

Revisão Narrativa sobre Modelos de Alocação de Recursos em UTI durante Pandemias: Abordagens Computacionais e Desafios Éticos

Carlos Eduardo V. Gomes¹, João Augusto F. Nunes de Carvalho¹,
Fael Faray de Paiva¹, Francisco Glaubos N. Clímaco¹,

¹ Departamento de Informática – Universidade Federal do Maranhão (UFMA)
Caixa Postal 65080-805 – São Luís – MA – Brazil

{carlos.evg, augusto.joao, fael.faray}@discente.ufma.br
francisco.glaubos@ufma.br

Abstract. *The COVID-19 pandemic highlighted the critical challenge of allocating patients to intensive care units (ICUs). This work reviews computational models proposed to support this decision-making process, encompassing approaches ranging from utility theory-based prioritization to recent Decision-Focused Learning methods. A clear trend emerges toward models that explicitly address uncertainty and emphasize practical applicability; however, significant challenges remain regarding clinical validation, equity, and ethical transparency.*

Resumo. *A pandemia de COVID-19 destacou o desafio de alocar pacientes em UTIs. Este trabalho revisa modelos computacionais propostos para apoiar essa decisão, abrangendo desde abordagens baseadas em teoria da utilidade até métodos recentes de Decision-Focused Learning. Observa-se uma tendência a modelos que tratam explicitamente a incerteza e buscam aplicabilidade prática, embora persistam desafios quanto à validação clínica, equidade e transparência ética.*

1. Introdução

A pandemia de COVID-19 evidenciou limitações críticas na capacidade das Unidades de Terapia Intensiva (UTI), decorrentes da rápida disseminação viral e da elevada gravidade dos quadros clínicos que evoluíam para insuficiência respiratória aguda [Guan et al. 2020, Zhou et al. 2020]. Esse descompasso entre demanda e disponibilidade de leitos, ventiladores e equipes especializadas expôs profissionais de saúde a decisões clínicas e éticas extremamente complexas, especialmente em cenários de escassez extrema. Nesse contexto, diferentes sistemas computacionais passaram a ser empregados como ferramentas de apoio, oferecendo alternativas mais transparentes, consistentes e baseadas em evidências, conforme apontado por Frej et al. (2021).

Diante desse cenário, esta revisão narrativa sintetiza e analisa criticamente as abordagens computacionais propostas entre 2020 e 2025 para apoiar a alocação de recursos escassos em UTI durante pandemias. O objetivo consiste em identificar avanços metodológicos, limitações práticas, tendências emergentes e desafios éticos relacionados

à integração entre modelos preditivos, processos de decisão, métodos de otimização e técnicas modernas de aprendizado de máquina. A análise também busca mapear lacunas relevantes e indicar direções futuras promissoras nesse campo interdisciplinar que conecta medicina intensiva, ciência de dados e pesquisa operacional.

2. Metodologia da Revisão

A revisão foi conduzida entre 2020 e 2025 nas bases PubMed, Google Scholar, Web of Science e Scopus, utilizando combinações de termos relacionados à alocação de recursos em UTI e ao suporte à decisão durante pandemias. Foram incluídos artigos revisados por pares que apresentassem modelos computacionais aplicáveis a cenários de escassez extrema, e excluídos estudos puramente clínicos, contribuições teóricas sem aplicação prática e documentos não publicados. A seleção seguiu análise temática organizada em quatro eixos: fundamentos teóricos, técnicas computacionais, métricas de avaliação e aspectos éticos, permitindo comparação estruturada das abordagens identificadas.

3. Abordagens Computacionais para Alocação de Recursos em UTI

Esta seção revisa as principais abordagens computacionais para otimizar a alocação de leitos de UTI em cenários de alta demanda, especialmente durante pandemias. São analisados modelos baseados em teoria da utilidade, processos de decisão Markovianos e métodos simulatórios, destacando fundamentos, vantagens, limitações e aplicabilidade prática no apoio à decisão clínica.

3.1. Modelos Baseados em Teoria da Utilidade e Seleção de Portfólio

A abordagem apresentada por Frej et al. (2021) constitui um marco na aplicação de conceitos de teoria da decisão e pesquisa operacional ao problema de alocação de leitos de UTI. O modelo é formulado como um problema de seleção de portfólio, em que os pacientes representam "ativos" e o "retorno" corresponde à utilidade esperada em termos de probabilidade de sobrevivência.

O objetivo central da formulação consiste em maximizar a utilidade global do sistema de saúde, definida por:

$$U_{ICU}(X_1, X_2, \dots, X_n) = \sum_{i=1}^n U_i(X_i = 1) X_i + \sum_{i=1}^n U_i(X_i = 0) (1 - X_i) \quad (1)$$

sujeito a:

$$\sum_{i=1}^n X_i = w, \quad X_i \in \{0, 1\}, \quad \forall i = 1, \dots, n \quad (2)$$

em que X_i indica a alocação do paciente i à UTI, w representa o número de leitos disponíveis e U_i expressa a utilidade esperada associada a cada possível decisão de alocação.

Um aspecto relevante da abordagem consiste no tratamento explícito da incerteza presente nas estimativas médicas de probabilidade de sobrevivência. Para lidar com essa imprecisão, utiliza-se uma escala verbal de Likert de 5 pontos (muito baixa, baixa, média, alta e muito alta), mapeada para intervalos probabilísticos de 20%. Em seguida, aplica-se simulação de Monte Carlo para estimar um índice de robustez que expressa a proporção de cenários em que cada paciente integra a alocação considerada ótima.

A viabilidade prática da metodologia é demonstrada por meio de sua implementação em um sistema web de apoio à decisão, que operacionaliza a análise de utilidade de forma acessível para equipes clínicas. O sistema é concebido como ferramenta complementar ao processo decisório, preservando-se a responsabilidade final do julgamento médico.

3.2. Modelos de Processos de Decisão Markovianos para Admissão e Alta

Ouyang et al. (2020) apresentaram uma abordagem baseada em Processos de Decisão Markovianos para otimizar decisões de admissão e alta em UTI durante períodos de alta demanda. Seu trabalho destaca-se por considerar explicitamente as transições dinâmicas no estado de saúde dos pacientes e desenvolver políticas ótimas que balanceiam benefício esperado versus tempo de permanência.

O modelo assume que os pacientes podem estar em um de dois estágios de saúde: crítico (estágio 1) ou altamente crítico (estágio 2), com transições Markovianas entre esses estados. A UTI possui capacidade limitada de b leitos, e quando um novo paciente chega com todos os leitos ocupados, uma decisão deve ser tomada sobre qual paciente transferir para a enfermaria geral.

Os autores caracterizam analiticamente a política ótima sob certas condições, demonstrando que ela possui uma estrutura de limiar que depende da composição dos pacientes na UTI. Especificamente, existe um limiar $x^* \in [1, b + 1]$ tal que:

$$a^*(x_1, x_2) = \begin{cases} (1, 0) & \text{se } x_1 \geq x^* \\ (0, 1) & \text{se } x_1 < x^* \end{cases} \quad (3)$$

onde $a^*(x_1, x_2)$ representa a ação ótima no estado (x_1, x_2) , com x_1 e x_2 sendo o número de pacientes nos estágios 1 e 2, respectivamente.

Uma das principais contribuições deste trabalho é a análise do cenário de leito único, que produz insights fundamentais sobre o trade-off entre benefício esperado e tempo de permanência. Ouyang et al. mostram que quando os pacientes do estágio i têm tanto maior benefício líquido esperado da UTI $(\phi_i^G - \phi_i)$ quanto maior taxa de benefício $((\phi_i^G - \phi_i)/L_i)$, eles devem ser preferidos. No entanto, quando pacientes têm maior benefício, mas menor taxa de benefício, eles só devem ser preferidos se a taxa de chegada for suficientemente baixa.

Com base nesses resultados analíticos, os autores propõem três políticas heurísticas:

- **Ratio Policy (RP):** Prioriza pacientes com base na razão $(\phi_i^G - \phi_i)/L_i$
- **Aggregated Ratio Policy (ARP):** Versão agregada da RP com quatro classes de pacientes
- **Aggregated Optimal Policy (AOP):** Usa a política ótima do modelo matemático

Através de um estudo de simulação abrangente que relaxa várias suposições restritivas do modelo matemático (considerando seis estágios de saúde, readmissões, e demanda não estacionária), os autores demonstram que a RP performa consistentemente melhor que políticas benchmark, particularmente sob alta carga do sistema.

3.3. Modelo de Otimização Multiobjetivo Considerando Taxa de Ocupação

Gomes *et al* (2024) propuseram um modelo matemático para alocação de leitos de UTI que considera os tipos de leitos adulto, pediátrico e neonatal, e incorpora uma taxa de ocupação ideal como parte da função objetivo. Esta abordagem representa um avanço significativo na personalização de modelos de alocação para contextos hospitalares específicos. O modelo foi formulado como um problema de programação linear inteira com três funções objetivo distintas, permitindo analisar diferentes estratégias éticas de alocação, denominadas pelos autores como MSG (Maximizar Sobrevida Geral), LSF (Least Serious First) e MSF (Most Serious First).

Os resultados demonstraram que a estratégia MSG supera as demais em cenários de alta demanda, enquanto LSF apresenta melhor desempenho em demandas baixas a moderadas, destacando a importância de estratégias adaptativas conforme o contexto operacional.

3.4. Modelos Preditivos e de Simulação para Planejamento de Capacidade

Wikman-Jorgensen et al. (2022) apresentaram uma abordagem complementar focada na previsão de demanda por recursos hospitalares. Seu modelo híbrido combina um modelo estocástico de Markov com simulação de eventos discretos para prever dinamicamente admissões hospitalares e ocupação diária de leitos hospitalares e de UTI.

A arquitetura do modelo compreende dois componentes principais:

1. **Gerador de Admissões:** Utiliza um modelo de Markov de duas etapas para prever a probabilidade de hospitalização na população geral com teste microbiológico positivo para COVID-19, estratificada por idade do paciente.
2. **Simulador de Percursos Hospitalares:** Implementa um modelo de simulação de eventos discretos que modela os diferentes percursos dos pacientes através do hospital, permitindo estimar a ocupação de leitos para a semana seguinte.

Os autores reportam excelente desempenho preditivo, com diferença absoluta mediana (MAD) entre a ocupação predita e real de 20 leitos/dia (5% dos leitos hospitalares) e 4 leitos/dia (25% dos leitos de UTI) no Hospital Universitário San Juan de Alicante. A validação externa no Hospital Vega Baja confirmou a robustez da abordagem, com MAD de 18 leitos/dia (5,1%) para leitos hospitalares e 3 leitos/dia (21,4%) para UTI.

Esta abordagem destaca-se pela simplicidade relativa de implementação e pela capacidade de fornecer previsões de curto prazo (uma semana) que são criticamente importantes para o planejamento operacional de hospitais durante surtos epidêmicos.

3.5. Abordagens de Aprendizado de Máquina com Foco na Decisão

O paradigma emergente de *Decision-Focused Learning* (DFL), conforme revisado por Mandi et al. (2024), representa uma evolução significativa na integração entre aprendizado de máquina e otimização. Diferentemente das abordagens tradicionais de "predizer-depois-otimizar", onde o modelo de ML é treinado para minimizar erros de predição

sem considerar o problema de otimização subsequente, o DFL treina o modelo para fazer previsões que levem diretamente a boas decisões.

Matematicamente, enquanto as abordagens tradicionais minimizam uma função de perda de previsão como:

$$\mathcal{L}_{pred}(\hat{\mathbf{c}}, \mathbf{c}) = \frac{1}{N} \|\mathbf{c} - \hat{\mathbf{c}}\|^2 \quad (4)$$

o DFL minimiza uma função de perda de tarefa baseada na qualidade da decisão resultante:

$$\mathcal{L}_{task}(\mathbf{x}^*(\hat{\mathbf{c}}), \mathbf{c}) = f(\mathbf{x}^*(\hat{\mathbf{c}}), \mathbf{c}) - f(\mathbf{x}^*(\mathbf{c}), \mathbf{c}) \quad (5)$$

onde o segundo termo representa o *regret* - a diferença entre o valor objetivo alcançado usando a decisão prescritiva e o valor ótimo de informação completa.

Mandi et al. (2024) categorizam as técnicas de DFL baseadas em gradiente em quatro classes:

1. **Diferenciação analítica de mapeamentos de otimização:** Envolve calcular gradientes analíticos através do problema de otimização.
2. **Suavização analítica de mapeamentos de otimização:** Substitui mapeamentos descontínuos por aproximações suaves.
3. **Suavização por perturbações aleatórias:** Utiliza métodos baseados em amostragem para estimar gradientes.
4. **Diferenciação de funções de perda substitutas:** Substitui a função de perda original por uma versão diferenciável.

Esta abordagem é particularmente relevante para problemas de alocação de UTI, onde pequenas variações nas previsões de parâmetros podem levar a mudanças significativas nas decisões de alocação.

3.6. Modelos Matemáticos Simplificados para Emergências

Manca et al. (2020) propuseram uma abordagem matemática simplificada para prever a demanda por leitos de UTI e taxa de mortalidade durante a pandemia de COVID-19. Seu trabalho destaca-se pelo foco em implementação prática e usabilidade por tomadores de decisão não-especialistas em modelagem.

Os autores exploram diferentes modelos matemáticos para descrever a dinâmica temporal de pacientes em UTI e óbitos:

- **Modelo Exponencial:** $y = a \cdot 10^{bt}$
- **Modelo Logístico:** $y = \frac{a}{1+be^{-ct}}$
- **Modelo Gompertz:** $y = ae^{-be^{-ct}}$
- **Modelo Gaussiano Modificado Exponencialmente:** $y = 10^{at^2+bt+c}$

Uma contribuição prática significativa deste trabalho é a implementação desses modelos em uma planilha Excel acessível, permitindo que gestores hospitalares realizem projeções sem necessidade de ferramentas computacionais complexas. Os autores demonstraram a aplicabilidade de sua abordagem usando dados da Lombardia (Itália), uma das regiões mais afetadas durante a primeira onda da pandemia.

4. Avaliação de Sistemas de Escore Clínico

Minne et al. (2008) conduziram uma revisão sistemática que avaliou o desempenho de modelos baseados no escore SOFA (*Sequential Organ Failure Assessment*) para predição de mortalidade em UTI. A análise de 18 estudos indicou que:

- os modelos baseados no escore SOFA na admissão apresentam desempenho apenas ligeiramente inferior aos modelos **APACHE II** [Knaus et al. 1985] e **APACHE III** [Knaus et al. 1991], além de serem competitivos com o sistema **SAPS II** [Le Gall et al. 1993];
- os modelos que utilizam escores SOFA sequenciais mostram desempenho semelhante ao de outros sistemas de avaliação de falência orgânica;
- a combinação de derivados sequenciais do SOFA com modelos APACHE II/III e SAPS II resulta em melhorias substanciais no desempenho prognóstico em comparação com qualquer modelo isolado.

A revisão também evidenciou ampla heterogeneidade metodológica entre os estudos analisados, destacando a necessidade de padronização nas metodologias de avaliação, incluindo medidas consistentes de discriminação, calibração e acurácia.

Além disso, o SOFA-2, desenvolvido recentemente, tem apresentado forte correlação com mortalidade, configurando-se como ferramenta promissora para predição de desfechos fatais em pacientes críticos [Ranzani et al. 2025].

No contexto da COVID-19, o escore SOFA e outros sistemas de avaliação de gravidade tornaram-se elementos centrais em diversos protocolos de triagem para alocação de recursos escassos, embora seu uso tenha suscitado questões éticas relevantes, discutidas na seção seguinte.

5. Desafios Éticos e de Implementação

A utilização de sistemas computacionais para alocação de leitos de UTI em contextos de escassez extrema envolve desafios éticos relevantes que ultrapassam considerações exclusivamente técnicas. Dilemas relacionados à ocupação total da UTI e à determinação de quais pacientes devem receber tratamento tendem a gerar elevado estresse moral entre profissionais de saúde, evidenciando o impacto humano e emocional dessas decisões [Oerlemans et al. 2015].

Revisões sistemáticas indicam que protocolos de triagem em situações de desastre incorporam múltiplos fatores clínicos e não clínicos; entretanto, ainda não há consenso sobre os princípios éticos mais adequados para orientar a priorização de pacientes [Ghanbari et al. 2019]. A ausência de diretrizes uniformes torna particularmente sensível a adoção de modelos computacionais, que podem, inadvertidamente, reforçar vieses existentes ou aplicar critérios considerados controversos.

A literatura, representada por autores como McGuire e McConnell (2019), aponta que uma abordagem eticamente consistente para a alocação de leitos de UTI deve combinar diferentes princípios morais — justiça, equidade, maximização do benefício e responsabilidade social — de forma a constituir uma base ética coerente. Dessa forma, a mera eficiência dos modelos matemáticos não se mostra suficiente; torna-se necessário assegurar que sua lógica esteja alinhada com valores éticos reconhecidos pela sociedade e pelos profissionais da área.

Nos sistemas computacionais, tais desafios se refletem em requisitos técnicos essenciais, como transparência nos critérios de decisão, mitigação de vieses algorítmicos, manutenção de responsabilidade humana e capacidade de adaptação a contextos específicos. O modelo de Frej et al. (2021) contempla parte desses elementos ao incorporar índices de robustez que quantificam incertezas e ao enfatizar que o sistema funciona apenas como instrumento de apoio, preservando o julgamento final sob responsabilidade clínica.

6. Síntese Integrativa e Discussão

A literatura analisada revela um cenário metodológico diversificado, constituído por abordagens complementares que tratam diferentes dimensões do problema de alocação de recursos em UTI durante pandemias. A Tabela 1 apresenta uma síntese comparativa das principais características das abordagens examinadas.

A literatura recente evidencia tendências claras: integração crescente entre modelos preditivos e prescritivos, reduzindo a separação tradicional entre predição e otimização; incorporação explícita da incerteza por meio de simulações de Monte Carlo, intervalos probabilísticos ou modelagem estocástica; e ênfase na usabilidade prática, com soluções acessíveis como sistemas web [Frej et al. 2021] e planilhas estruturadas [Manca et al. 2020]. Essas características indicam uma convergência em direção a modelos simultaneamente rigorosos e aplicáveis ao cotidiano clínico.

Também se observa uma expansão dos esforços de validação em ambientes reais. Diversos estudos recentes têm aplicado seus modelos diretamente a dados operacionais de hospitais, reforçando a robustez e a aplicabilidade das propostas [Frej et al. 2021, Wikman-Jorgensen et al. 2022]. Trabalhos anteriores já enfatizavam a importância da validação empírica como componente essencial na orientação de decisões críticas em terapia intensiva [Costa et al. 2003, Manca et al. 2020, Minne et al. 2008].

Apesar dos avanços, subsistem desafios significativos. Persistem lacunas na validação clínica, uma vez que poucos estudos realizam avaliações prospectivas ou ensaios clínicos capazes de mensurar impacto sobre desfechos reais de pacientes. Questões relacionadas à generalização também permanecem relevantes, pois modelos desenvolvidos em contextos específicos não são necessariamente transferíveis para realidades com recursos, perfis epidemiológicos ou estruturas organizacionais distintas. Ademais, a integração entre decisões automatizadas e julgamento clínico ainda enfrenta tensões, sobretudo quando envolve dilemas éticos complexos e a necessidade de equilibrar recomendações algorítmicas com autonomia profissional.

7. Conclusão e Direções Futuras

A literatura analisada evidencia o papel central e progressivamente mais sofisticado desempenhado por modelos computacionais no apoio à alocação de recursos em UTI durante situações de pandemia. As abordagens revisadas constituem contribuições relevantes da ciência da computação, da pesquisa operacional e da inteligência artificial para um dos desafios mais críticos enfrentados pelos sistemas de saúde contemporâneos.

Observa-se uma evolução que vai desde modelos simples baseados em escores de gravidade até sistemas integrados capazes de combinar aprendizado de máquina e otimização sob incerteza. Essa trajetória reflete avanços técnicos, bem como maior com-

Tabela 1. Comparação das Abordagens Computacionais para Alocação de Recursos em UTI

Abordagem	Principais Vantagens	Limitações e Desafios	Exemplos / Dados / Métricas
Teoria da Utilidade	Considera explicitamente incerteza; incorpora julgamento médico estruturado; fornece decisões robustas por Monte Carlo; permite análise ética utilitarista.	Depende de estimativas subjetivas de probabilidade; sensível à definição das utilidades; exige coleta padronizada das escalas clínicas.	Frej et al. (2021): dados hospitalares de COVID-19; uso de escala Likert de probabilidade; índice de robustez por simulação; demonstração via sistema web.
Processos de Decisão Markovianos	Modela evolução temporal do estado de saúde; produz políticas ótimas formalmente derivadas; possibilita análise de limiares e trade-offs.	Suposições Markovianas podem ser restritivas; exige parametrização detalhada das transições; complexidade cresce com o número de estados.	Ouyang et al. (2020): simulações com múltiplos estágios clínicos; avaliação de heurísticas (RP, ARP, AOP); desempenho superior da RP sob alta demanda.
Modelos Preditivos + Simulação	Preveem demanda futura e ocupação de leitos; auxiliam no planejamento operacional; fornecem projeções de curto prazo.	Não abordam diretamente decisões individuais de triagem; dependem de dados epidemiológicos de qualidade; sensíveis às variações contextuais.	Wikman-Jorgensen et al. (2022): dados de dois hospitais espanhóis; MAD de 5% para enfermaria e 21–25% para UTI; validação externa robusta.
Decision-Focused Learning (DFL)	Integra aprendizado e otimização; reduz o “erro de decisão”; treina modelos voltados à qualidade prescritiva; representa paradigma emergente.	Exige alta capacidade computacional; dificuldades de diferenciabilidade; aplicação complexa sob restrições clínicas rígidas; sensível à formulação do objetivo.	Mandi et al. (2024): benchmarks variados; comparação com modelos tradicionais; melhora consistente em termos de regret.
Modelos Matemáticos Simplificados	Implementação rápida; fácil de ajustar; adequado para gestores não especialistas; utilizável em planilhas; útil para projeções iniciais.	Precisão limitada em cenários complexos; não captura variabilidade clínica detalhada; não modela decisões individuais.	Manca et al. (2020): dados da Lombardia; ajuste de curvas epidêmicas; modelos Gompertz, logístico e exponencial; previsão do pico de UTI.

preensão das complexidades clínicas, operacionais e éticas envolvidas no processo decisório. À luz do estado atual da pesquisa, destacam-se diversos eixos metodológicos considerados promissores para trabalhos futuros:

1. **Modelos Híbridos:** Integrações entre diferentes classes de métodos tendem a mitigar limitações individuais e ampliar a robustez das soluções.

2. **Abordagens Multidisciplinares:** Colaborações envolvendo cientistas, profissionais de saúde e especialistas em ética favorecem o desenvolvimento de sistemas tecnicamente sólidos, clinicamente aplicáveis e eticamente alinhados.
3. **Processos de Decisão Markovianos:** Estudos indicam que, apesar da complexidade estrutural das políticas ótimas, heurísticas baseadas na razão entre benefício e tempo de permanência oferecem desempenho próximo ao ótimo em cenários realistas [Ouyang et al. 2020].
4. **Estudos de Implementação:** Investigações voltadas aos desafios práticos de implantação em ambientes clínicos reais permanecem necessárias.
5. **Avaliação de Impacto:** Análises longitudinais podem esclarecer os efeitos dos sistemas de apoio à decisão sobre desfechos clínicos, experiência profissional e equidade.
6. **Adaptabilidade Contextual:** O desenvolvimento de modelos flexíveis e sensíveis às particularidades de diferentes sistemas de saúde constitui eixo estratégico de avanço.
7. **Soluções Explicáveis e Transparentes:** Ferramentas baseadas em inteligência artificial explicável têm potencial para ampliar confiança, transparência e aceitação entre equipes clínicas.

Em síntese, a pandemia de COVID-19 expôs fragilidades estruturais, mas também estimulou avanços significativos em sistemas computacionais de apoio à decisão. As próximas etapas exigem esforços voltados a garantir que essas inovações evoluam para práticas equitativas, transparentes e eticamente sustentáveis, capazes de oferecer suporte robusto diante de futuras emergências sanitárias.

Referências

- Costa, A., Ridley, S., Shahani, A., Harper, P., De Senna, V., and Nielsen, M. (2003). Mathematical modelling and simulation for planning critical care capacity. *Anaesthesia*, 58(4):320–327.
- Frej, E. A., Roselli, L. R. P., Ferreira, R. J. P., Alberti, A. R., and de Almeida, A. T. (2021). Decision model for allocation of intensive care unit beds for suspected covid-19 patients under scarce resources. *Computational and Mathematical Methods in Medicine*, 2021:8853787.
- Ghanbari, V., Ardalan, A., Zareiyan, A., Nejati, A., Hanfling, D., and Bagheri, A. (2019). Ethical prioritization of patients during disaster triage: a systematic review. *International Emergency Nursing*, 43:126–132.
- Gomes, C., Clímaco, G., Carvalho, J., and Quintanilha, D. (2024). Modelagem matemática para a alocação de leitos de uti com diferentes tipos de leitos e taxa de ocupação. In *Anais do XXIV Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 226–237, Porto Alegre, RS, Brasil. SBC.
- Guan, W.-j., Ni, Z.-y., Hu, Y., Liang, W.-h., Ou, C.-q., He, J.-x., et al. (2020). Clinical characteristics of coronavirus disease 2019 in china. *New England Journal of Medicine*, 382(18):1708–1720.
- Knaus, W. A., Draper, E. A., Wagner, D. P., and Zimmerman, J. E. (1985). Apache ii: A severity of disease classification system. *Critical Care Medicine*, 13(10):818–829.

- Knaus, W. A., Wagner, D. P., Draper, E. A., Zimmerman, J. E., Bergner, M., Bastos, P. G., et al. (1991). The apache iii prognostic system. *Chest*, 100(6):1619–1636.
- Le Gall, J.-R., Lemeshow, S., and Saulnier, F. (1993). A new simplified acute physiology score (saps ii). *JAMA*, 270(24):2957–2963.
- Manca, D., Caldirola, D., and Storti, E. (2020). A simplified math approach to predict icu beds and mortality rate for hospital emergency planning under covid-19 pandemic. *Computers and Chemical Engineering*, 140:106945.
- Mandi, J., Kotary, J., Berden, S., Mulamba, M., Bucarey, V., Guns, T., and Fioretto, F. (2024). Decision-focused learning: Foundations, state of the art, benchmark and future opportunities. *Journal of Artificial Intelligence Research*, 81:1623–1701.
- McGuire, A. and McConnell, P. C. (2019). Resource allocation in icu. *Current Opinion in Anaesthesiology*, 32(2):190–194.
- Minne, L., Abu-Hanna, A., and de Jonge, E. (2008). Evaluation of sofa-based models for predicting mortality in the icu: A systematic review. *Critical Care*, 12(6):R161.
- Oerlemans, A. J. M., van Sluisveld, N., van Leeuwen, E. S. J., Wollersheim, H., Dekkers, W. J. M., and Zegers, M. (2015). Ethical problems in intensive care unit admission and discharge decisions: a qualitative study. *BMC Medical Ethics*, 16(1):1–11.
- Ouyang, H., Argon, N. T., and Ziya, S. (2020). Allocation of intensive care unit beds in periods of high demand. *Operations Research*, 68(2):591–608.
- Ranzani, O. T., Singer, M., Salluh, J. I. F., Shankar-Hari, M., Pilcher, D., et al. (2025). Development and validation of the sofa-2 score. *JAMA*.
- Wikman-Jorgensen, P. E., Ruiz, A., Galva, V. G., Lienas-García, J., Seguí-Ripoll, J. M., Serrano, J. M. S., et al. (2022). Hospitalization forecast to inform covid-19 pandemic planning and resource allocation using mathematical models. *medRxiv*.
- Zhou, F., Yu, T., Du, R., Fan, G., Liu, Y., Liu, Z., et al. (2020). Clinical course and risk factors for mortality of adult inpatients with covid-19. *The Lancet*, 395(10229):1054–1062.