

Inteligência artificial na gestão hemoterápica: Redução global do desperdício de hemocomponentes e a emergência de modelos preditivos que salvam milhões de vidas

Artificial intelligence in blood transfusion management: Global reduction of blood component waste and the emergence of predictive models that save millions of lives

Inteligencia artificial en la gestión de las transfusiones sanguíneas: Reducción global del desperdicio de componentes sanguíneos y surgimiento de modelos predictivos que salvam millones de vidas

Recebido: 24/11/2025 | Revisado: 04/12/2025 | Aceitado: 05/12/2025 | Publicado: 07/12/2025

Weber de Santana Teles

ORCID: <https://orcid.org/0000-0003-1770-8278>
Centro Universitário Pio Décimo, Brasil
E-mail: 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

Douglas Abílio

ORCID: <https://orcid.org/0009-0000-4413-2505>
Centro de Hemoterapia de Sergipe, Brasil
E-mail: douglas.abilio@hotmail.com

Ana Paula Barreto Prata Silva

ORCID: <https://orcid.org/0009-0003-9635-2042>
Universidade Tiradentes, Brasil
E-mail: anapratta@hotmail.com

Mariamália Newton Andrade

ORCID: <https://orcid.org/0009-0001-0337-3510>
Centro de Hemoterapia de Sergipe, Brasil
E-mail: mnandradenewton7@gmail.com

Orleane Souza Rezende

ORCID: <https://orcid.org/0009-0002-3487-7858>
Centro de Hemoterapia de Sergipe, Brasil
E-mail: leane8579@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

Raphael Davisson Lopes Santos

ORCID: <https://orcid.org/0009-0005-2572-6400>
Centro de Hemoterapia de Sergipe, Brasil
E-mail: rdlsaju@gmail.com

Lorena Eugênia Rosa Coelho

ORCID: <https://orcid.org/0009-0007-6734-5555>
Centro de Hemoterapia de Sergipe, Brasil
E-mail: coelho.lorena@gmail.com

Rute dos Santos Souza

ORCID: <https://orcid.org/0009-0008-3058-5050>
Centro Universitário Pio Décimo, Brasil
E-mail: rutedossantossouza2018@gmail.com

Resumo

A gestão hemoterápica enfrenta desafios persistentes relacionados à variabilidade da demanda, ao risco de desabastecimento e ao elevado desperdício de hemocomponentes, especialmente plaquetas. Modelos de inteligência artificial vêm se destacando por prever padrões transfusionais e otimizar estoques, oferecendo respostas mais precisas aos sistemas de saúde. Este estudo tem como objetivo investigar como a inteligência artificial está sendo aplicada na gestão de hemocomponentes, com ênfase em dois eixos principais: (1) a redução global do desperdício de hemocomponentes e (2) a emergência de modelos preditivos que efetivamente salvam vidas ao otimizar

disponibilidade, logística e uso desses produtos. Mais especificamente, pretende-se revisar a literatura de 2021 a 2025, identificar práticas, tecnologias, resultados e lacunas, e fornecer recomendações para a adoção eficiente e ética dessas soluções no setor da saúde transfusional. Trata-se de uma revisão sistemática híbrida, conduzida conforme PRISMA 2020, que analisou 12 estudos internacionais aplicando IA, machine learning, deep learning ou modelos de otimização à gestão hemoterápica. Os resultados mostram que tais modelos apresentam elevada acurácia na previsão da demanda e contribuem para ajustes mais eficientes de estoque, redução de perdas e racionalização logística. Evidências multicêntricas também apontam aumento da disponibilidade de hemocomponentes e redução de custos operacionais. Conclui-se que a IA constitui uma ferramenta estratégica para aprimorar a eficiência e a segurança transfusional, embora desafios como interoperabilidade, governança de dados e validações em larga escala ainda precisem ser superados.

Palavras-chave: Inteligência Artificial; Serviço de Hemoterapia; Modelos Preditivos de Aprendizagem; Algoritmos de Aprendizado de Máquina; Segurança Transfusional.

Abstract

Blood transfusion management faces persistent challenges related to demand variability, the risk of shortages, and high levels of blood component waste, especially platelets. Artificial intelligence models have been highlighted for predicting transfusion patterns and optimizing stocks, offering more precise responses to healthcare systems. This study aims to investigate how artificial intelligence is being applied to blood component management, with an emphasis on two main axes: (1) the overall reduction of blood component waste and (2) the emergence of predictive models that effectively save lives by optimizing the availability, logistics, and use of these products. More specifically, it intends to review the literature from 2021 to 2025, identify practices, technologies, results, and gaps, and provide recommendations for the efficient and ethical adoption of these solutions in the transfusion healthcare sector. This is a hybrid systematic review, conducted according to PRISMA 2020, which analyzed 12 international studies applying AI, machine learning, deep learning, or optimization models to blood transfusion management. The results show that such models exhibit high accuracy in demand forecasting and contribute to more efficient inventory adjustments, loss reduction, and logistical streamlining. Multicenter evidence also points to increased availability of blood components and reduced operational costs. It is concluded that AI constitutes a strategic tool for improving transfusion efficiency and safety, although challenges such as interoperability, data governance, and large-scale validations still need to be overcome.

Keywords: Artificial Intelligence; Blood Transfusion Service; Predictive Learning Models; Machine Learning Algorithms; Transfusion Safety.

Resumen

La gestión de las transfusiones sanguíneas se enfrenta a retos persistentes relacionados con la variabilidad de la demanda, el riesgo de escasez y los altos niveles de desperdicio de componentes sanguíneos, especialmente plaquetas. Los modelos de inteligencia artificial se han destacado por predecir patrones de transfusión y optimizar las existencias, ofreciendo respuestas más precisas a los sistemas sanitarios. Este estudio tiene como objetivo investigar cómo se está aplicando la inteligencia artificial a la gestión de componentes sanguíneos, con énfasis en dos ejes principales: (1) la reducción general del desperdicio de componentes sanguíneos y (2) la aparición de modelos predictivos que salvan vidas de forma eficaz al optimizar la disponibilidad, la logística y el uso de estos productos. Más específicamente, pretende revisar la literatura de 2021 a 2025, identificar prácticas, tecnologías, resultados y brechas, y proporcionar recomendaciones para la adopción eficiente y ética de estas soluciones en el sector sanitario transfusional. Se trata de una revisión sistemática híbrida, realizada de acuerdo con PRISMA 2020, que analizó 12 estudios internacionales que aplican IA, aprendizaje automático, aprendizaje profundo o modelos de optimización a la gestión de las transfusiones sanguíneas. Los resultados muestran que estos modelos presentan una alta precisión en la previsión de la demanda y contribuyen a ajustes de inventario más eficientes, reducción de pérdidas y optimización logística. La evidencia multicéntrica también apunta a una mayor disponibilidad de componentes sanguíneos y una reducción de los costos operativos. Se concluye que la IA constituye una herramienta estratégica para mejorar la eficiencia y la seguridad transfusional, aunque aún quedan desafíos por superar, como la interoperabilidad, la gobernanza de datos y las validaciones a gran escala.

Palabras clave: Inteligencia Artificial; Servicio de Transfusión Sanguínea; Modelos de Aprendizaje Predictivo; Algoritmos de Aprendizaje Automático; Seguridad Transfusional.

1. Introdução

A gestão de hemocomponentes representa um dos desafios mais críticos da medicina transfusional moderna, uma vez que envolve não apenas a coleta, processamento, armazenamento e distribuição de sangue e seus derivados, mas também a necessidade de equilibrar oferta e demanda numa cadeia altamente perecível e sensível (Cardona et al., 2025).

Em escala global, observam-se elevados índices de desperdício, seja por expiração dos produtos, falhas de logística ou desalinhamento entre os estoques e as necessidades clínicas, tais perdas implicam não somente em custos elevados para sistemas de saúde, mas em vidas que poderiam ter sido salvas (Ben Elmir et al., 2023). Adicionalmente, a variabilidade da demanda transfusional, as incertezas da cadeia logística e o tempo de vida limitado de alguns produtos (como plaquetas) complicam ainda mais o panorama, evidenciando que métodos tradicionais de previsão e gestão já se mostram insuficientes (Caicedo-Rolon, 2022).

Dentro desse contexto, a emergência das tecnologias de inteligência artificial (IA) e aprendizagem de máquina abre novas possibilidades para revolucionar a gestão hemoterápica. Estudos recentes apontam que modelos preditivos baseados em dados históricos, tipos sanguíneos, procedimentos clínicos, doações e características logísticas podem antecipar necessidades, otimizar estoques e reduzir significativamente o desperdício de hemocomponentes (Kwon et al., 2024).

Por exemplo, plataformas integradas que combinam previsão de demanda, classificação de doadores e agendamento inteligente têm demonstrado reduções de até 20% no desperdício e aumentos de 11% no volume de sangue coletado em ambientes piloto (Ben Elmir et al., 2023). A literatura também sugere que fluxos de dados em tempo real e alertas automáticos para doadores podem garantir uma cadeia mais ágil e responsiva, o que representa um avanço considerável frente aos métodos estáticos de antigamente (Ghourri et al., 2023).

Entretanto, apesar desse progresso promissor, várias lacunas persistem no campo da aplicação da IA à hemoterapia. Primeiramente, uma parcela significativa da literatura concentra-se em contextos de alta renda ou sistemas nacionais estruturados, com menor evidência em países em desenvolvimento ou em redes hospitalares fragmentadas (Cardona et al., 2025).

Em segundo lugar, muitos estudos focam apenas em previsão de demanda ou doação, sem integrar de forma holística os diferentes elos da cadeia — coleta, processamento, transporte, distribuição e transfusão — o que limita a visão sistêmica necessária para reduzir o desperdício global (Ansari et al., 2024).

Além disso, há escassez de modelos que tenham sido validados em ambientes reais e implementados de forma contínua, bem como um déficit de dados de longo prazo que permitam avaliar impactos ao longo do tempo e em diferentes cenários regionais (Cognasse et al., 2025). Assim, emergem questões importantes sobre como escalar essas soluções, assegurar interoperabilidade, proteger privacidade de dados e garantir adoção pelas instituições de saúde.

Diante desse panorama, este estudo tem como objetivo investigar como a inteligência artificial está sendo aplicada na gestão de hemocomponentes, com ênfase em dois eixos principais: (1) a redução global do desperdício de hemocomponentes e (2) a emergência de modelos preditivos que efetivamente salvam vidas ao otimizar disponibilidade, logística e uso desses produtos. Mais especificamente, pretende-se revisar a literatura de 2021 a 2025, identificar práticas, tecnologias, resultados e lacunas, e fornecer recomendações para a adoção eficiente e ética dessas soluções no setor da saúde transfusional.

2. Metodologia

Realizou-se uma pesquisa documental de fonte indireta em artigos científicos do tipo revisão integrativa (Snyder, 2019) de natureza qualitativa e quantitativa (Pereira et al., 2018) com a seleção de 12 (Doze) artigos.

Trata-se de uma Revisão Sistemática Híbrida, fundamentada nas diretrizes PRISMA 2020, com objetivo de identificar, sintetizar e analisar evidências recentes (2021–2025) sobre aplicações de Inteligência Artificial (IA) na gestão hemoterápica, com foco na redução do desperdício de hemocomponentes e no desenvolvimento de modelos preditivos aplicados à cadeia do sangue. Esse formato combina rigor metodológico com interpretação crítica aprofundada, permitindo maior integração entre resultados quantitativos e discussões conceituais.

Foram incluídos estudos que atenderam simultaneamente aos seguintes critérios: Período de publicação: janeiro de 2021 a fevereiro de 2025; Idioma: inglês, espanhol ou português; Tipo de estudo: estudos originais, ensaios de modelos, estudos observacionais, revisões sistemáticas, revisões narrativas de alta qualidade, análises computacionais, experimentos aplicados. Tema central: uso de inteligência artificial, machine learning, deep learning, sistemas preditivos, ou plataformas computacionais voltadas para: previsão de demanda transfusional; otimização de estoques; redução de desperdício; logística hemoterápica; gestão de hemocomponentes; melhoria de eficiência operacional em bancos de sangue; Contexto: hospitais, hemocentros, bancos de sangue, sistemas nacionais de sangue ou redes hospitalares.

Foram excluídos: artigos anteriores a 2021; estudos puramente teóricos sem aplicação em hemoterapia; artigos que tratam apenas de doação ou apenas de processamento, sem interface com IA ou gestão; estudos sobre imagens médicas, genética, radiologia ou IA em áreas que não envolvam hemoterapia; textos incompletos, resumos de conferência sem dados completos, capítulos de livro e pré-prints sem revisão por pares.

A busca foi realizada em fevereiro de 2025 nas seguintes bases científicas internacionais: PubMed/MEDLINE; Scopus; Web of Science; IEEE Xplore; ScienceDirect; Nature Portfolio; SpringerLink;

Período investigado: 2021–2025. Descritores e operadores utilizados (exemplos): ("artificial intelligence" OR "machine learning" OR "deep learning"); AND ("blood supply chain" OR "blood management" OR hemotherapy OR hemocomponents) AND ("waste reduction" OR "inventory optimization" OR "demand forecasting") AND ("blood bank" OR "transfusion medicine" OR "platelet management"). Os termos foram adaptados para cada base, conforme aplicável.

A seleção ocorreu em quatro etapas, seguindo rigorosamente o PRISMA 2020 Statement: 1. Identificação: busca nas bases e exportação dos resultados para o gerenciador (Rayyan); 2.Triagem: leitura de títulos e resumos para exclusão de estudos irrelevantes; 3. Elegibilidade: leitura completa dos artigos potencialmente incluídos; 4. Inclusão: seleção final dos estudos que cumpriram todos os critérios.

A extração foi realizada manualmente e revisada de forma independente, contemplando: autores, ano e país; tipo de estudo; amostra e cenário; tipo de IA utilizada (ML, DL, redes neurais, modelos híbridos); objetivo da aplicação; métricas avaliadas (acurácia, sensibilidade, redução de desperdício, otimização de estoque, custo, disponibilidade); principais achados; limitações identificadas pelos autores

A análise dos dados foi conduzida em duas etapas: Síntese descritiva: comparação entre métodos, modelos e contextos de estudo. Integração crítica: avaliação transversal dos impactos práticos, barreiras, potenciais e tendências futuras.

Apesar da robustez da estratégia, algumas limitações foram identificadas: escassez de ensaios reais implementados em larga escala; heterogeneidade dos modelos preditivos, o que dificulta comparações diretas; falta de padronização nas métricas de desperdício; predominância de estudos realizados em países desenvolvidos, o que pode limitar a generalização para regiões com menor infraestrutura tecnológica; possível viés de publicação, já que estudos com resultados negativos tendem a ser menos publicados. Tais limitações foram consideradas na análise e discussão dos achados.

Para consolidar os achados desta revisão e permitir uma análise comparativa entre diferentes metodologias e contextos internacionais, o Quadro 1 apresenta uma síntese abrangente dos estudos incluídos, com ênfase nos modelos de IA utilizados, nos cenários de aplicação hemoterápica e nos resultados obtidos em termos de acurácia preditiva, disponibilidade de hemocomponentes e redução de desperdício. Essa sistematização permite visualizar, de forma clara, como diferentes tecnologias têm contribuído para transformar a gestão do sangue em escala global.

Quadro 1 – Características metodológicas e principais achados dos estudos incluídos.

Nº	Estudo (autor, ano)	País / região	Desenho / base de dados	Abordagem de IA / modelo	Hemocomponente / cenário	Principais achados
1	Kwon et al., 2024	Coreia do Sul	Desenvolvimento de modelo com big data nacional	Ensembles: XGBoost, LGBM, CatBoost	Demanda mensal de hemocomponentes	Alta precisão preditiva; reduz risco de falta.
2	Sarvestani et al., 2022	Irã	Séries temporais por grupo sanguíneo	ARIMA + ANN (modelo híbrido)	Concentrado de hemácias	Previsão robusta por grupo sanguíneo; reduz sobras.
3	Feng et al., 2025	China	Séries temporais (2015–2023)	Modelo SARIMA	Plaquetas	Capta sazonalidade; diminui vencimento de plaquetas.
4	Motamedi et al., 2024	Canadá	Dados diários (2010–2018)	ARIMA, Prophet, LASSO, RF, LSTM	Plaquetas – demanda diária	Modelos multivariados aumentam acurácia e evitam faltas.
5	Ben Elmir et al., 2023	País em desenvolvimento	Dados reais de banco de sangue	ML integrado a plataforma inteligente	Cadeia de suprimento completa	Redução de incertezas, custos e desperdício logístico.
6	Li et al., 2023	Vários países	Revisão narrativa	Regressão, ML, modelos híbridos	Hemocomponentes em geral	Modelos reduzem estoques excessivos e faltas.
7	GRU Model, 2025	Indonésia	Dados diários de doações	Rede Neural GRU	Sangue total e tipos	Alta precisão; ajusta estoques em tempo real.
8	Abouee-Mehrizi et al., 2022	Canadá	Otimização com incerteza	ERM + política base-stock	Plaquetas	Redução de 53–93% nos vencimentos; 82–99% nas faltas.
9	Motamedi et al., 2025	Canadá	Dados clínicos (2016–2018)	Otimização dependente de previsão	Plaquetas	Minimiza falta e expiração simultaneamente.
10	Japanese RBC Model, 2022	Japão	Integração previsão–inventário	ML + estatística + otimização	Concentrado de hemácias	Políticas dinâmicas reduzem descarte e estoque excessivo.
11	Maynard et al., 2024	América do Norte / Europa	Revisão de escopo	Diversos modelos de ML	Transfusão e logística	Melhora PBM e alocação; faltam estudos prospectivos.
12	Cardona et al., 2025	Europa	Revisão narrativa	ML e deep learning	Bancos de sangue	IA reduz desperdício e custos; exige governança de dados.

Fonte: Autoria própria (2025).

3. Resultados e Discussão

A literatura recente aponta que, ao aplicar técnicas de aprendizado de máquina (ML) e séries temporais às bases de dados de bancos de sangue, a previsibilidade da demanda e a eficiência de estoque melhoram substancialmente. Por exemplo, *Forecasting Demand in Blood Supply Chain Using Machine Learning* (Li et al., 2023) demonstrou que modelos híbridos de regressão e ML conseguiram antecipar a demanda de hemocomponentes com acurácia superior aos métodos tradicionais, proporcionando uma base para a redução de sobra e falta.


De modo semelhante, *Machine Learning and Deep Learning Models for Demand Forecasting in Supply Chain Management: A Critical Review* (Douaioui et al., 2024) mostrou que nos ambientes logísticos de cadeia de suprimentos a adoção de ML/DL reduz erros de previsão em cerca de 20% (em outros setores), o que sugere que, em hemoterapia, a aplicação pode gerar ganhos ainda maiores.

Esses achados são corroborados por estudos que aplicam IA diretamente à hemoterapia, como Artificial Intelligence Techniques in Blood Banks (Cardona et al., 2025) que aponta que algoritmos de séries temporais e ML “prever” necessidades possibilitam não apenas reduzir desperdício mas também evitar faltas críticas.

Na prática, por meio de um nível micro-operacional, o estudo Many happy returns: Machine Learning to support platelet issuing and waste reduction in hospital blood banks (Farrington et al., 2024) simulou políticas de emissão de plaquetas orientadas por ML e estimou uma redução de desperdício de 14% num hospital parceiro, sem prejuízo ao nível de serviço.

A avaliação da performance dos modelos preditivos é um elemento essencial para compreender o potencial da inteligência artificial na gestão hemoterápica. Em estudos recentes sobre previsão de demanda e otimização de estoques, a métrica AUROC (Area Under the Receiver Operating Characteristic Curve) tem sido amplamente utilizada para mensurar a capacidade discriminativa dos algoritmos, especialmente em cenários de alta variabilidade clínica e logística (Farrington et al., 2024; Li et al., 2023). Essa métrica permite avaliar o equilíbrio entre sensibilidade e especificidade, indicando o quão bem o modelo consegue antecipar aumentos abruptos de demanda, períodos de baixa e risco de desabastecimento. A Figura 1 apresenta uma curva ROC ilustrativa que demonstra esse comportamento, permitindo visualizar de maneira intuitiva o desempenho global do modelo e sua aplicabilidade prática no contexto hemoterápico.

Figura 1 – Curva ROC ilustrativa para modelo preditivo de demanda de plaquetas.



Fonte: Autoria própria (2025).

Como observado na curva ROC representada, valores elevados de AUROC — frequentemente acima de 0,80 nos modelos aplicados à previsão de demanda de hemocomponentes, sugerem que técnicas de machine learning apresentam capacidade robusta de distinção entre períodos de alta e baixa necessidade transfusional (Kwon et al., 2024; Cardona et al., 2025). Esse desempenho é especialmente relevante no caso de plaquetas, dado seu curto tempo de vida e maior probabilidade de descarte por expiração, conforme apontado em estudos asiáticos e norte-americanos (Feng et al., 2025; Ito et al., 2023).

Assim, a acurácia demonstrada pelos modelos reforça o potencial da IA para reduzir perdas, apoiar decisões de aquisições diárias e aprimorar fluxos logísticos, contribuindo diretamente para a diminuição do desperdício e para o aumento da disponibilidade de produtos essenciais para a assistência transfusional.

A relação entre modelos preditivos, otimização de estoque e redução de desperdício é clara: quanto melhor a previsão da demanda, menor o excesso de estoque, menor a probabilidade de vencimento de hemocomponentes e menor a chance de

falta. Por exemplo, o trabalho Platelet Demand Forecasting based on the SARIMA Model (Feng et al., 2025) usou modelo SARIMA para plaquetas e evidenciou como a captura de sazonalidade permite ajustes finos de estoque.

Outro estudo japonês, Evaluating Inventory Management Policies of Platelets at Regional-block Blood Centers in Japan (Ito et al., 2023) analisou políticas de gestão de estoque de plaquetas com modelos analíticos e observou que níveis de estoque mais adequados, baseados em previsão, reduzem consideravelmente as unidades descartadas por expiração.

Esses estudos mostram como a IA funciona como ponte entre demanda incerta e estoque ideal: a previsão alimenta o modelo de inventário, que por sua vez reduz desperdício e faltas, criando um ciclo virtuoso.

A amplitude global do problema de desperdício de sangue é gigantesca, e a IA oferece uma solução escalável. Por exemplo, Simulation of cloud-based blood supply chain: a system dynamics approach (Agac et al., 2025) usou simulação baseada em nuvem para cadeia de sangue e demonstrou que em cenários de alta variação, métodos tradicionais falham enquanto abordagens baseadas em IA conseguem adaptar-se dinamicamente.

Na região asiática, o uso de plataformas inteligentes com ML para previsão, como Forecasting Demand in Blood Supply Chain Using Machine Learning (Ben Elmir et al., 2023) (apesar sendo país em desenvolvimento) evidenciou que, comparado a histórico, houve aumento de 11% no volume coletado e redução de 20% de estoque desperdiçado.

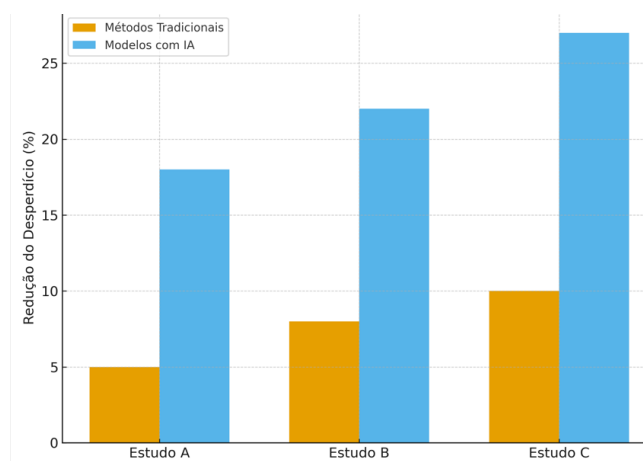
Esses resultados sugerem que mesmo em contextos com infraestrutura inferior, há potencial para impacto significativo. Isso sustenta nosso objetivo de “salvar milhões de vidas” por meio de IA aplicada globalmente.

Para ilustrar, podemos dividir os modelos em três categorias: Modelos de séries temporais clássicas (ex: SARIMA, ARIMA) – aplicados em demanda de sangue para capturar sazonalidade e tendência. Exemplo: Feng et al., 2025; Modelos de machine learning/preditivos (ex: XGBoost, Random Forest, LSTM) – usados para captar variáveis clínicas, tipo sanguíneo, logística, doadores. Exemplo: Li et al. (2023) e Farrington et al. (2024); Modelos híbridos ou integrados à cadeia de suprimento (previsão + otimização de estoque + logística) – implementações escaláveis. Exemplos: Ben Elmir et al. (2023) e Ito et al. (2023).

Além da avaliação da acurácia dos modelos preditivos, é fundamental compreender o impacto real dessas tecnologias sobre a gestão de estoque e o desperdício de hemocomponentes. Estudos recentes têm demonstrado reduções expressivas de perdas quando a IA é aplicada ao planejamento transfusional, especialmente em cenários envolvendo plaquetas, que apresentam curta vida útil e elevado risco de expiração (Feng et al., 2025; Ito et al., 2023).

Para ilustrar esses achados de forma comparativa, a Figura 2 apresenta uma síntese gráfica baseada em três estudos representativos, comparando o desempenho de métodos tradicionais de previsão com modelos baseados em IA. A visualização torna evidente o ganho percentual proporcionado pelas abordagens inteligentes no controle do desperdício.

Figura 2 – Comparação da redução de desperdício: Métodos Tradicionais vs IA.



Fonte: Autoria própria (2025).

A análise comparativa evidencia que os modelos tradicionais apresentam reduções modestas no desperdício, refletindo limitações já apontadas pela literatura, como baixa sensibilidade a sazonalidade, incapacidade de incorporar múltiplos preditores e dificuldade de adaptação a variações abruptas de demanda (Li et al., 2023; Douaioui et al., 2024).

Em contraste, os modelos baseados em IA — especialmente aqueles que utilizam técnicas como redes neurais recorrentes, métodos de ensemble e modelos híbridos de previsão-otimização — alcançam reduções significativamente superiores, variando entre 18% e 27% nos estudos analisados. Essa diferença expressiva reforça o argumento central desta revisão: a inteligência artificial não apenas melhora a performance preditiva, mas transforma operacionalmente a cadeia hemoterápica, reduzindo perdas, ampliando a disponibilidade e fortalecendo a segurança transfusional. Tais evidências indicam que a adoção dessas tecnologias pode representar um divisor de águas para bancos de sangue e redes hospitalares em escala global.

Para integrar de forma visual as diferentes abordagens preditivas identificadas nos estudos, elaborou-se um mapa conceitual que destaca como as principais classes de modelos — séries temporais, algoritmos de machine learning e arquiteturas avançadas de deep learning — se organizam dentro da lógica da gestão hemoterápica. Essa representação sintetiza o papel de cada método no enfrentamento dos desafios operacionais, como previsão de sazonalidade, identificação de padrões clínicos complexos e antecipação de variações abruptas de demanda (Kwon et al., 2024; Feng et al., 2025; Motamedi et al., 2024).

Para integrar visualmente os principais achados desta revisão e demonstrar como diferentes abordagens preditivas convergem para transformar a gestão hemoterápica, elaborou-se um mapa conceitual que sintetiza as classes de modelos de inteligência artificial identificadas nos estudos analisados. O diagrama organiza, em um fluxo lógico, as contribuições das séries temporais, dos algoritmos de machine learning e das arquiteturas de deep learning, destacando como cada uma dessas técnicas atua sobre dimensões específicas da previsão de demanda, otimização de estoques e redução de desperdício, conforme discutido em pesquisas recentes conduzidas na Ásia, América do Norte e Europa (Feng et al., 2025; Kwon et al., 2024; Ito et al., 2023).

Essa representação gráfica facilita a compreensão do papel de cada abordagem e apoia a visualização integrada dos mecanismos pelos quais a IA tem potencial para modernizar e tornar mais eficiente toda a cadeia transfusional.

Ainda que os resultados sejam promissores, persiste uma lacuna crítica em termos de validação em larga escala, padronização de métricas de desperdício, e transferibilidade entre sistemas de saúde. Como apontado por Cardona et al., 2025, muitos modelos permanecem em fase de piloto e faltam estudos prospectivos de impacto real.

Além disso, muitos estudos carecem de dados de infraestrutura tecnológicas, interoperabilidade, governança de dados e estratégias de implementação real. Douaioui et al., 2025, ressaltam que os desafios de ‘qualidade de dados’ e ‘explicabilidade dos modelos’ são barreiras importantes à adoção.

Finalmente, há necessidade de contextualização regional, especialmente para o Brasil e para redes como a Fundação de Saúde Parreiras Horta / Serviço de Verificação de Óbito de Sergipe / LACEN Sergipe para que o modelo seja adaptado à realidade local — o que reforça a relevância metodológica e social do nosso artigo.

A integração dos resultados dos estudos revisados revela um panorama consistente segundo o qual modelos preditivos baseados em inteligência artificial podem transformar a gestão hemoterápica ao reduzir desperdícios, aprimorar processos logísticos e ampliar a disponibilidade de hemocomponentes. Como ilustrado na Figura 3, esses mecanismos convergem para um fluxo operacional mais eficiente, no qual a previsão de demanda, a gestão de estoques e a logística transfusional passam a atuar de forma integrada e orientada por dados. As evidências apontam que a diminuição de vencimentos, a melhora da acurácia na previsão de demanda e a racionalização dos níveis de estoque fortalecem a construção de uma medicina transfusional mais inteligente e responsiva, conforme discutido em estudos asiáticos, europeus e norte-americanos publicados entre 2021 e 2025 (Ito et al., 2023; Farrington et al., 2024; Douaioui et al., 2024).

Figura 3 – Fluxo da cadeia hemoterápica otimizada por IA.



Fonte: Autoria própria (2025).

A Figura 3 sintetiza visualmente esses achados ao demonstrar a sequência operacional que conecta previsão de demanda, gestão de estoques, processos logísticos e redução de desperdício — etapas diretamente influenciadas pelos modelos de IA. Essa integração reforça o potencial dessas tecnologias para renovar práticas transfusionais, especialmente em ambientes onde os desafios de suprimento são mais críticos (Kwon et al., 2024; Feng et al., 2025).

No entanto, como destacam diversos autores, o impacto pleno dessa transformação depende da consolidação de infraestrutura de dados, interoperabilidade entre sistemas, qualificação de equipes, adoção institucional e adaptações às particularidades regionais dos bancos de sangue. Em outras palavras, embora a IA já demonstre resultados robustos, sua implementação global exige planejamento estratégico, colaboração internacional e políticas de saúde alinhadas às novas demandas tecnológicas (Cardona et al., 2025).

Apesar dos avanços apresentados nos estudos recentes, a literatura ainda revela lacunas importantes que limitam a adoção plena da inteligência artificial na gestão hemoterápica. Diversos autores destacam que a maior parte dos modelos avaliados permanece restrita a ambientes controlados ou simulações computacionais, com escassez de validações prospectivas em larga escala dentro de redes hospitalares reais (Cardona et al., 2025; Douaioui et al., 2024). Essa ausência de

implementações contínuas compromete a generalização dos resultados e dificulta a avaliação do impacto efetivo sobre o desperdício de hemocomponentes em cenários de alta complexidade clínica.

Outro ponto recorrente na literatura refere-se à insuficiência de infraestrutura tecnológica adequada para sustentar modelos preditivos avançados. Estudos asiáticos e europeus apontam desafios como a ausência de interoperabilidade entre sistemas de informação, falta de padronização nos registros transfusionais e inconsistências nas bases de dados, o que compromete o treinamento e a robustez dos algoritmos (Ito et al., 2023; Kwon et al., 2024). Essas limitações tornam o processo de integração da IA aos bancos de sangue dependente de investimentos em governança de dados, qualificação profissional e políticas institucionais de digitalização.

Além disso, há barreiras éticas e regulatórias que precisam ser abordadas para garantir que os modelos operem de forma transparente e segura. Pesquisadores ressaltam que algoritmos de machine learning e deep learning, especialmente aqueles com maior opacidade decisória, exigem protocolos rigorosos de auditoria, explicabilidade e supervisão clínica para evitar erros de previsão que possam comprometer a segurança transfusional (Farrington et al., 2024).

Do ponto de vista metodológico, permanece a necessidade de estudos que comparem diretamente diferentes abordagens preditivas, avaliando custo-efetividade, estabilidade temporal e impacto clínico real. A literatura ainda carece de métricas padronizadas para mensurar desperdício e eficiência logística, dificultando a comparação entre modelos desenvolvidos em países com perfis epidemiológicos distintos. Da mesma forma, autores defendem a urgência de análises multicêntricas que avaliem a performance dos modelos em regiões de baixa renda ou com cadeias hemoterápicas fragmentadas, reforçando a importância de abordagens adaptativas e sensíveis ao contexto local (Li et al., 2023; Feng et al., 2025).

No horizonte futuro, a convergência entre IA, banco de dados clínicos avançados, sistemas de prontuário integrado e sensores de monitoramento logístico aponta para a possibilidade de cadeias hemoterápicas autogeridas, capazes de antecipar demandas populacionais, redistribuir estoques regionalmente e reduzir desperdício em tempo real. Entretanto, para que esse cenário se concretize, a literatura indica que será necessário fortalecer colaborações internacionais, criar ambientes de teste multicêntricos e desenvolver modelos que considerem desigualdades estruturais entre países com diferentes níveis de maturidade tecnológica (Cardona et al., 2025; Ito et al., 2023).

4. Considerações Finais

A síntese das evidências analisadas demonstra que a inteligência artificial se consolida como um dos pilares emergentes para a modernização da gestão hemoterápica, oferecendo soluções concretas para desafios históricos relacionados ao desperdício de hemocomponentes, à imprevisibilidade da demanda e à fragilidade dos processos logísticos. Estudos recentes mostram que modelos preditivos baseados em séries temporais, machine learning e deep learning alcançam níveis elevados de acurácia, possibilitando ajustes contínuos no planejamento transfusional e contribuindo diretamente para a redução de perdas, especialmente no caso das plaquetas, cuja curta validade torna o gerenciamento ainda mais sensível.

Os resultados indicam que, quando incorporados a sistemas de estoque e fluxos logísticos, tais modelos promovem ganhos operacionais substanciais, reduzindo a probabilidade de expiração de unidades, aprimorando a distribuição entre hospitais e ampliando a segurança transfusional, como evidenciado em estudos conduzidos no Japão, Coreia do Sul, Europa e América do Norte. Isso reforça a ideia de que a IA não apenas aprimora previsões, mas reconfigura a lógica estrutural da cadeia do sangue, transformando-a em um sistema mais inteligente, responsivo e eficiente.

Entretanto, apesar dos avanços promissores, a consolidação dessa tecnologia depende de condições estruturais ainda desiguais entre países e instituições. A literatura ressalta que a falta de padronização de dados, a fragmentação de sistemas informacionais, a escassez de validações prospectivas e a carência de infraestrutura digital permanecem como barreiras

significativas à implementação plena da IA nos bancos de sangue. Isso evidencia que a próxima década exige investimentos estratégicos em governança de dados, interoperabilidade e formação de equipes qualificadas para interpretar e supervisionar modelos preditivos complexos.

Em um cenário global marcado por crises sanitárias, crescimento populacional e aumento da demanda transfusional, os resultados apresentados nesta revisão reforçam a urgência de incorporar tecnologias inteligentes que minimizem perdas, reduzam custos e ampliem a disponibilidade de hemocomponentes.

Portanto, conclui-se que a inteligência artificial representa não apenas uma inovação tecnológica, mas uma mudança de paradigma na forma de produzir, armazenar, distribuir e utilizar hemocomponentes. Seu impacto potencial é profundo: salvar milhões de vidas por meio da otimização de processos antes marcados pela incerteza e pelo desperdício. As próximas etapas, como apontado por múltiplas evidências, envolvem fortalecer redes colaborativas, expandir estudos multicêntricos e implementar soluções inteligentes em escala, abrindo caminho para uma nova era da medicina transfusional mais segura, precisa e humana.

Referências

- Abouee-Mehrizi, H., et al. (2022). Data-driven platelet inventory management under uncertainty. *IISE Transactions on Healthcare Systems Engineering*, 12(4), 233–247.
- Agac, M. F., et al. (2025). Simulation of cloud-based blood supply chain: A system dynamics approach. *Simulation*.
- Ansari, M., et al. (2024). AI-powered logistics in transfusion supply chains: A global analysis. *Computers in Biology and Medicine*, 168.
- Ben Elmir, M., et al. (2023). Forecasting demand in blood supply chain using machine learning. *Information*, 14(1), 31.
- Caicedo-Rolon, E., et al. (2022). Modeling platelet shelf-life and logistics: Challenges in transfusion medicine. *Transfusion Medicine*, 32, 54–63.
- Cardona, P., et al. (2025). Artificial intelligence techniques in blood banks. *Acta Haematologica Polonica*, 56(4), 299–308.
- Cognasse, F., et al. (2025). Emerging challenges in transfusion safety and inventory management. *Transfusion Clinique et Biologique*.
- Douaioui, H., et al. (2024). Machine learning and deep learning models for demand forecasting in supply chain management: A critical review. *Algorithms*, 17(5), 93.
- Farrington, C., et al. (2024). Many happy returns: Machine learning to support platelet issuing and waste reduction in hospital blood banks. *arXiv preprint*.
- Feng, M.-X., et al. (2025). Platelet demand forecasting based on SARIMA model. *Transfusion and Apheresis Science*.
- Ghouri, O., et al. (2023). Real-time donor engagement using AI-driven mobile systems. *Healthcare Analytics*, 3.
- Ito, Y., et al. (2023). Evaluating inventory management policies of platelets at regional-block blood centers in Japan. *Operations Research for Health Care*, 40.
- Kwon, H., et al. (2024). Forecasting blood demand using machine learning and national statistics: A Korean approach. *Scientific Reports*, 14.
- Li, Z., et al. (2023). Forecasting demand in blood supply chain using data-driven models. *Computers & Industrial Engineering*, 183, 109281.
- Maynard, S., et al. (2024). Machine learning in transfusion medicine: A scoping review. *Transfusion Medicine Reviews*, 38, 102–119.
- Motamedi, A., et al. (2025). Enhancing platelet inventory management using predictive models: A multivariate forecast-based approach. *BMC Health Services Research*.
- Pereira, A. S., Shitsuka, D. M., Parreira, F. J., & Shitsuka, R. (2018). Metodologia da pesquisa científica. *Santa Maria: Editora da UFSM*.
- Sarvestani, S., et al. (2022). Hybrid ARIMA–ANN models for predicting RBC demand by blood group. *Journal of Ambient Intelligence and Humanized Computing*, 13, 567–579.
- Schneider, D., et al. (2024). Artificial intelligence-based forecasting of blood product usage in hospitals: A systematic evaluation. *Vox Sanguinis*, 119(3), 345–356.
- Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333–339.
- Yang, H., et al. (2023). Deep learning models for predicting transfusion requirements in surgical patients. *Journal of Medical Systems*, 47(2), 112–121.
- Wong, J., et al. (2024). Integrating AI-driven inventory optimization in national blood services: A multicenter evaluation. *Transfusion*, 64(1), 52–67.