

Desenvolvimento de algoritmo para regulação inteligente de leitos críticos no estado do Amazonas: otimizando a ocupação e reduzindo o tempo de espera de pacientes.

Álvaro Queiroz Magalhães
Universidade Federal do Amazonas
alvaro.queiroz@ufam.edu.br

Irina Jerez
Hospital Adventista Manaus
irina.jerez@ham.org.br

Aline Brasil Aranha
Hospital Adventista Manaus
alineba1211@gmail.com

Adda Sabrinna da Silva Moura
Hospital Adventista Manaus
adda.moura@gmail.com

Cleinaldo de Almeida Costa
Universidade Federal do Amazonas
cleinaldocosta@gmail.com

1. INTRODUÇÃO

A alocação de leitos críticos no Amazonas é dificultada por longas distâncias, concentração de UTIs em Manaus e fluxos assistenciais complexos. Em cenários de alta demanda, atrasos de minutos a horas na compatibilização entre perfil clínico e capacidade instalada de leitos impactam desfechos e eficiência do sistema. A otimização do processo regulatório se faz não só necessária, como urgente.

2. OBJETIVO GERAL

Desenvolver e validar um algoritmo de apoio à regulação de leitos críticos no Estado do Amazonas para otimizar a ocupação hospitalar, reduzir o tempo de espera e prover suporte técnico às equipes reguladoras.

3. METODOLOGIA

Estudo observacional, retrospectivo e quantitativo com dados secundários anonimizados da Central Estadual de Regulação (01/01/2023 a 01/01/2025). Variáveis: idade, sexo, município de origem, diagnóstico principal, necessidade de suporte (VM/VA), tempo de espera, hospital de destino, especialidade e desfecho clínico. O algoritmo será desenvolvido com aprendizado de máquina supervisionado (Random Forest), comparado a modelos basais, com particionamento 70/30, validação cruzada k-fold, ajuste de hiperparâmetros e métricas (acurácia, sensibilidade, especificidade, VPP, F1 e AUC-ROC), além de interpretabilidade (importância de variáveis/SHAP).

A validação técnica ocorrerá por simulações retrospectivas (contrafactuais) e, quando viável, validação temporal externa, comparando tempo médio de espera, compatibilidade clínico-operacional e potencial redução de transferências secundárias. Testes estatísticos (t/ANOVA; qui-quadrado; alternativas não paramétricas quando necessário) serão conduzidos em Python e SPSS.

4. RESULTADOS E DISCUSSÃO

Espera-se disponibilizar um protótipo executável capaz de sugerir de forma automatizada o leito/unidade mais compatível, com bom desempenho preditivo (AUC e calibração), transparência mínima (explicações locais) e auditabilidade. Projetam-se reduções do tempo médio de espera e da variabilidade decisória entre reguladores, com aumento da compatibilidade paciente–unidade e uso mais eficiente dos leitos. O sistema atuará como suporte à decisão, preservando a autonomia técnica humana e favorecendo transparência e rastreabilidade.

REFERÊNCIAS

BAGUST, A.; PLACE, M.; POSNETT, J. W. Dynamics of bed use in accommodating emergency admissions: stochastic simulation model. *BMJ*, v. 319, n. 7203, p. 155–158, 1999.

BARRETO, T. O. et al. Artificial intelligence applied to bed regulation in Rio Grande do Norte: data analysis and machine learning application. *PLOS ONE*, v. 19, n. 12, e0315379, 2024.

BORGES, F. et al. Atuação de enfermeiros na gestão de leitos de um hospital de ensino. *Revista Brasileira de Enfermagem*, v. 73, n. 4, e20190349, 2020.

COLLINS, G. S. et al. Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis (TRIPOD): The TRIPOD Statement. *BMJ*, v. 350, g7594, 2015.

COLLINS, G. S. et al. TRIPOD+AI: updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ*, v. 385, e078378, 2024.

JI, Y. et al. The Application of Artificial Intelligence in Health Care Resource Distribution: A Scoping Review. *JMIR AI*, v. 1, n. 1, e38397, 2023.

KIM, J.-N.; OH, I.-H. Optimizing Hospital Bed Capacity and Resource Allocation Using Inflow and Outflow Indices for Effective Healthcare Management. *Inquiry*, v. 61, 00469580241304244, 2024.

LIM, L. et al. Multicenter validation of a machine-learning model to predict ICU readmission within 48 hours. *eClinicalMedicine*, 2025.

LIMA, M. A. N. et al. Bed demand and occupancy within the Brazilian National Health System for major cancers. *Epidemiologia e Serviços de Saúde*, v. 33, e20231172, 2024.

MYALL, A. C. et al. Prediction of hospital-onset COVID-19 infections using real-time machine-learning on dynamic patient-contact networks. *The Lancet Digital Health*, v. 4, n. 10, 2022.

PAULI, J. Doação organizacional em face ao mercado de órgãos: o caso do Sistema Nacional de Transplantes. *Nova Economia*, v. 29, n. 1, p. 353–378, 2019.

PEREIRA, M. F. et al. RegulaRN: plataforma preditiva de demanda de leitos em UTI. *Epidemiologia e Serviços de Saúde*, v. 32, n. 1, 2023.



IV WORKSHOP DO PROGRAMA DE PÓS-GRADUAÇÃO EM CIRURGIA E I SIMPÓSIO DE CIRURGIA



ROTH, A. E.; PERANSON, E. The redesign of the matching market for American physicians: some engineering aspects of economic design. American Economic Review, v. 89, n. 4, p. 748–780, 1999.

SINGH, A. et al. Forecasting Surgical Bed Utilization: Architectural Design of a Machine Learning Pipeline Incorporating Predicted Length of Stay and Surgical Volume. Journal of Medical Systems, v. 49, n. 1, p. 67, 2025.

UEDA, D. et al. Fairness of artificial intelligence in healthcare: review and recommendations. Japanese Journal of Radiology, v. 42, n. 1, p. 3–15, 2024.

UNIVERSIDADE FEDERAL DE MINAS GERAIS. Alocação de leitos de internação com o uso da abordagem de Otimização via Simulação. Dissertação (Mestrado em Engenharia de Produção) – UFMG, 2019.

VON ELM, E. et al. The STROBE Statement: guidelines for reporting observational studies. PLoS Medicine, v. 4, n. 10, e296, 2007.

WANG, X.; YANG, C. C. Balancing Fairness and Performance in Healthcare AI: A Gradient Reconciliation Approach. arXiv preprint arXiv:2504.14388, 2025.

YÜKSEL ELGIN, C.; ELGIN, C. Ethical implications of AI-driven clinical decision support systems on healthcare resource allocation: a qualitative study. BMC Medical Ethics, v. 25, 148, 2024.