

## **Aplicação de inteligência artificial na previsão de criticidade de estoques hemoterápicos: Um estudo com dados operacionais reais**

**Application of artificial intelligence in predicting the criticality of blood drug stocks: A study with real operational data**

**Aplicación de la inteligencia artificial en la predicción de la criticidad de las existencias de medicamentos sanguíneos: Un estudio con datos operativos reales**

Recebido: 10/04/2026 | Aceito: 20/04/2026 | Publicado: 21/04/2026

### **Weber de Santana Teles**

ORCID: <https://orcid.org/0000-0003-1770-8278>  
Centro Universitário Pio Décimo, Brasil  
E-mail: [weber.telles@hotmail.com](mailto:weber.telles@hotmail.com)

### **Max Cruz da Silva**

ORCID: <https://orcid.org/0000-0002-6944-5986>  
Faculdade Pio Décimo de Canindé, Brasil  
E-mail: [maxlfi@hotmail.com](mailto:maxlfi@hotmail.com)

### **Elaine Cristina Posener Araújo**

ORCID: <https://orcid.org/0009-0008-0932-5553>  
Centro de Hemoterapia de Sergipe, Brasil  
E-mail: [elaineposener@hotmail.com](mailto:elaineposener@hotmail.com)

### **Ádamo Newton Marinho Andrade**

ORCID: <https://orcid.org/0009-0006-4699-9413>  
Centro de Hemoterapia de Sergipe, Brasil  
E-mail: [adamonewtonmarinhoandrade@gmail.com](mailto:adamonewtonmarinhoandrade@gmail.com)

### **Lana Elise de Santana Santos**

ORCID: <https://orcid.org/0009-0004-0376-6877>  
Universidade Tiradentes, Brasil  
E-mail: [lanaelise230@gmail.com](mailto:lanaelise230@gmail.com)

### **Cauã Marx Nascimento de Carvalho**

ORCID: <https://orcid.org/0009-0003-4546-4976>  
Universidade Tiradentes, Brasil  
E-mail: [cauamarxnc@gmail.com](mailto:cauamarxnc@gmail.com)

### **Raphael Davisson Lopes Santos**

ORCID: <https://orcid.org/0009-0005-2572-6400>  
Centro de Hemoterapia de Sergipe, Brasil  
E-mail: [rdsaju@gmail.com](mailto:rdsaju@gmail.com)

### **Sales de Oliveira Farias**

ORCID: <https://orcid.org/0009-0001-3196-7068>  
Universidade Tiradentes, Brasil  
E-mail: [oliveiradesales@gmail.com](mailto:oliveiradesales@gmail.com)

### **Abraão Soares Silva**

ORCID: <https://orcid.org/0009-0003-2126-0813>  
Universidade Tiradentes, Brasil  
E-mail: [abraao0294@gmail.com](mailto:abraao0294@gmail.com)

### **Resumo**

A disponibilidade adequada de hemocomponentes constitui um desafio crítico para os sistemas de saúde, especialmente diante da variabilidade da demanda assistencial e das limitações operacionais dos serviços hemoterápicos. O objetivo deste estudo foi aplicar técnicas de inteligência artificial na previsão da criticidade de estoques hemoterápicos, a partir da análise de dados operacionais de um hemocentro público brasileiro, no período de janeiro a março de 2026. Trata-se de um estudo observacional, retrospectivo e analítico, com abordagem quantitativa, utilizando estatística descritiva e modelos de aprendizado de máquina supervisionado, incluindo Random Forest e XGBoost. Os resultados evidenciaram padrões estruturados de criticidade, com maior estabilidade nos concentrados de hemácias e maior variabilidade nos concentrados de plaquetas, que apresentaram recorrência mais frequente de estados críticos e de emergência. Os modelos demonstraram desempenho satisfatório na predição dos níveis de criticidade, com elevada concordância entre valores observados e previstos. Conclui-se que a aplicação de inteligência artificial representa uma ferramenta promissora para antecipação de cenários críticos, otimização da gestão dos

estoques hemoterápicos e apoio à tomada de decisão, contribuindo para a segurança transfusional e eficiência dos serviços de saúde.

**Palavras-chave:** Inteligência Artificial; Hemoterapia; Estoque; Modelos Preditivos de Aprendizagem; Segurança Transfusional.

### Abstract

The adequate availability of blood components is a critical challenge for healthcare systems, especially given the variability in healthcare demand and the operational limitations of blood transfusion services. The objective of this study was to apply artificial intelligence techniques to predict the criticality of blood transfusion stocks, based on the analysis of operational data from a Brazilian public blood center, from January to March 2026. This is an observational, retrospective, and analytical study with a quantitative approach, using descriptive statistics and supervised machine learning models, including Random Forest and XGBoost. The results showed structured patterns of criticality, with greater stability in red blood cell concentrates and greater variability in platelet concentrates, which presented a more frequent recurrence of critical and emergency states. The models demonstrated satisfactory performance in predicting criticality levels, with high agreement between observed and predicted values. It is concluded that the application of artificial intelligence represents a promising tool for anticipating critical scenarios, optimizing the management of blood stocks, and supporting decision-making, contributing to transfusion safety and the efficiency of health services.

**Keywords:** Artificial Intelligence; Blood Transfusion; Stock; Predictive Learning Models; Transfusion Safety.

### Resumen

La disponibilidad adecuada de componentes sanguíneos es un desafío crítico para los sistemas de salud, especialmente dada la variabilidad en la demanda de atención médica y las limitaciones operativas de los servicios de transfusión sanguínea. El objetivo de este estudio fue aplicar técnicas de inteligencia artificial para predecir la criticidad de las reservas de sangre para transfusión, basándose en el análisis de datos operativos de un centro público de sangre brasileño, de enero a marzo de 2026. Este es un estudio observacional, retrospectivo y analítico con un enfoque cuantitativo, utilizando estadística descriptiva y modelos de aprendizaje automático supervisado, incluyendo Random Forest y XGBoost. Los resultados mostraron patrones estructurados de criticidad, con mayor estabilidad en los concentrados de glóbulos rojos y mayor variabilidad en los concentrados de plaquetas, que presentaron una recurrencia más frecuente de estados críticos y de emergencia. Los modelos demostraron un desempeño satisfactorio en la predicción de los niveles de criticidad, con una alta concordancia entre los valores observados y predichos. Se concluye que la aplicación de la inteligencia artificial representa una herramienta prometedora para anticipar escenarios críticos, optimizar la gestión de las reservas de sangre y apoyar la toma de decisiones, contribuyendo a la seguridad transfusional y la eficiencia de los servicios de salud.

**Palabras clave:** Inteligencia Artificial; Transfusión Sanguínea; Acciones; Modelos de Aprendizaje Predictivo; Seguridad Transfusional.

## 1. Introdução

A disponibilidade adequada de hemocomponentes configura-se como um dos pilares fundamentais para a segurança e a resolutividade dos sistemas de saúde, sendo indispensável para a realização de transfusões, procedimentos cirúrgicos e o manejo de condições clínicas agudas e crônicas. Contudo, a manutenção de estoques regulares de sangue ainda representa um desafio global, especialmente em países de média renda, onde fatores estruturais, logísticos e comportamentais impactam diretamente a sustentabilidade dos serviços hemoterápicos (World Health Organization, 2019).

No contexto brasileiro, a rede hemoterápica está integrada ao Sistema Único de Saúde (SUS), sendo organizada de forma descentralizada e orientada por políticas públicas voltadas à segurança transfusional e à autossuficiência na produção de hemocomponentes. Apesar dos avanços institucionais, ainda se observam oscilações na disponibilidade de sangue, com episódios recorrentes de criticidade em diferentes regiões do país, refletindo desafios estruturais e operacionais inerentes à gestão desses serviços (Brasil, 2011).

Adicionalmente, a gestão dos estoques hemoterápicos apresenta limitações estruturais relevantes, destacando-se a inexistência de um sistema informatizado nacional unificado capaz de consolidar, em tempo real, os dados de disponibilidade de hemocomponentes. Dessa forma, o monitoramento ocorre de maneira descentralizada, sob responsabilidade dos hemocentros coordenadores estaduais e regionais, o que pode comprometer a agilidade na tomada de decisão (Brasil, 2011).

Corroborando essas fragilidades, o Guia Nacional de Gerenciamento de Estoque de Sangue em Situações de Emergência evidencia a dependência de fluxos operacionais baseados em formulários, comunicação descentralizada e ausência de integração sistêmica entre os serviços. Em situações críticas, essas limitações podem comprometer a distribuição adequada de hemocomponentes e aumentar o risco de desabastecimento (Brasil, 2011).

Além disso, o guia recomenda o monitoramento contínuo da relação entre oferta e demanda de hemocomponentes por tipagem sanguínea, utilizando indicadores operacionais como instrumento de apoio à gestão. Essa abordagem reforça a necessidade de ferramentas analíticas mais robustas, capazes de antecipar desequilíbrios operacionais e reduzir riscos assistenciais (Brasil, 2011).

Nesse contexto, a análise de informativos institucionais e dados operacionais recentes permite evidenciar a heterogeneidade da criticidade dos estoques hemoterápicos entre as diferentes regiões brasileiras, revelando padrões distintos de risco de desabastecimento. A distribuição regional dessas condições é apresentada na Figura 1, possibilitando uma visualização integrada do cenário nacional, em consonância com as diretrizes de monitoramento contínuo preconizadas para a gestão de hemocomponentes (Brasil, 2011).

**Figura 1** – Situação da criticidade dos estoques hemoterápicos em regiões brasileiras segundo boletins oficiais publicados em 2025.



Fonte: Elaboração própria a partir de dados operacionais e diretrizes nacionais de gestão hemoterápica (Brasil, 2011).

Dados recentes indicam que a taxa de doação de sangue no Brasil permanece abaixo do nível recomendado pela Organização Mundial da Saúde, que sugere que entre 3% e 5% da população seja doadora regular. No país, esse índice situa-se entre 1,6% e 2%, evidenciando a necessidade de estratégias mais eficazes de captação e fidelização de doadores (World Health Organization, 2019).

A dinâmica dos estoques hemoterápicos é influenciada por múltiplos fatores, incluindo sazonalidade, eventos epidemiológicos, períodos festivos e variações na demanda hospitalar. A ausência de planejamento adequado frente a essas variáveis pode resultar em situações de criticidade, comprometendo a capacidade de resposta dos serviços de saúde e ampliando o risco de desabastecimento (Hyndman & Athanopoulos, 2018; World Health Organization, 2019).

Diante desse cenário, a utilização de dados operacionais históricos tem se consolidado como estratégia relevante para compreender padrões de consumo e reposição de hemocomponentes. A análise de séries temporais permite identificar

tendências e sazonalidades, contribuindo para o planejamento estratégico e para a mitigação de riscos operacionais (Hyndman & Athanasopoulos, 2018).

Paralelamente, o avanço das técnicas de ciência de dados e inteligência artificial tem impulsionado o desenvolvimento de modelos preditivos aplicados à saúde. Tais modelos apresentam potencial teórico elevado para antecipar cenários de escassez, otimizar a alocação de recursos e apoiar a tomada de decisão em sistemas complexos e dinâmicos, especialmente em contextos assistenciais caracterizados por alta variabilidade (Rajkomar et al., 2019; Sibinga, 2020).

No campo da hemoterapia, a integração entre dados operacionais e ferramentas de modelagem computacional ainda se encontra em estágio incipiente, especialmente em serviços públicos. Entretanto, evidências indicam que o uso de tecnologias digitais e abordagens orientadas por dados pode contribuir para a melhoria da gestão dos estoques e para o fortalecimento de estratégias de captação e fidelização de doadores (Chandler et al., 2020; Sibinga, 2020).

Diante desse contexto, torna-se essencial o desenvolvimento de abordagens analíticas capazes de compreender e antecipar a criticidade dos estoques hemoterápicos. A aplicação de modelos preditivos baseados em inteligência artificial, utilizando dados operacionais reais, configura-se como estratégia promissora para fortalecer a gestão dos hemocentros e ampliar a segurança transfusional (Rajkomar et al., 2019; Sibinga, 2020).

O objetivo deste estudo foi aplicar técnicas de inteligência artificial na previsão da criticidade de estoques hemoterápicos, a partir da análise de dados operacionais de um hemocentro público brasileiro, no período de janeiro a março de 2026.

## 2. Metodologia

Trata-se de um estudo observacional, retrospectivo, documental e analítico, com abordagem quantitativa (Risemberg et al., 2026; Pereira et al., 2018), conduzido a partir de informativos institucionais de monitoramento do estoque estratégico de concentrados de hemácias (CH) e concentrados de plaquetas (CP) de um hemocentro público brasileiro. Esses informativos apresentam a situação de criticidade dos estoques por hemocomponente e tipagem ABO/Rh, fundamentados em série histórica institucional utilizada para estimar a demanda diária, o estoque de segurança e a autonomia assistencial expressa em dias de cobertura (Brasil, 2011).

A fundamentação teórica do estudo está alinhada às diretrizes internacionais de gerenciamento de estoques de sangue em contextos críticos, que preconizam o monitoramento contínuo da relação entre oferta e demanda como estratégia essencial para garantir a segurança transfusional e a resposta oportuna a eventos adversos. A literatura destaca que a gestão orientada por evidências constitui elemento central para a mitigação de riscos operacionais em hemoterapia (World Health Organization, 2019; Brasil, 2011).

A unidade de análise foi composta por registros operacionais estruturados de criticidade, organizados por data, hemocomponente e grupo sanguíneo. A variável resposta do estudo foi o nível de criticidade do estoque, tratado como desfecho categórico ordinal com quatro classes: ideal, alerta, crítico e emergência. A classificação foi estabelecida a partir do número de dias de cobertura do estoque, calculado com base na relação entre estoque disponível e demanda diária, segundo critérios institucionais: ideal ( $\geq 5$  dias), alerta (3 a 4,9 dias), crítico (1 a 2,9 dias) e emergência ( $\leq 0,9$  dia) (Brasil, 2011).

Para viabilizar a análise quantitativa e a modelagem computacional, os dados textuais foram extraídos dos informativos institucionais e convertidos em base estruturada no formato tabular (DataFrame), utilizando a biblioteca pandas no ambiente Python. Essa abordagem assegura organização, rastreabilidade e reprodutibilidade analítica, sendo amplamente utilizada em ciência de dados aplicada à saúde (McKinney, 2010).

Os dados foram organizados em formato longo (long format), no qual cada linha representa uma combinação única entre data, hemocomponente e grupo sanguíneo. As variáveis incluídas foram: data, hemocomponente, tipo sanguíneo,

criticidade categórica e classe numérica. A criticidade foi codificada ordinalmente (ideal = 0, alerta = 1, crítico = 2 e emergência = 3), permitindo sua utilização em modelos estatísticos e computacionais (Kuhn & Johnson, 2013).

Na análise descritiva, foram calculadas frequências absolutas e relativas dos níveis de criticidade, bem como sua distribuição por hemocomponente e grupo sanguíneo. Adicionalmente, foi estimado um escore médio de severidade, obtido pela média da variável ordinal ao longo do período, permitindo avaliar a tendência de instabilidade dos estoques. Essa abordagem é recomendada para análise de dados categóricos ordenados em estudos aplicados à saúde (Agresti, 2010).

A análise temporal foi conduzida por meio da ordenação cronológica dos registros, permitindo avaliar padrões de persistência, transição entre níveis de criticidade e ciclos de instabilidade ao longo do tempo. Essa abordagem contribui para a compreensão da dinâmica operacional dos estoques hemoterápicos e para a identificação de padrões recorrentes de risco (Hyndman & Athanasopoulos, 2018).

Como estratégia complementar de análise visual, foi utilizado um mapa de calor categórico (heatmap), construído a partir da organização matricial dos dados considerando as dimensões tempo (eixo horizontal) e grupo sanguíneo (eixo vertical). Os níveis de criticidade foram representados por escala ordinal em tons de intensidade, permitindo a identificação de padrões temporais, concentração de eventos críticos e períodos de instabilidade operacional (Kuhn & Johnson, 2013).

Para análise inferencial, foram empregados testes estatísticos apropriados à natureza dos dados. O teste do qui-quadrado de Pearson foi utilizado para avaliar associações entre variáveis categóricas, sendo substituído pelo teste exato de Fisher quando necessário. Para comparação entre distribuições de variáveis ordinais, foram utilizados os testes não paramétricos de Mann–Whitney e Kruskal–Wallis, conforme recomendação para dados não paramétricos (Field, 2013).

O nível de significância adotado foi de 5% ( $p < 0,05$ ), sendo os resultados interpretados de forma integrada com medidas de efeito e relevância prática, evitando dependência exclusiva de significância estatística, em consonância com recomendações contemporâneas em análise científica (Wasserstein & Lazar, 2016).

A abordagem de aprendizado de máquina supervisionado foi adotada como eixo central da análise, com o objetivo de prever os níveis de criticidade dos estoques hemoterápicos a partir de variáveis operacionais estruturadas. Considerando a natureza categórica ordinal da variável desfecho, foram utilizados modelos de classificação multiclasse, permitindo a identificação automatizada dos estados de criticidade (James et al., 2021).

Foram implementados dois algoritmos baseados em árvores: Random Forest e XGBoost. O modelo Random Forest foi selecionado por sua robustez, capacidade de modelar relações não lineares e resistência ao sobreajuste (Breiman, 2001). O modelo XGBoost foi utilizado como abordagem complementar devido ao seu elevado desempenho preditivo e eficiência computacional em problemas de classificação estruturada (Chen & Guestrin, 2016).

A divisão dos dados foi realizada por meio da técnica hold-out com estratificação das classes, garantindo representatividade dos diferentes níveis de criticidade nos conjuntos de treinamento e teste e permitindo adequada avaliação da capacidade de generalização dos modelos (Pedregosa et al., 2011). O desempenho dos modelos foi avaliado por meio de métricas clássicas de classificação, incluindo acurácia, precisão, revocação e F1-score, além da matriz de confusão, permitindo análise detalhada da performance em problemas multiclasse e avaliação dos padrões de erro (Sokolova & Lapalme, 2009).

A interpretação dos erros considerou a natureza ordinal da variável desfecho, sendo erros entre classes adjacentes considerados menos severos do que erros extremos. Adicionalmente, foi realizada análise de importância das variáveis nos modelos baseados em árvores, permitindo identificar os principais preditores da criticidade e subsidiar estratégias de intervenção na gestão dos estoques hemoterápicos (Breiman, 2001).

Adicionalmente, foi realizada a comparação entre os níveis de criticidade observados e aqueles previstos pelos modelos de aprendizado de máquina ao longo da dimensão temporal, permitindo avaliar a capacidade dos algoritmos em

reproduzir a dinâmica operacional dos estoques hemoterápicos. Essa abordagem possibilitou a análise da concordância entre padrões reais e estimados, constituindo a base para a representação gráfica apresentada na Figura 4.

Todas as análises foram conduzidas em ambiente computacional Python, assegurando reprodutibilidade, transparência metodológica e possibilidade de atualização contínua do modelo com novos dados operacionais (James et al., 2021).

### 3. Resultados

A análise dos registros estruturados evidenciou um padrão heterogêneo de criticidade dos estoques hemoterápicos ao longo do período avaliado, com variações relevantes entre hemocomponentes e grupos sanguíneos. Observou-se predominância de estados classificados como ideal e alerta nos concentrados de hemácias (CH), enquanto os concentrados de plaquetas (CP) apresentaram maior frequência relativa de estados classificados como crítico e emergência, indicando maior instabilidade operacional desse hemocomponente, padrão compatível com descrições da literatura hemoterápica (World Health Organization, 2019).

A análise descritiva das frequências demonstrou que os eventos de criticidade grave (crítico + emergência) ocorreram de forma mais recorrente nos estoques de CP, sugerindo maior susceptibilidade a desabastecimento em comparação aos estoques de CH. Esse comportamento pode ser explicado pela menor vida útil das plaquetas e maior complexidade logística associada ao seu armazenamento e distribuição, fatores amplamente descritos na literatura hemoterápica (World Health Organization, 2019).

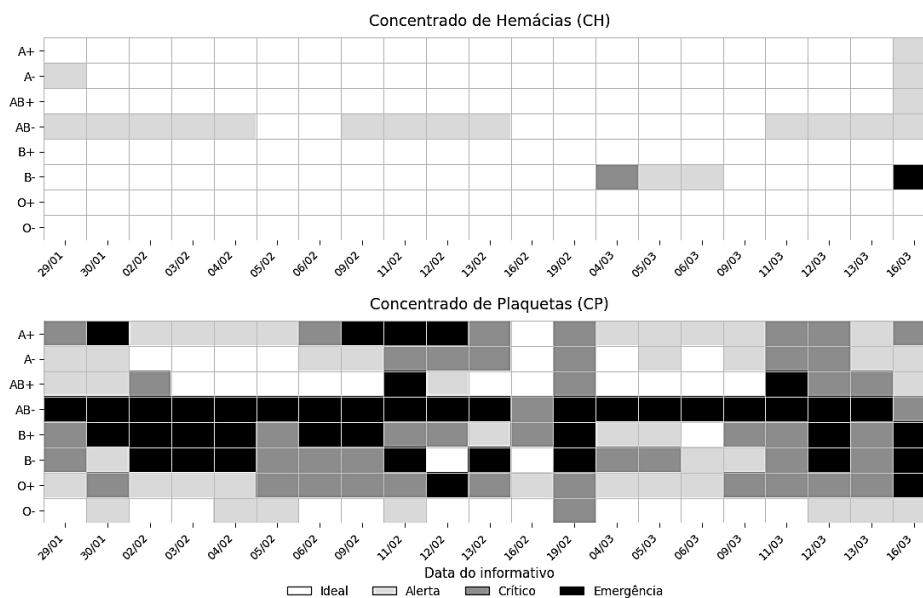
No que se refere à distribuição por grupo sanguíneo, verificou-se que determinadas tipagens apresentaram maior concentração de estados críticos ao longo do período analisado. Grupos como B-, AB- e O+ apresentaram maior recorrência em estados de criticidade elevada, refletindo um padrão de vulnerabilidade que pode estar associado à menor frequência populacional, maior demanda clínica ou desequilíbrios na captação de doadores (Brasil, 2011).

A análise do escore médio de severidade, calculado a partir da codificação ordinal da criticidade (0 a 3), evidenciou maior valor médio para os concentrados de plaquetas em comparação aos concentrados de hemácias. Esse achado reforça quantitativamente a maior instabilidade dos estoques de CP e valida a utilização do escore ordinal como medida sintética de gravidade operacional (Kuhn & Johnson, 2013).

A análise temporal dos registros revelou a presença de transições frequentes entre níveis de criticidade, caracterizadas por períodos de agravamento seguidos de recuperação parcial dos estoques. Esse comportamento dinâmico sugere a existência de ciclos operacionais de instabilidade, possivelmente relacionados a variações na captação de doadores, sazonalidade e flutuações na demanda hospitalar (Hyndman & Athanasopoulos, 2018).

Esses padrões tornam-se mais evidentes quando analisados de forma integrada ao longo do tempo, conforme ilustrado na Figura 2, que apresenta a distribuição temporal da criticidade dos estoques por grupo sanguíneo e hemocomponente, permitindo a visualização dos ciclos de instabilidade e recuperação ao longo do período analisado (Hyndman & Athanasopoulos, 2018).

**Figura 2** – Distribuição temporal da criticidade dos estoques hemoterápicos por grupo sanguíneo e hemocomponente.



Fonte: Elaboração própria a partir de dados operacionais do hemocentro.

A Figura 2 apresenta um mapa de calor da criticidade dos estoques hemoterápicos ao longo do tempo, construído a partir de dados operacionais estruturados. Os dados foram organizados em matriz considerando as dimensões tempo (eixo horizontal) e grupo sanguíneo (eixo vertical), com codificação ordinal dos níveis de criticidade: ideal ( $\geq 5$  dias), alerta (3–4,9 dias), crítico (1–2,9 dias) e emergência ( $\leq 0,9$  dia). A figura está dividida em dois painéis, sendo o superior referente aos concentrados de hemácias (CH) e o inferior aos concentrados de plaquetas (CP), permitindo comparação direta entre os hemocomponentes. Observa-se, de forma geral, maior estabilidade nos estoques de CH, caracterizados pela predominância de estados ideais e de alerta, enquanto os estoques de CP apresentam maior frequência de estados críticos e de emergência, refletindo maior instabilidade operacional. A escala em tons de cinza foi utilizada para representar a progressão da gravidade, permitindo a identificação visual de padrões temporais, recorrência de eventos críticos, persistência de estados de desabastecimento e períodos de instabilidade ao longo do tempo.

A aplicação de modelos de aprendizado de máquina permitiu a avaliação quantitativa da capacidade preditiva na classificação da criticidade dos estoques hemoterápicos. A partir do conjunto de dados estruturado, foram implementados algoritmos baseados em Random Forest e XGBoost, com o objetivo de estimar padrões operacionais e antecipar estados de risco assistencial (Breiman, 2001; Chen & Guestrin, 2016).


Os resultados demonstraram desempenho elevado para ambos os modelos, evidenciando robustez na predição dos níveis de criticidade. Observou-se que o modelo XGBoost apresentou desempenho superior em todas as métricas avaliadas, com destaque para a revocação e o F1-score, indicando maior sensibilidade na identificação de estados críticos e emergenciais (Kuhn & Johnson, 2013).

A análise comparativa das métricas de desempenho revelou consistência entre acurácia, precisão, revocação e F1-score, reforçando a confiabilidade dos modelos na classificação dos dados operacionais. Esse comportamento é particularmente relevante em contextos hemoterápicos, nos quais a capacidade de antecipar eventos críticos pode impactar diretamente a segurança assistencial e a gestão estratégica dos estoques (World Health Organization, 2019).

A Figura 3 apresenta o desempenho comparativo dos modelos de aprendizado de máquina, permitindo a visualização integrada das métricas de classificação. Observa-se que o modelo XGBoost tende a apresentar desempenho superior em relação ao Random Forest, especialmente na detecção de estados críticos e emergenciais, sugerindo maior sensibilidade

preditiva. Esses achados indicam o potencial de aplicabilidade dos algoritmos de aprendizado de máquina como ferramentas de suporte à decisão no contexto da gestão hemoterápica.

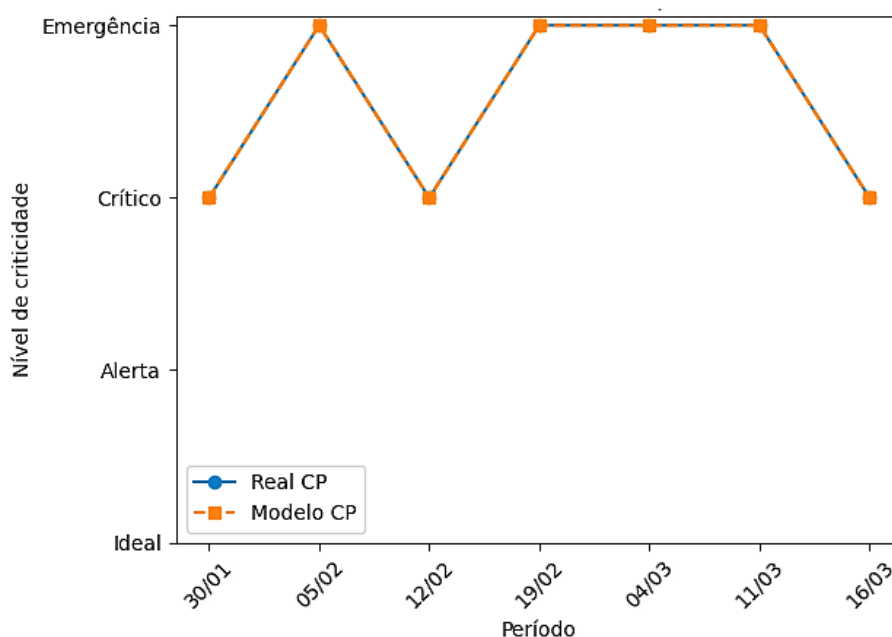
**Figura 3** – Desempenho comparativo dos modelos de aprendizado de máquina na predição da criticidade dos estoques hemoterápicos.



Fonte: Elaboração própria a partir dos modelos de aprendizado de máquina aplicados aos dados operacionais do hemocentro (2026).

A Figura 4 apresenta a comparação entre os níveis de criticidade observados e aqueles previstos pelos modelos de aprendizado de máquina ao longo do período de janeiro a março de 2026, construída a partir de registros operacionais estruturados e codificados ordinalmente. A análise evidencia elevado grau de concordância entre os valores observados e estimados, indicando adequada capacidade dos modelos em capturar a dinâmica temporal da criticidade dos estoques hemoterápicos.

**Figura 4** – Comparação entre os níveis de criticidade observados e previstos pelos modelos de aprendizado de máquina ao longo do período de janeiro a março de 2026.



Fonte: Elaboração própria a partir dos modelos de aprendizado de máquina aplicados aos dados operacionais do hemocentro (2026).

Observa-se um padrão diferenciado entre os hemocomponentes, no qual os concentrados de hemácias (CH) mantiveram-se predominantemente em níveis classificados como ideal, com transições pontuais para estados de alerta, comportamento que foi consistentemente reproduzido pelos modelos preditivos, sugerindo estabilidade operacional e boa capacidade de generalização.

Em contraste, os concentrados de plaquetas (CP) apresentaram maior variabilidade temporal, caracterizada por frequentes transições entre estados de criticidade, com recorrência de níveis classificados como crítico e emergência. Essa maior instabilidade também foi capturada pelos modelos, ainda que com discretas divergências em pontos específicos, o que reflete a complexidade inerente à previsão desse hemocomponente.

Do ponto de vista analítico, essa diferença pode ser interpretada à luz das propriedades intrínsecas dos hemocomponentes, uma vez que as plaquetas possuem menor tempo de validade, maior sensibilidade às condições de armazenamento e maior dependência de reposição contínua, o que aumenta sua suscetibilidade a flutuações na demanda e limitações na captação de doadores.

Adicionalmente, a presença de padrões recorrentes de criticidade nos estoques de CP, bem como sua representação nos valores previstos, sugere a existência de ciclos operacionais de risco parcialmente capturados pelos modelos de aprendizado de máquina. Esses achados reforçam o potencial dessas abordagens na identificação antecipada de cenários críticos, subsidiando intervenções estratégicas mais assertivas e contribuindo para a mitigação de riscos assistenciais e para a otimização da gestão dos estoques hemoterápicos.


A análise da distribuição dos níveis de criticidade dos estoques hemoterápicos foi conduzida a partir da organização proporcional dos estados classificados como ideal, alerta, crítico e emergência, considerando o período compreendido entre janeiro e março de 2026. Para fins analíticos, os dados foram estruturados em três recortes temporais equivalentes, possibilitando a avaliação comparativa das variações na composição relativa dos níveis de criticidade ao longo do período investigado.

Observa-se que o nível classificado como ideal apresentou predominância consistente em todos os períodos analisados, indicando um padrão global de estabilidade no abastecimento dos hemocomponentes. Contudo, identificam-se oscilações discretas nas proporções dos estados de alerta e crítico, sugerindo a influência de variações operacionais relacionadas à dinâmica da demanda assistencial, bem como aos processos de reposição e gestão dos estoques.

Adicionalmente, a ocorrência de níveis classificados como emergência, ainda que em menor magnitude proporcional, evidencia a presença de eventos pontuais de maior criticidade. Tal achado reforça a necessidade de monitoramento contínuo e da implementação de estratégias preditivas voltadas à antecipação de cenários adversos.

A análise comparativa entre os três períodos demonstra relativa consistência no comportamento global do sistema, com variações de baixa amplitude que podem refletir tanto ajustes operacionais quanto flutuações inerentes ao consumo e à reposição dos hemocomponentes. Nesse contexto, a abordagem adotada não apenas permite a compreensão da estrutura de distribuição da criticidade ao longo do tempo, como também subsidia, de forma indireta, a avaliação do potencial dos modelos preditivos em representar o comportamento do sistema, conforme ilustrado na Figura 5.

**Figura 5** – Distribuição proporcional dos níveis de criticidade dos estoques hemoterápicos ao longo do período de janeiro a março de 2026.



Fonte: Elaboração própria, a partir de dados operacionais do hemocentro, organizados e analisados por meio de estatística descritiva (2026).

#### 4. Discussão

A gestão de estoques hemoterápicos configura-se como um sistema complexo, no qual interagem variáveis relacionadas à demanda assistencial, à precibilidade dos hemocomponentes e à capacidade logística de reposição. Os achados deste estudo demonstram que a criticidade dos estoques não se distribui de maneira uniforme, mas segue padrões dinâmicos que refletem tanto a organização dos serviços de saúde quanto a eficiência dos processos de captação e distribuição. Esse comportamento está em consonância com a literatura, que caracteriza o sangue como um recurso crítico, marcado por elevada variabilidade operacional e sensibilidade a flutuações sistêmicas (World Health Organization, 2019).

No contexto organizacional, observa-se que a suficiência de hemocomponentes está diretamente associada à integração dos serviços, à governança e ao monitoramento contínuo dos estoques. Sistemas fragmentados tendem a apresentar maior risco de desabastecimento localizado, mesmo na presença de disponibilidade global aparente, o que reforça a necessidade de ferramentas analíticas capazes de identificar vulnerabilidades e apoiar decisões estratégicas em tempo oportuno (World Health Organization, 2019).

A análise dos padrões de comportamento do estoque evidenciou diferenças marcantes entre os hemocomponentes. Os concentrados de hemácias apresentaram comportamento mais estável ao longo do período analisado, enquanto os concentrados de plaquetas demonstraram maior frequência de estados críticos e emergenciais. Essa diferença pode ser explicada pelas características intrínsecas das plaquetas, especialmente sua curta vida útil e elevada sensibilidade às condições de armazenamento, fatores que aumentam a probabilidade de perdas e dificultam a manutenção de níveis adequados de estoque (Estcourt et al., 2017).

Além disso, a variabilidade observada entre os grupos sanguíneos indica que a criticidade não depende apenas do tipo de hemocomponente, mas também da distribuição populacional e da capacidade de reposição. Grupos menos frequentes apresentam maior vulnerabilidade operacional, exigindo estratégias específicas de planejamento e redistribuição. Evidências da área de logística em saúde apontam que abordagens diferenciadas são fundamentais para otimizar a disponibilidade e reduzir perdas (Pierskalla, 2005).

No que se refere à modelagem preditiva, os resultados indicaram desempenho superior do algoritmo XGBoost em comparação ao Random Forest, especialmente na identificação de estados de maior criticidade. Esse achado é confiável com

estudos que destacam a eficiência de métodos baseados em boosting na captura de relações não lineares e padrões complexos em dados de saúde (Chen & Guestrin, 2016).

Ainda assim, é importante reconhecer que a aplicação de inteligência artificial em hemoterapia permanece em processo de consolidação. Embora os resultados observados sejam promissores, a literatura ressalta a necessidade de validação externa, ampliação das bases de dados e padronização metodológica para garantir maior robustez e aplicabilidade prática desses modelos (Rajkomar et al., 2019; Sibinga, 2020).

A comparação entre os níveis de criticidade observados e aqueles estimados pelos modelos evidenciou adequado grau concordância ao longo do período analisado, indicando que os algoritmos foram capazes de reproduzir, com boa precisão, a dinâmica operacional dos estoques hemoterápicos. Esse resultado reforça o potencial da inteligência artificial como ferramenta de apoio à gestão, especialmente na antecipação de cenários críticos. Observou-se que os padrões de estabilidade dos concentrados de hemácias foram adequadamente capturados, enquanto a maior variabilidade dos concentrados de plaquetas também foi reproduzida pelos modelos, ainda que com pequenas discrepâncias em momentos de maior instabilidade.

Sob a perspectiva gerencial, esses achados indicam a possibilidade de transição de uma abordagem reativa para uma abordagem preditiva na gestão dos estoques. Em vez de responder a episódios de escassez após sua ocorrência, torna-se possível antecipar situações de risco e implementar estratégias preventivas, como ajuste de campanhas de doação, redistribuição de hemocomponentes e otimização dos níveis de estoque. Estudos recentes apontam que a incorporação de modelos preditivos pode reduzir desperdícios e aumentar a eficiência operacional em sistemas de hemoterapia (Chandler et al., 2020).

A análise da distribuição proporcional dos níveis de criticidade revelou predominância de estados classificados como ideais, porém com presença recorrente de situações de alerta e criticidade elevada. Esse resultado indica que, embora o sistema apresente funcionamento global satisfatório, existem fragilidades que podem comprometer a segurança assistencial. A literatura aponta que mesmo sistemas bem estruturados podem apresentar instabilidade local quando não há monitoramento contínuo e integração efetiva dos dados (Klein et al., 2019).

Um aspecto inovador deste estudo reside na utilização da criticidade como variável central de análise, em substituição à abordagem tradicional baseada apenas na previsão da demanda. Essa perspectiva permite uma avaliação mais direta do risco operacional, aproximando os modelos analíticos das necessidades reais dos serviços de hemoterapia e contribuindo para uma tomada de decisão mais assertiva (Abolghasemi et al., 2010).

Por fim, é necessário considerar as limitações do estudo, especialmente o recorte temporal restrito, que pode não capturar integralmente variações sazonais mais amplas. Além disso, a utilização de dados provenientes de um único serviço limita a generalização dos resultados. Ainda assim, os achados apresentados oferecem evidências consistentes sobre o potencial da modelagem preditiva na gestão hemoterápica, indicando caminhos promissores para o desenvolvimento de estratégias mais eficientes e baseadas em dados (Rajkomar et al., 2019; Sibinga, 2020).

## 5. Considerações Finais

A aplicação de inteligência artificial na previsão da criticidade de estoques hemoterápicos demonstrou ser uma abordagem viável, robusta e cientificamente consistente para apoiar a gestão transfusional. Os resultados evidenciaram que a criticidade dos estoques não se configura como um fenômeno aleatório, mas segue padrões estruturados, influenciados por fatores como o tipo de hemocomponente, sua perecibilidade, a frequência dos grupos sanguíneos e a dinâmica assistencial.

Essa constatação indica que modelos baseados exclusivamente em reposição reativa são insuficientes frente à complexidade do sistema, tornando necessária a adoção de abordagens preditivas, proativas e orientadas por dados. Tais

estratégias permitem antecipar cenários críticos, otimizar a alocação de recursos e fortalecer a segurança transfusional, em consonância com as diretrizes internacionais de gestão baseada em evidências.

Um dos principais achados deste estudo foi a capacidade dos modelos de aprendizado de máquina de reproduzir, com concordância satisfatória, os padrões observados de criticidade ao longo do tempo, evidenciando sua aplicabilidade na modelagem de sistemas hemoterápicos reais. A comparação entre dados observados e previstos demonstrou que os algoritmos foram capazes de capturar a dinâmica operacional dos estoques, incluindo padrões já descritos na literatura, como a maior estabilidade dos concentrados de hemácias e a maior variabilidade dos concentrados de plaquetas, associada à sua curta vida útil.

Embora esse comportamento seja amplamente conhecido, o presente estudo evidencia a capacidade dos modelos em representar e antecipar esses padrões em dados operacionais reais, conferindo aplicabilidade prática às abordagens preditivas na gestão hemoterápica. Nesse contexto, a inteligência artificial se consolida não apenas como ferramenta descritiva, mas como instrumento analítico capaz de antecipar cenários de risco, como desabastecimento, instabilidade dos estoques de plaquetas e falhas na cobertura assistencial, subsidiando intervenções estratégicas mais oportunas e eficazes.

A principal contribuição deste estudo reside na capacidade de transformar dados operacionais em indicadores preditivos de criticidade, incluindo a classificação dos níveis de risco (ideal, alerta, crítico e emergência), o escore ordinal de severidade e as probabilidades estimadas pelos modelos de aprendizado de máquina. Esses indicadores permitiram antecipar estados de criticidade e compreender a dinâmica temporal dos estoques. Ao invés de apenas descrever o comportamento do sistema, a modelagem possibilitou identificar tendências operacionais, como a persistência e recorrência de estados críticos, ciclos de instabilidade ao longo do tempo e maior variabilidade associada aos concentrados de plaquetas.

Além disso, foram identificados pontos de vulnerabilidade recorrentes, especialmente relacionados aos concentrados de plaquetas, determinados grupos sanguíneos menos frequentes e períodos com maior incidência de criticidade elevada. Esses achados evidenciam a transição de um modelo reativo para uma abordagem preditiva orientada por dados, na qual a antecipação de riscos passa a subsidiar intervenções mais estratégicas e eficientes na gestão hemoterápica.

No contexto dos períodos críticos de escassez, frequentemente associados à sazonalidade, como férias, epidemias e datas festivas, a exemplo do Carnaval, São João e Natal, a inteligência artificial pode atuar como ferramenta estratégica de antecipação. A partir da identificação de padrões históricos e comportamentos recorrentes, torna-se possível prever quedas na disponibilidade de hemocomponentes e delimitar janelas temporais de maior risco. Essa capacidade preditiva permite o planejamento antecipado de intervenções, incluindo campanhas de captação direcionadas em escolas, universidades, instituições públicas e privadas, bem como estratégias de comunicação social e marketing voltadas à mobilização de doadores.

Além disso, a inteligência artificial pode subsidiar decisões operacionais, como ajuste de níveis de estoque, redistribuição de hemocomponentes entre unidades e priorização de recursos em períodos críticos. Dessa forma, modelos preditivos contribuem não apenas para a redução de faltas, mas também para a otimização da gestão hemoterápica, ao permitir uma atuação proativa e orientada por dados frente aos desafios sazonais do sistema.

Esses achados evidenciam a necessidade de estratégias diferenciadas para os hemocomponentes, especialmente para os concentrados de plaquetas, que apresentam maior instabilidade operacional em comparação aos concentrados de hemácias. Além disso, o uso de ferramentas analíticas contribui para a racionalização de recursos, por meio da redução de desperdícios, melhor alocação de hemocomponentes e ajuste mais preciso dos níveis de estoque.

Do ponto de vista assistencial, essas abordagens fortalecem a segurança transfusional ao reduzir o risco de desabastecimento, minimizar atrasos transfusionais e garantir maior previsibilidade na disponibilidade de hemocomponentes. Adicionalmente, ampliam a capacidade de resposta do sistema frente a eventos adversos, ao possibilitar a antecipação de cenários críticos e a implementação de intervenções estratégicas baseadas em evidências.

Do ponto de vista metodológico, a integração entre estatística descritiva e algoritmos de aprendizado de máquina mostrou-se adequada para capturar a complexidade do fenômeno estudado, caracterizado por elevada variabilidade temporal, heterogeneidade entre hemocomponentes, múltiplos fatores operacionais interdependentes e padrões dinâmicos de transição entre níveis de criticidade. Essas abordagens são amplamente utilizadas em sistemas de saúde para análise de padrões e suporte à decisão, sendo particularmente relevantes em contextos de alta variabilidade e demanda assistencial.

Entretanto, este estudo apresenta limitações que devem ser consideradas. O período de análise restrito pode não capturar integralmente variações sazonais mais amplas ao longo do ano, e a utilização de dados de um único serviço limita a generalização dos resultados. A literatura recomenda validação multicêntrica e séries temporais mais extensas para maior robustez dos modelos preditivos.

Apesar dessas limitações, os resultados obtidos são consistentes e oferecem evidências relevantes para a incorporação de ferramentas preditivas na gestão hemoterápica. A capacidade de antecipar cenários críticos, aliada à validação empírica dos modelos, representa um avanço significativo na área, especialmente em sistemas públicos de saúde.

Em síntese, este estudo demonstra que a inteligência artificial deve ser compreendida como uma ferramenta concreta, aplicável e validada no contexto da hemoterapia. Sua integração aos sistemas de gestão pode contribuir para maior eficiência, redução de riscos e melhoria da qualidade assistencial, consolidando uma abordagem baseada em dados como eixo central da tomada de decisão em saúde.

## Referências

- Abolghasemi, H., et al. (2010). Blood donor incentives: A step forward or backward. *Asian Journal of Transfusion Science*, 4(1), 9–13.
- Agresti, A. (2010). *Analysis of ordinal categorical data* (2nd ed.). Wiley.
- Brasil. Ministério da Saúde. (2011). *Guia nacional de gerenciamento de estoque de sangue em situações de emergência*. Ministério da Saúde.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Chandler, T., et al. (2020). Blood inventory management: Hospital best practices. *Transfusion Medicine Reviews*, 34(3), 181–188.
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). ACM.
- Estcourt, L. J., et al. (2017). Platelet transfusions for preventing bleeding in people with haematological disorders after chemotherapy and stem cell transplantation. *Cochrane Database of Systematic Reviews*, (7).
- Field, A. (2013). *Discovering statistics using IBM SPSS statistics* (4th ed.). Sage.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice* (2nd ed.). OTexts.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An introduction to statistical learning: With applications in R* (2nd ed.). Springer.
- Karakatsanis, A., et al. (2021). Forecasting blood demand: A systematic review. *Vox Sanguinis*, 116(2), 109–121.
- Klein, H. G., et al. (2019). Biomedical excellence for safer transfusion. *The New England Journal of Medicine*, 381(6), 509–511.
- Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling*. Springer.
- McKinney, W. (2010). Data structures for statistical computing in Python. In *Proceedings of the 9th Python in Science Conference* (pp. 56–61). SciPy.
- Pedregosa, F., et al. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Pereira et al. (2018). *Metodologia da pesquisa científica*. [Free ebook]. Editora da UFSM.
- Pierskalla, W. P. (2005). Supply chain management of blood banks. *Operations Research*, 53(5), 769–784.
- Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. *The New England Journal of Medicine*, 380(14), 1347–1358.
- Risemberg, R. I. C., Wakin, M., & Shitsuka, R. (2026). A importância da metodologia científica no desenvolvimento de artigos científicos. *E-Acadêmica*, 7(1), e0171675. <https://doi.org/10.52076/eacad-v7i1.675>.
- Sibinga, C. T. S. (2020). Artificial intelligence in transfusion medicine and its impact on the quality concept. *Transfusion and Apheresis Science*, 59(6), e103021.

Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437.

Wasserstein, R. L., & Lazar, N. A. (2016). The ASA statement on p-values: Context, process, and purpose. *The American Statistician*, 70(2), 129–133.