 leitos adultos.

O Algoritmo 2 descreve um processo iterativo de avaliação das estratégias de alocação de pacientes em UTIs sob diferentes cenários. Em cada iteração de num_rounds , um novo cenário é gerado com base nos parâmetros de idade dos pacientes, quantidade de leitos disponíveis e taxa de ocupação desejada, ajustados pela dinâmica da demanda d . As estratégias MSG, LSF, MSF e FCFS são aplicadas para determinar as alocações de leitos neste cenário.

Algoritmo 2 : Simulacao($n_rodadas, d$)

- 1: **Para** $j \leftarrow 1$ até num_rounds **Faça**
 - 2: $cenario \leftarrow$ GerarCenario(A, Q, TO, d)
 - 3: Definir alocações com a execução das abordagens MSG, LSF, MSF, e FCFS a partir do $cenario$
 - 4: **Para** $i \leftarrow 1$ até $cenario.n_pacientes$ **Faça**
 - 5: Gerar um valor aleatório v_i de maneira uniforme no intervalo $(0, 1]$
 - 6: **Se** $v_i \leq P_{out}^i$ **Então**
 - 7: Paciente i sobrevive independentemente de ser alocado em UTI
 - 8: **Senão Se** $P_{out}^i < v_i \leq P_{in}^i$ **Então**
 - 9: Paciente i sobrevive apenas se for alocado em UTI
 - 10: **Senão Se** $v_i > P_{in}^i$ **Então**
 - 11: Paciente i não sobrevive independentemente se for alocado em UTI
 - 12: **Fim Se**
 - 13: **Fim Para**
 - 14: Para cada estratégia, contabilizar o número de pacientes sobreviventes
 - 15: **Fim Para**
 - 16: **Saída**: Número médio de pacientes sobreviventes por rodada de decisão para as três regras de alocação (MSG, LSF, MSF, e FCFS)
-

Para cada paciente no cenário, um valor aleatório é gerado para determinar o resultado do paciente, representando o elemento aleatório e imprevisível dos resultados de saúde. Se o valor aleatório estiver abaixo da probabilidade de sobrevivência fora da UTI (P_{out_i}), isso implica que no contexto da simulação, o evento “paciente sobrevive fora da UTI” ocorreu. Se o valor estiver entre a probabilidade de sobrevivência fora da UTI e dentro da UTI, a sobrevivência do paciente depende de sua alocação na UTI, definida pela respectiva estratégia. Valores acima de P_{in_i} indicam que o paciente não sobreviverá, independentemente da alocação.

A Tabela 3 apresenta a média de pacientes sobreviventes por rodada de decisão, comparando diferentes estratégias de alocação de leitos de UTI. Cada linha da tabela corresponde a um nível específico de demanda. As colunas MSG, LSF, MSF, e FCFS indicam as médias de pacientes sobreviventes por rodada de decisão para as estratégias de alocação. As colunas $\Delta MSG/LSF$, $\Delta MSG/MSF$ e $\Delta MSG/FCFS$ apresentam a diferença percentual na média de pacientes sobreviventes entre a estratégia MSG e as estratégias LSF, MSF, e FCFS, respectivamente. Um $\Delta > 0$ indica que o MSG pôde superar a estratégia comparada, enquanto $\Delta < 0$ indica o oposto. Resultados em negrito destacam as maiores taxas de sobrevivência.

A análise da Tabela 3, que apresenta os resultados da simulação com 1000 rodadas, revela nuances importantes na eficácia das diferentes estratégias de alocação de leitos de UTI sob várias condições de demanda. Observa-se que a estratégia LSF destaca-se nos

Tabela 3. Resultados a partir da simulação com $n_{rodadas} = 1000$.

Demanda	MSG	LSF	MSF	FCFS	Δ MSG/LSF	Δ MSG/MSF	Δ MSG/FCFS
1	31.98	35.82	7.95	26.27	-10.72 %	302.01 %	21.72 %
2	35.83	40	10.61	26.71	-10.41 %	237.53 %	34.13 %
3	37.99	40.92	10.89	27.10	-7.16 %	248.72 %	40.17 %
4	44.34	44.54	12.00	27.58	-0.45 %	269.38 %	60.73 %
5	48.80	48.23	17.56	29.58	1.19 %	177.85 %	64.96 %
6	50.29	49.51	18.12	30.12	1.59 %	177.58 %	66.94 %

cenários de demanda mais baixa a moderada. Em contraste, a estratégia MSP mostra-se superior em cenários de alta demanda, sugerindo que sua abordagem de maximização da expectativa de sobrevivência geral se adapta melhor às situações onde a gestão eficiente dos recursos disponíveis é crucial para salvar o maior número de vidas.

A MSF demonstra ser a menos eficaz entre as estratégias examinadas. Isso pode ser atribuído à sua ênfase na alocação de leitos para pacientes com as menores probabilidades de sobrevivência fora da UTI, o que, em um cenário de recursos limitados, pode resultar na alocação de recursos para pacientes cujas chances de sobrevivência, mesmo com o suporte da UTI, permanecem relativamente baixas. Tal abordagem pode não ser a mais eficiente quando o objetivo é maximizar o número total de vidas salvas.

Por outro lado, a FCFS, embora intuitivamente pareça uma estratégia menos sofisticada, ao não discriminar com base na gravidade ou na probabilidade de sobrevivência, evita potencialmente a armadilha da MSF, sendo a de priorizar pacientes com prognósticos extremamente ruins. A estratégia FCFS pode, por vezes, resultar em uma distribuição mais “justa” de recursos, especialmente em cenários onde a previsão da probabilidade de sobrevivência não é absolutamente clara ou em situações de mudança rápida, como em uma crise pandêmica.

Outra maneira de analisar os resultados das simulações é por meio das Figuras 1, 2 e 3, que apresentam, por rodada, a média de pacientes sobreviventes em relação ao número total de pacientes alocados. Em cenários com demanda baixa (Figura 1), a estratégia MSG supera as demais mantendo uma taxa de sobrevivência mais constante e alta, indicando eficácia em maximizar as chances de sobrevivência quando há leitos suficientes disponíveis. LSF e FCFS também apresentam bons resultados, mas com uma taxa inferior à MSG, enquanto MSF apresenta as menores taxas de sobrevivência, sugerindo que essa abordagem pode não ser ideal mesmo quando os recursos não estão tão restritos. A medida que a demanda se torna mais alta (Figuras 2 e 3), o desempenho das estratégias MSF e LSF se assemelham, enquanto a estratégia FCFS passa a ser a menos interessante, sendo ultrapassada pela estratégia MSF com $d = 6$.

6. Conclusões

Neste trabalho, foi proposto um modelo matemático para a alocação eficiente de leitos de UTI em um contexto de recursos escassos, considerando diferentes tipos de leitos (adulto, pediátrico e neonatal) e uma taxa de ocupação ideal. O modelo foi desenvolvido com base em três diferentes estratégias de alocação, MSG, LSF, e MSF, além de um algoritmo




Figura 1. Taxa de sobreviventes por total de pacientes alocados - Demanda Baixa ($d = 1$).




Figura 2. Taxa de sobreviventes por total de pacientes alocados - Demanda Alta ($d = 3$).




Figura 3. Taxa de sobreviventes por total de pacientes alocados - Demanda Altíssima ($d = 6$).

FCFS implementado para fins de comparação.

Para avaliar o desempenho das diferentes estratégias, simulações foram realizadas a partir de dados reais fornecidos pelo HU-UFMA, considerando diferentes níveis de demanda de pacientes, distribuições etárias, prevalência de condições médicas e pontuação SOFA. Os resultados obtidos indicam que a estratégia MSG apresenta um bom desempenho em termos de maximizar a expectativa de sobrevivência geral, especialmente em cenários com alta demanda por leitos. A estratégia LSF pode ser mais eficaz em cenários com recursos suficientes para atender a todos os pacientes, enquanto a estratégia MSF pode ser mais adequada em situações com alta taxa de mortalidade entre pacientes graves.

Como limitações deste trabalho, pode-se destacar a pouca variação dos tipos de leitos de UTI considerados, a não consideração de custos de alocação e tratamento, duração possível da estadia na UTI de cada paciente, e a disponibilidade de recursos para cada leito. Para futuras pesquisas, sugere-se elaborar novos modelos matemáticos que incorporem as limitações mencionadas acima, além da implementação de uma solução em formato de software, que integre estas modelagens à interface dos sistemas de gestão hospitalar.

7. Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, Fundação de Amparo a Pesquisa do Maranhão (FAPEMA), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e Empresa Brasileira de Serviços Hospitalares (Ebserh) Brasil (Proc. 409593/2021-4 e 114912/2023-8).

Referências

- Aquino, Y. S. J., Rogers, W. A., Scully, J. L., Magrabi, F., and Carter, S. M. (2022). Ethical guidance for hard decisions: a critical review of early international covid-19 icu triage guidelines. *Health Care Analysis*, 30(2):163–195.
- Craxì, L., Vergano, M., Savulescu, J., and Wilkinson, D. (2020). Rationing in a pandemic: lessons from italy. *Asian Bioethics Review*, 12:325–330.
- Dantzig, G. B. (2002). Linear programming. *Operations research*, 50(1):42–47.
- de Vicuña Bilbao, D. G. and de Vicuña Bilbao, D. G. (2022). Simulation models to support intensive care unit decision-making in pandemic and non-pandemic times. *null*.
- Dieteren, C. M., van Hulslen, M. A., Rohde, K. I., and van Exel, J. (2022). How should icu beds be allocated during a crisis? evidence from the covid-19 pandemic. *Plos one*, 17(8):e0270996.
- EBSERH (2022). Relatório gerencial dos HUFs 2019-2022. https://www.gov.br/ebserh/pt-br/hospitais-universitarios/relatorios-gerenciais/2019-2022/relatorio-gerencial-dos-hufs-2019-2022_e.pdf/@download/file. [online, acesso em 27-fevereiro-2024].
- Frej, E. A., Roselli, L. R. P., Alberti, A. R., Britto, M. A., de Barros Campelo Júnior, E., Ferreira, R. J. P., and de Almeida, A. T. (2023). Collaborative decision model for allocating intensive care units beds with scarce resources in health systems: A portfolio based approach under expected utility theory and bayesian decision analysis. *Mathematics*, 11(3):659.
- Frej, E. A., Roselli, L. R. P., Ferreira, R. J. P., Alberti, A. R., de Almeida, A. T., et al. (2021). Decision model for allocation of intensive care unit beds for suspected covid-19 patients under scarce resources. *Computational and Mathematical Methods in Medicine*, 2021.
- Gurobi Optimization, L. (2023). Gurobi optimizer reference manual.
- Karboub, K. and Tabaa, M. (2023). Bed allocation optimization based on survival analysis, treatment trajectory and costs estimations. *IEEE Access*.
- King, M., Ramnarayan, P., Seaton, S. E., and Pagel, C. (2019). Modelling the allocation of paediatric intensive care retrieval teams in england and wales. *Archives of Disease in Childhood*, 104(10):962–966.
- Murray, L. L., Wilson, J. A., Rodrigues, F. F., and Zaric, G. S. (2023). Forecasting icu census by combining time series and survival models. *Critical Care Explorations*.

- Schmidt, F., Schmidt, F., Hauptmann, C., Hauptmann, C., Kohlenz, W., Kohlenz, W., Gasser, P., Gasser, P., Hartmann, S., Hartmann, S., Daunderer, M., Daunderer, M., Weiler, T., Weiler, T., Nowak, L., and Nowak, L. (2021). Tackling the waves of covid-19: A planning model for intrahospital resource allocation. *Frontiers in Health Services*.
- Valeva, S., Pang, G., Schaefer, A. J., and Clermont, G. (2023). Acuity-based allocation of icu-downstream beds with flexible staffing. *INFORMS journal on computing*.
- Wang, X. and Wang, L. (2008). A new mathematical model for analyzing cqi channel allocation mechanism in ieee 802.16 systems. In *2008 4th IEEE International Conference on Circuits and Systems for Communications*, pages 177–181. IEEE.
- White, D. B., White, D. B., Lo, B., and Lo, B. (2021). Promoting equity with a multi-principle framework to allocate scarce icu resources. *Journal of Medical Ethics*.
- Wolsey, L. A. (2020). *Integer programming*. John Wiley & Sons.