· 综述 ·

机器学习赋能精准输血:研究进展、挑战与展望

邓江 王超杰 赵宁 吕丽萍 马平 张珂 张艳宇
(军事医学研究院,北京 100850)

摘要:输血是现代医学重要的生命支持手段,随着临床治疗对输血的需求日益增加,血液供给持续处于"血液资源供需紧张"状态,充分有效地利用血液宝贵医疗资源是血液保障中重要一环。精准预测输血需求对于优化血液管理,节约血液资源具有重要意义。传统输血决策依赖临床经验及简化评分系统,难以满足精准医疗需求。机器学习技术可整合人口统计学特征、实验室指标、手术信息及动态生理波形等多维数据构建高性能预测模型,为输血预测提供了新途径。本文系统综述了机器学习在创伤、围手术期及产科等临床场景输血预测中的应用进展。在创伤领域,机器学习已应用于早期大量输血预测、院前输血决策及儿童创伤精准预测;在围手术期领域,涵盖创伤性脑损伤、骨科、心脏大血管及肝脏外科等专科;在产科领域,模型可有效预测产后出血及剖宫产输血需求。研究表明,随机森林、梯度提升机、深度神经网络等算法在大量输血预测中受试者工作特征曲线下面积可达 0.83-0.98,在围手术期场景中可达 0.75-0.97,在产科输血预测中可达 0.80-0.89,显著优于传统评分工具。然而,当前研究普遍存在单中心回顾性设计、外部验证不足、报告规范性欠缺等局限,模型可解释性不足与临床整合困难亦制约了实际转化。未来应着力于多中心数据队列构建、多模态数据融合、前瞻性实施研究及模型与电子病历系统深度整合,推动机器学习服务于临床输血决策优化。

关键词:机器学习;输血预测;患者血液管理;临床决策支持;精准输血
中图分类号:R457.1 **文献标识码**:A **文章编号**:1004-549X(2026)7-0967-10
DOI:10.13303/j.cjbt.issn.1004-549x.2026.07.023

Machine learning-enabled precision transfusion: research progress, challenges, and prospects

DENG Jiang, WANG Chaojie, ZHAO Ning, LYU Liping, MA Ping, ZHANG Ke, ZHANG Yanyu.
Academy of Military Medical Sciences, Beijing 100850, *China.*
Co-corresponding authors: ZHANG Yanyu, Email: swgczhyy@126.com; ZHANG Ke, Email: 31522723@qq.com

Abstract: Blood transfusion is an important life-support measure in modern medicine. As clinical demand for transfusion continues to rise, blood supply remains under persistent strain, making the efficient utilization of this precious medical resource a critical component of blood management. Accurate prediction of transfusion needs is of great significance for optimizing blood resource allocation and conserving blood products. Traditional transfusion decision-making relies on clinical experience and simplified scoring systems, which are insufficient to meet the demands of precision medicine. Machine learning (ML) technology can integrate multidimensional data—including demographic characteristics, laboratory indicators, surgical information, and dynamic physiological waveforms—to construct high-performance predictive models, offering a new approach to transfusion prediction. This article systematically reviews the application progress of ML in transfusion prediction across clinical scenarios such as trauma, the perioperative period, and obstetrics. In trauma, ML has been applied to early massive transfusion prediction, prehospital transfusion decision-making, and precise prediction in pediatric trauma. In the perioperative field, applications span specialties including traumatic brain injury, orthopedic surgery, cardiovascular and major vascular surgery, and hepatic surgery. In obstetrics, models can effectively predict postpartum hemorrhage and transfusion requirements associated with cesarean section. Studies have shown that algorithms such as random forest, gradient boosting machines, and deep neural networks achieve area under the receiver operating characteristic curve (AUC) values of 0.83-0.98 in massive transfusion prediction, 0.75-0.97 in perioperative scenarios, and 0.80-0.89 in obstetric transfusion prediction—significantly outperforming traditional scoring tools. However, current studies are generally limited by single-center retrospective designs, insufficient external validation, and inadequate reporting standards; limited model interpretability and challenges in clinical integration further constrain practical translation. Future research should focus on constructing multicenter data cohorts, integrating multimodal data, conducting prospective implementation studies, and deeply

第一作者简介:邓江(1988-),男,副研究员,Email:ammsdjxm@163.com;**共同通信作者**:张艳宇,Email:swgczhyy@126.com;张珂,Email:31522723@qq.com

embedding models within electronic health record systems, thereby advancing the application of ML to optimize clinical transfusion decision-making.

Key words: machine learning(ML); transfusion prediction; patient blood management; clinical decision support; precision transfusion

输血作为现代医疗中不可或缺的生命支持手段,在创伤急救、重大手术及多种疾病治疗中发挥着挽救生命的关键作用[1-3]。然而随着我国人口老龄化的加剧以及医疗水平的提高,临床用血需求持续攀升,而血液采集量增长相对有限,血液资源日趋紧张。不当输血不仅引发感染、免疫反应及凝血功能障碍等一系列并发症,同时也可能导致患者预后不良及医疗成本增加,并使血液供应紧张的状态进一步加剧[4-6]。因此,实现精准输血、避免不必要的血液制品使用,已成为现代患者血液管理(patient blood management, PBM)体系的核心目标[7]。长期以来,临床输血决策在很大程度上依赖于医生的个人经验及简化的评分系统,如创伤领域的 ABC 评分和围手术期的最大手术备血量表(maximum surgical blood order schedule, MSBOS),然而,这些传统方法在应对个体差异与复杂临床情景时,预测准确性与个性化程度均有不足,难以满足精准医疗时代的需求[8-10]。

近年来,机器学习(machine learning, ML)技术的快速发展为破解这一难题提供了新的途径[11]。ML 模型能够从高维、异构的临床数据中自动学习并挖掘复杂的非线性关系,整合人口统计学特征、实验室指标、手术信息乃至动态生理波形等多维度信息,构建出性能远超传统统计方法的预测系统[12-14]。多项研究证实,无论是经典的逻辑回归(logistic regression, LR)、随机森林(random forest, RF)、支持向量机(support vector machine, SVM),还是前沿的梯度提升机(gradient boosting machine, GBM)与深度神经网络(deep neural network, DNN),在预测大量输血(massive transfusion, MT)需求、围术期输血风险以及特定疾病相关输血概率方面,其区分度与准确性均显著优于传统评分工具[15-18]。这种数据驱动的模式转变为临床医生提供了高度个性化的决策支持,使其能够在患者入院或术前早期识别高风险个体,从而提前干预并优化血液资源配置[19-20]。国内研究团队在该领域亦发展迅速:中南大学湘雅三医院输血科团队围绕心脏外科手术、骨折手术及肝移植手术等场景开展了一系列开创性探索[17, 21-24];解放军总医院第一医学中心输血医学科团队率先基于决策树算法建立国内首个急诊泛创伤输血预测模型,并陆续开展基于 XGBoost 的术前备血量预测及智能输血系统,共同证实机器学习模型在输血预测准确性和用血合理性上显著优于医生经验判断[25-27];军事医学研究院卫生勤务与血液研究所团队联合国内多家单位围绕创伤性脑损伤(traumatic brain injury, TBI)患者输血构建了整合多模态数据与多中心验证的输血预测模型,为国内首个全面遵循整合人工智能技术的个体预后或诊断多变量预测模型报告规范(transparent reporting of a multivariable prediction model for individual prognosis or diagnosis + artificial intelligence, TRIPOD+AI)开发的输血预测模型[28]。

本文旨在系统梳理与评述 ML 在输血预测领域的最新研究进展,重点探讨了当前研究在方法学规范、模型验证与临床转化方面面临的核心挑战,并对未来发展方向进行展望,以期为这一交叉领域的研究与实践提供参考。

1 输血预测中的 ML 基础

1.1 数据来源与特征工程

ML 模型在输血预测领域的成功,基础在于对高质量、多维度临床数据的有效挖掘与利用。当前研究所依赖的数据源极为广泛,涵盖静态基础信息与动态监测数据等多种类型。其中,人口统计学数据(如年龄、性别、身体质量指数)构成了风险评估的基础层[29-30];患者入院或术前的生理及实验室检测指标则更为核心,包括生命体征、血常规(尤其是血红蛋白与红细胞压积)、凝血功能、生化指标及血气分析等反映即时健康状态的量化数据[4, 31-33];此外,既往病史、合并症(如心脏病、糖尿病)、ASA 分级以及手术相关信息(如手术类型、预估时长、麻醉方式)亦是不可或缺的预测变量[2-3, 34-35]。近年来,研究者开始探索更具动态性的数据源,如围术期持续监测的血流动力学波形[36]。在非结构化数据的利用方面,Deng 等[28]构建的创伤性脑损伤输血预测模型,通过自动提取电子病历中的入院诊断文本、脑部 CT 影像及常规检查数据,实现了多模态数据的整合建模,并在 4 个不同来源的医疗中心完成了内部与外部验证。上述研究表明,结构化与非结构化数据的融合为捕捉动态输血需求变化提供了新的可能。

从海量原始数据中提炼出对预测任务最有价值的信息,是特征工程的核心任务,其质量在很大程度上决定了模型的性能上限。为应对高维数据带来的"维度灾难"并提升模型的泛化能力与可解释性,研究者广泛采用了多种特征选择方法,如最小绝对收缩与选择算子(least absolute shrinkage and selection operator, LASSO)回归、递归特征消除(recursive feature elimination, RFE)及 Boruta 算法等,用于筛选最具预测力的核心变量组合[17, 37-38]。与此同时,临床数据中普遍存在的类别不平衡问题(即输血事件相较于非输血事件属于少数类)也受到特别关注,通过应用合成少数类过采样技术(synthetic minority over-sampling technique, SMOTE)等方法,可有效缓解数据偏态对模型训练的负面影响,提高模型对稀有事件的识别能力[1, 34]。这些精细化的数据预处理步骤,为构建高精度、高鲁棒性的预测模型奠定了坚实基础。

1.2 常用 ML 算法

在输血预测领域,研究者探索并应用了多种 ML 算法,

从经典 LR 到前沿 DNN,形成了丰富的算法工具箱。根据结构与复杂性,这些算法大致可分为传统 ML 算法与深度学习算法 2 大类。

传统 ML 算法因理论成熟、性能稳健而得到广泛应用。LR 作为经典的广义线性模型,以其简单高效且结果可解释的特点,常被用作基准模型与其他复杂算法进行性能比较[34, 39]。在高维数据建模方面,树模型及其集成变体是该领域应用最广泛且表现最优异的一类算法。例如,RF 通过构建多棵决策树并进行集成,能有效处理复杂的非线性关系,具有较强的鲁棒性与抗过拟合能力,在多项创伤及围手术期输血预测研究中均表现卓越[15, 38, 40-43];以 GBM 为核心思想的集成学习算法,如 XGBoost、LightGBM、CatBoost 和 GBDT,则通过迭代优化弱学习器,往往能在结构化表格数据上达到最优预测精度,已成为众多高性能输血预测模型的首选[6, 12, 16-18, 22, 44-45]。

随着数据复杂性的增加,深度学习算法也逐渐应用于输血预测领域。DNN 能够通过深层结构自动学习数据中的高级抽象特征,以其中最基础的多层感知器(multi-layer perceptron, MLP)或人工神经网络(artificial neural network, ANN)为基础,尤其擅长捕捉高度复杂的非线性模式[1, 14, 46-47]。针对动态时序监测数据,如重症监护室(intensive care unit,ICU)中患者生命体征的时间序列,长短期记忆网络(long short-term memory, LSTM)凭借其独特的门控机制,能有效捕捉数据中的长期时序依赖关系,在动态风险预测中展现出独特优势[43, 48]。此外,卷积神经网络(convolutional neural network, CNN)虽以图像识别著称,但在处理一维生理波形数据(如心电图、光电容积脉搏波)方面亦显示出应用潜力[36, 49]。主流算法在输血预测领域的特点与典型应用见表 1。

表 1 输血预测中常用 ML 算法对比

Table 1 Comparison of commonly used machine learning algorithms for transfusion prediction

	代表性算法	核心特点	在输血预测中的典型应用	算法原理
传统 ML	逻辑回归(LR)	可解释性强,计算速度快,适合线性关系	作为基线模型,用于风险因素分析和构建简单评分系统[31, 34]	对特征线性加权后经 Sigmoid 函数映射为概率,通过最大似然估计求解权重
	随机森林(RF)	鲁棒性强,不易过拟合,能处理高维数据	广泛应用于创伤和围手术期输血预测,性能稳定[15, 38, 41-42]	对多棵基于随机抽样与随机特征构建的决策树结果进行投票集成,降低过拟合风险
	GBM 类模型,如 XGBoost、LightGBM、CatBoost、GBDT	预测精度高,效率优异,是当前表格数据预测的主流选择	在多项研究中取得最优性能,用于构建高精度预测模型[16-18, 45]	顺序迭代训练决策树,每棵树拟合前序模型的残差,通过加法模型逐步降低预测误差
	支持向量机(SVM)	在小样本、高维度数据上表现良好	用于特定场景下的分类任务,如部分骨科手术预测[41, 47]	寻找使类间间隔最大化的超平面,借助核函数处理非线性分类问题
深度学习	人工神经网络/多层感知器(ANN/MLP)	强大的非线性建模能力,能自动学习特征	预测复杂手术(如脊柱、心脏)的输血需求[1, 14, 46]	由多层神经元组成,经非线性激活函数变换,通过反向传播迭代更新权重以拟合数据
	长短期记忆网络(LSTM)	擅长处理时间序列数据,捕捉动态变化	用于 ICU 患者的动态输血风险评估,如 GIB 患者[43, 48]	在循环网络中引入门控机制,选择性保留或遗忘历史信息,有效捕捉长期时序依赖
	卷积神经网络(CNN)	擅长处理网格结构数据(如图像、波形)	分析生理波形数据以预测术中大出血[36]	以可学习滤波器滑动卷积提取局部特征,经池化逐层抽象后完成分类或回归任务

2 ML 在关键临床场景的输血预测应用

随着算法的成熟与数据可及性的提升,ML 已在多个临床领域得到广泛应用,并针对不同场景的独特挑战发展出各具特色的预测模型。其中,创伤、围手术期及产科是输血预测研究最为集中、进展最为显著的 3 个领域。

2.1 创伤相关输血预测:从院前到院内

创伤是导致可预防性死亡的首要原因,而失血性休克是其中的关键致死环节[50-51]。早期且准确地识别需要 MT 的患者,对于启动损伤控制性复苏、优化血液资源配置至关重要[8, 12]。ML 在此领域展现了远超传统评分系统的潜力。

2.1.1 早期 MT 预测

MT 指短时间内连续、快速输注大量血液。通常是指 24 h 内输入的血液总量等于或超出患者全身血容量,或 3 h 内的血液输注量达到患者自身血容量的 50%以上[52]。由于 MT 需求多发生在病情早期且进展迅速,识别不及时可导致休克和多器官功能障碍,引入 ML 模型整合多维临床信息,有助于更早、更精准地预测 MT 需求,从而优化输血决策、改善患者预后并提高血液资源利用效率。

无论是在资源受限的战区环境还是民用创伤中心,ML 模型均表现出卓越的预测性能。在战伤者研究中,Lammers 等[15]构建的 RF 模型预测 MT 需求时,受试者工作特征曲线下面积(area under the receiver operating characteristic curve, AUROC)高达 0.98,远超传统评分系统。在民用创伤领域,Strickland 等[8]与 Nikouline 等[12]的研究表明,集成学习模型预测创伤 MT 的 AUROC 可达 0.83,敏感性显著高于传统 ABC 或 TASH 评分。值得注意的是,即便仅能获取有限的院前信息,Nederpelt 等[53]开发的 FAIT 模型仍能对休克、MT 及大手术需求做出高精度预测,AUROC 分别为 0.89、0.86 和 0.82,证明了 AI 在早期预警中的巨大潜力。此外,部分前瞻性研究开始关注预测的动态演化。Cobler-Lichter 等[54]的 MIASurviveMTP 模型与 Meyer 等[55]的 TiME OUT 模型揭示了预测死亡率的关键生理指标会随复苏时间推移而变化,为临床动态调整治疗策略提供了数据依据。

2.1.2 院前输血决策的智能辅助

目前,ML 的价值链已延伸至院前急救环节。Avital 等[56]构建的院前评分系统不依赖任何实验室检查,仅凭现

场可及信息即可有效预测患者到达急诊后的输血需求(AUROC 0.84),为提前激活输血方案提供了可能。Feng 等[25]发现创伤部位、休克指数和血细胞比容是影响输血需求的关键因素,建立基于 XGBoost 算法模型可成为在急诊环境下辅助医生快速、准确决策输血的重要技术工具。Zadorozny 等[57]的研究则强调了院前乳酸检测对于识别传统生命体征正常的"隐匿性休克"患者的独特价值。极具代表性的 ShockMatrix 研究通过前瞻性部署,验证了机器学习模型在真实临床环境中的可行性与有效性:基于院前 9 个变量的 ML 模型预测出血复苏需求的性能与经验丰富的创伤组长相当,而将两者决策结合后,预测敏感性可进一步提升,展现了人机协同的潜在互补优势[58-59]。

2.1.3　儿童创伤的精准预测

针对生理特征独特的儿童创伤患者,ML 同样取得了重要突破。Shahi 等[60]利用深度学习模型预测儿童钝性实质脏器损伤的 MT 需求、非手术治疗失败及死亡率,AUROC 均超过 0.90,展现了深度学习处理复杂儿科数据的能力。Sullivan 等[61]开发的 TRAIN 贝叶斯信念网络模型预测儿科创伤输血需求的 AUROC 高达 0.92,且能有效处理数据缺失问题。Kim 等[62]提出的"活动性出血"算法,则从根本上修正了以往研究中单纯依赖"输血收据"作为出血结局指标所带来的系统性偏差,为更精确的模型开发奠定了方法学基础。

2.1.4　TBI 的输血预测

在 TBI 输血预测领域,研究者针对不同人群构建了系统性预测模型。针对重度 TBI 患者,基于 756 例病例的研究识别出手术治疗、颅骨骨折、失血性休克、血小板计数降低、红细胞比积降低及国际标准化比值升高 6 项独立危险因素,列线图模型 AUROC 达 0.82-0.87[63]。扩大至 3 579 例患者的研究纳入 9 项危险因素,模型 AUROC 提升至 0.92-0.93,敏感度与特异度分别为 78.0%-80.0%和 87.0%-88.8%[64]。针对单纯性 TBI,6 种 ML 算法比较显示 CatBoost 模型表现最优,AUROC 达 0.91[65]。儿童 TBI 多中心研究纳入 1 535 例患儿,识别出心率、骨折、治疗方式、血红蛋白、血小板计数、活化部分凝血活酶时间及 D-二聚体 7 项危险因素,模型 AUROC 达 0.95[66]。在方法学层面,基于多算法特征评分加权组合的特征选择方法可有效提升模型性能[67]。最新的多组学数据融合研究整合了临床生物标志物、神经影像学特征及临床文本挖掘数据,在 2 219 例多中心队列中开发的手术干预预测模型 F1 值达 0.63-0.85,输血预测模型在验证集和外部测试集的 F1 值分别为 0.78 和 0.74,预测概率与实际输血量呈显著相关[28]。这些研究表明,ML 算法能够有效整合 TBI 患者的多维临床信息,为早期识别输血需求、优化血液资源配置及改善患者预后提供决策支持。

2.2　围手术期输血预测:多专科应用

围手术期是输血需求最为集中的场景之一,涵盖骨科、心脏外科、肝脏外科等多个专科。ML 的应用旨在通过术前风险分层,实现个体化的血液管理策略。

2.2.1　骨科手术

在以高输血率著称的髋、膝关节置换术中,Huang 等[43]的研究表明,LSTM 与 RF 预测术后输血的 AUROC 达 0.83-0.84,显著优于传统 LR。其他研究采用 GBM 等算法,在全膝关节置换术输血预测中同样取得了 0.84-0.97 的优异 AUROC[41, 68]。这些模型不仅能识别高风险患者,其临床价值更体现在低风险人群的精准筛选,Kolin 等[5]的模型已被证实可用于指导取消低风险患者的常规术后血常规检查,从而节约医疗资源;Hayter 等[69]的模型甚至实现了对 ASA 1/2 级健康患者 100%的"无需输血"预测准确率,为区域手术中心的"中心-辐射"高效诊疗模式提供了数据支持。

在更为复杂的脊柱外科领域,ML 表现同样出色。针对脊柱畸形、腰椎融合等高风险手术,ANN、RF 与 XGBoost 等模型预测术中输血的 AUROC 可达 0.84-0.96[1, 4, 6, 38, 70]。然而,上述模型泛化能力问题在该领域也得到了深刻揭示,Shi 等[71]开发的用于预测脊柱转移瘤术中大出血的 XGBoost 模型,在内部及初步外部验证中表现优异(AUROC 0.81-0.86);但 de Reus 等[72]随后进行的 1 项跨越三大洲的多中心外部验证研究却发现,该模型在新数据集上表现欠佳,AUROC 仅为 0.63,提示模型可能存在过拟合或因地域、临床实践差异导致的分布偏移。这一结果提示在推广应用任何预测模型之前必须进行严格、广泛的外部验证的重要性。

2.2.2　心脏与大血管外科

心脏与大血管手术因其复杂性及体外循环的应用,是输血需求量最大的领域之一。在冠状动脉搭桥术中,Tsai 等[49]创新性地利用合成数据技术增强 DNN 训练,使预测输血需求的 AUROC 提升至 0.94。在二尖瓣、主动脉瓣等瓣膜手术中,CatBoost、LightGBM 等先进算法预测输血风险的 AUROC 普遍在 0.75-0.94[23, 31, 73]。Che 等[32]针对主动脉手术开发的模型甚至能够预测具体输血量,平均绝对误差仅为 1.17 U。1 项关键的多中心外部验证研究证实,CatBoost 与 RF 模型在不同心脏中心的泛化能力显著优于传统 LR 模型,进一步巩固了 ML 在该领域的应用价值[18]。但此类严格多中心验证在该领域仍属少数。

2.2.3　肝脏外科

肝移植及肝癌切除术常伴随难以控制的出血。多项研究表明,XGBoost 与 CatBoost 等模型能有效利用术前变量预测肝移植术中 MT 或红细胞输血需求,AUROC 可达 0.81,敏感性高达 89%[17, 22]。针对肝内胆管癌根治术,Catalano 等[74]开发了基于多因素回归的风险评分系统,为识别高危患者提供了实用工具。

2.3　产科输血预测:保障母婴安全

产后出血是全球孕产妇死亡的首要原因之一,对出血及输血风险的早期预警对保障母婴安全至关重要。在此领域,ML 模型也展现出超越传统风险评估工具的优势。多项大样本研究显示,相较于传统 LR,XGBoost、RF 及 DNN 等 ML 模型在预测输血或"产后出血—输血"复合临床场景时具有更优的判别能力(AUROC 约 0.80-0.83),且能够整合孕前、孕期、分娩期及医疗机构层面的多维特征,如分娩方

式、前置胎盘、血红蛋白及血小板水平、凝血功能指标和既往剖宫产史等关键风险因素[45, 75-76]。此外,近年来引入大语言模型(large language models,LLMs)对电子病历文本进行特征提取或直接预测,进一步突破了结构化数据的限制,在预测需要临床干预(包括输血)的产后出血方面表现出更高的准确性(AUROC 约 0.79-0.80),并兼顾模型可解释性与临床实用性[77]。Lengerich 等[9]开发的可解释 ML 模型预测与严重孕产妇发病相关的产后出血高风险患者时,AUROC(0.67)显著优于临床常用的 CMQCC 量表(0.52),灵敏度几乎为后者的 2 倍。在剖宫产这一特定场景下,基于 XGBoost 或 GBDT 模型的预测系统预测输血需求的 AUROC 稳定在 0.82-0.89,为术前精准备血与多学科团队的早期介入提供了宝贵时间窗口[45, 78]。总体而言,AI 方法通过捕捉复杂的非线性关系与高维信息,为早期识别高风险孕产妇、优化围产期输血准备和个体化干预策略提供了新的技术路径,但其临床推广仍需在不同人群和场景中进行进一步的外部验证[46, 75-77]。

3 挑战与未来方向

尽管 ML 在输血预测领域展现出显著优于传统方法的性能,但其从研究成果向临床应用的转化仍面临方法学、验证体系及临床实施等多重挑战。

3.1 方法学与验证层面的挑战

当前输血预测模型研究在方法学层面存在系统性缺陷。在汇总近年来该领域内研究后我们发现,绝大多数研究基于单中心回顾性数据开发模型,样本量有限且仅进行内部验证,严重缺乏跨地域、跨机构的外部验证。这种研究模式极易产生过度拟合,导致模型在特定数据集上表现优异,却难以适应不同临床环境。de Reus 等[72]的研究为此提供了极有说服力的证据:一个在内部验证中 AUROC>0.8 的脊柱转移瘤出血预测模型,在涵盖三大洲多家医疗中心的外部验证中性能急剧下降至 0.63,几乎丧失临床应用价值,这一案例不仅揭示了单中心模型的脆弱性,也反衬出少数开展严格多中心外部验证研究的重要价值[17-18, 79]。

另一应警惕的问题是,研究报告的规范性相对欠缺。尽管 TRIPOD+AI 声明等国际指南已对预测模型的开发与报告提出明确要求,但多数研究未遵循这些规范,导致方法学细节缺失、研究可复现性差,阻碍了领域内的知识积累与横向比较[80-81]。此外,部分模型性能评估存在片面性,多数研究过度依赖 AUROC 等区分度指标,而忽视校准度及决策曲线分析等对临床决策同样关键的评估维度[2, 82]。一个区分度良好但校准度不佳的模型,其输出的风险概率可能对临床决策产生严重误导。

除 TRIPOD+AI 规范外,预测模型研究风险偏倚评估工具(prediction model study risk of bias assessment tool, PROBAST)是输血预测模型质量评价的另一重要国际指南[83-84]。二者存在一定的定位互补:TRIPOD+AI 侧重于“如何报告”,规范预测模型的开发与呈现流程;PROBAST 则聚焦于“如何评价”,从参与者、预测因子、结局及分析 4 个领域系统评估研究的偏倚风险与适用性,其 2025 年发布的 PROBAST-AI 扩展版进一步细化了对 ML 研究的评估标准[85]。基于 PROBAST 框架审视当前输血预测研究,可识别出若干共性偏倚:单中心样本代表性不足、使用结局后变量造成数据泄露、以“实际输血”作为结局存在循环论证风险、缺乏严格外部验证等[62]。应该注意的是,绝大多数已发表研究既未明确遵循 TRIPOD+AI 报告规范,也未接受 PROBAST 系统评估,导致研究质量参差、横向比较困难。未来研究者应将双重规范作为基本要求,期刊与同行评审亦应将其纳入审稿标准,从源头提升领域研究质量。

3.2 临床转化层面的挑战

在临床转化层面,模型的可解释性不足是制约其应用的核心障碍。深度学习及复杂集成算法的决策过程在很大程度上仍是不透明的,这与临床决策要求的可追溯性和责任归属明晰性形成冲突。尽管沙普利可加性解释模型(Shapley additive explanations,SHAP)等事后解释技术已被部分研究采用以增强透明度,但这些方法仅能提供特征重要性的近似估计,无法完全揭示算法的内部逻辑[32, 37, 44]。同时,当前模型本质上基于相关性而非因果性建模,能够预测哪些患者可能需要输血,却难以阐明其病理生理机制[86]。这种“知其然而不知其所以然”的特性,在很大程度上限制了临床医生对模型预测的信任与采纳。

另一挑战在于模型与临床工作流程的集成。已有研究者尝试开发在线计算器或智能手机应用以降低使用门槛,但多数模型仍停留在离线验证阶段,尚未真正嵌入电子病历系统实现临床输血的实时决策支持[19, 71, 87-88]。如何将模型输出无缝整合至临床流程,并建立有效的人机协作模式,使算法预测与临床判断形成互补而非替代关系,仍是亟待解决的问题。在该方面,ShockMatrix 研究的发现具有启发意义:机器学习与临床医生的判断存在互补性,2 者结合可达到高于任一方单独决策的敏感性[58-59]。

3.3 伦理与隐私考量

ML 输血预测模型的开发高度依赖大规模敏感临床数据,由此引发的隐私保护、伦理审查及算法公平性问题不容忽视。在数据隐私层面,单纯的去标识化难以完全防范再识别风险,近年来发展的联邦学习、差分隐私等隐私保护技术为破解“数据孤岛”与隐私保护的矛盾提供了新思路,但在输血预测领域的应用尚处萌芽阶段。在伦理审查层面,回顾性数据研究的知情同意豁免边界、模型部署后的责任归属问题(开发者、医疗机构与临床医生之间的责任分担)尚缺乏统一规范。在算法公平性层面,当前主流模型多基于单一种族或地域人群开发,性别、年龄、损伤机制及临床实践差异均可能导致预测性能的群体异质性,前述 de Reus 等[72]在跨大洲外部验证中观察到的性能急剧下降已印证了分布偏移问题。未来研究应在模型开发阶段引入亚组公平性评估指标,并通过重加权、对抗性去偏等技术主动缓解算法偏见,确保 ML 工具能够公平服务于不同人群。

3.4 未来潜在研究方向

综合前述挑战与局限,尽管部分议题的解决路径已在前文有所论及,我们认为以下若干研究方向仍亟待重点关注与深入探索。

3.4.1 构建标准化的多中心数据队列

规范、统一标准的数据集构建是提升模型泛化能力的根本途径,这要求跨机构协作,统一数据采集标准、变量定义及结局指标,为开发具有普适性的稳健模型提供坚实基础。多模态数据融合为突破单纯依赖结构化临床变量的局限提供了可能。如同 Deng 等[28]在 TBI 研究中所展示的,整合动态生理特征、影像数据、临床文本乃至组学信息,有望构建更全面的患者风险画像。

3.4.2 推进前瞻化与外部模型验证

研究设计层面,从回顾性研究逐步过渡至前瞻性实施研究,在真实临床环境中检验模型的实际效用与安全性,应成为领域发展的重要方向。当前瞻性研究在当前阶段尚不可及时,在回顾性研究中开展严格的多中心外部验证应被视为模型发表的必备基本要求而非可选项。

3.4.3 加强通用化预测工具开发

Walczak 等[14]的研究表明,单一神经网络模型可跨越数千种手术类型进行有效预测,为广谱预测工具的开发提供了可行性依据。将经过充分验证的模型深度嵌入电子病历系统,实现风险预警与治疗决策实时支持,是推动 ML 技术落地的关键环节。只有不断降低模型的使用门槛,使其成为临床工作流中触手可及的常规工具,数据驱动的精准输血决策方能真正实现临床转化。

3.4.4 提升特殊场景下关键特征的获取能力

关键特征的临床可及性是制约输血预测模型实际应用的重要瓶颈,在院前输血等时间敏感场景中尤为突出。血红蛋白浓度、血小板计数等实验室指标作为经典输血预测因子,已积累了充分的循证医学依据,在常规住院诊疗场景中已得到有效获取;然而,在创伤急救、院前处置等紧急情境下,上述指标往往难以在黄金救治窗口内及时采集,严重削弱了模型的实时预测能力。随着相关研究的深入推进,学界逐渐形成共识:机器学习模型的训练与部署均以数据的充分可及为前提,而数据的采集质量与覆盖规模则高度依赖快速、便携的监测设备作为硬件支撑。因此,单纯优化算法层面的性能而忽视数据采集端的基础建设,将使模型的临床转化面临根本性障碍。未来研究应以院前创伤救治、极端环境输血保障等紧急应用场景为重点方向,加快推进可穿戴智能检测设备的研发与规模化落地,系统积累输血相关临床数据,从而切实提升输血预测模型在真实救治场景中的适用性与临床转化价值。

4 结论

ML 技术已在创伤 MT 预测、围手术期输血评估、产科出血预警等多个临床领域展现出优于传统方法的预测性能,为精准患者血液管理提供了新的技术路径。该领域的发展仍受制于外部验证不足、模型可解释性欠缺及临床集成障碍等问题,多数模型尚未完成从离线验证到实际应用的转化。未来研究应着力于构建多中心标准化数据队列、开展严格的外部验证与前瞻性实施研究、推动模型与电子病历系统的深度整合及新型可穿戴设备应用,使机器学习真正服务于临床输血决策的优化与患者预后的改善。

利益冲突说明/Conflict of Interests

所有作者均声明不存在利益冲突。

伦理批准及知情同意/Ethics Approval and Donor/Patient Consent

本文不涉及伦理审批和知情同意。

作者贡献/Authors' Contribution

邓江:文章撰写和修改;王超杰、赵宁、吕丽萍:资料和数据核对;马平:文献收集;张珂、张艳宇:综述研究的整体设计、框架规划和最终内容审订。

[参考文献]

[1] DE LA GARZA RAMOS R, HAMAD M K, RYVLIN J, et al. An artificial neural network model for the prediction of perioperative blood transfusion in adult spinal deformity surgery[J]. J Clin Med, 2022, 11(15):4436-4447.

[2] ZENG J, LIU L, YUAN Y, et al. Construction of a prediction model for perioperative blood transfusion in elderly hip fracture patients:a retrospective study[J]. Perioper Med (Lond), 2025, 14(1):128-141.

[3] ZANG H, HU A, XU X, et al. Development of machine learning models to predict perioperative blood transfusion in hip surgery[J]. BMC Med Inform Decis Mak, 2024, 24(1):158-176.

[4] RAMAN T, VASQUEZ-MONTES D, VARLOTTA C, et al. Decision tree-based modelling for identification of predictors of blood loss and transfusion requirement after adult spinal deformity surgery[J]. Int J Spine Surg, 2020, 14(1):87-95.

[5] KOLIN D A, LYMAN S, DELLA VALLE A G, et al. Predicting postoperative anemia and blood transfusion following total knee arthroplasty[J]. J Arthroplasty, 2023, 38(7):1262-1266.

[6] LANG F F, LIU L Y, WANG S W. Predictive modeling of perioperative blood transfusion in lumbar posterior interbody fusion using machine learning[J]. Front Physiol, 2023, 14(1):1306453.

[7] PULADI B, OOMS M, RIEG A, et al. Development of machine learning and multivariable models for predicting

blood transfusion in head and neck microvascular reconstruction for risk-stratified patient blood management [J]. Head Neck, 2023, 45(6):1389-1405.

[8] STRICKLAND M, NGUYEN A, WU S, et al. Assessment of machine learning methods to predict massive blood transfusion in trauma[J]. World J Surg, 2023, 47(10):2340-2346.

[9] LENGERICH B J, CARUANA R, PAINTER I, et al. Interpretable machine learning predicts postpartum hemorrhage with severe maternal morbidity in a lower-risk laboring obstetric population[J]. Am J Obstet Gynecol MFM, 2024, 6(8):101391-101399.

[10] SEHEULT J N, ANTO V P, FARHAT N, et al. Application of a recursive partitioning decision tree algorithm for the prediction of massive transfusion in civilian trauma:the MTPitt prediction tool[J]. Transfusion, 2019, 59(3):953-964.

[11] 杨鑫鑫, 徐士岚, 韩冰,等. 人工智能在输血医学中的应用研究进展[J]. 中国输血杂志, 2025,38(11):1502-1513.
YANG X X, XU S L, HAN B, et al. Research advances in the application of artificial intelligence in transfusion medicine[J]. Chin J Blood Transfusion, 2025,38(11):1502-1513.

[12] NIKOULINE A, FENG J, RUDZICZ F, et al. Machine learning in the prediction of massive transfusion in trauma:a retrospective analysis as a proof-of-concept[J]. Eur J Trauma Emerg Surg, 2024, 50(3):1073-1081.

[13] BENJAMIN A J, YOUNG A J, HOLCOMB J B, et al. Early prediction of massive transfusion for patients with traumatic hemorrhage:development of a multivariable machine learning model[J]. Ann Surg Open, 2023, 4(3):e314-e332.

[14] WALCZAK S, VELANOVICH V. Prediction of perioperative transfusions using an artificial neural network[J]. PLoS One, 2020, 15(2):e229450-e229461.

[15] LAMMERS D, MARENCO C, MORTE K, et al. Machine learning for military trauma:novel massive transfusion predictive models in combat zones[J]. J Surg Res, 2022, 270:369-375.

[16] LOU S S, LIU H, LU C, et al. Personalized surgical transfusion risk prediction using machine learning to guide preoperative type and screen orders[J]. Anesthesiology, 2022, 137(1):55-66.

[17] LIU L P, ZHAO Q Y, WU J, et al. Machine learning for the prediction of red blood cell transfusion in patients during or after liver transplantation surgery[J]. Front Med (Lausanne), 2021, 8:632210-632223.

[18] LI Q, LV H, CHEN Y, et al. Development and validation of a machine learning prediction model for perioperative red blood cell transfusions in cardiac surgery[J]. Int J Med Inform, 2024, 184:105343-105355.

[19] ZAPF M, FABBRI D V, ANDREWS J, et al. Development of a machine learning model to predict intraoperative transfusion and guide type and screen ordering[J]. J Clin Anesth, 2023, 91:111272-111283.

[20] FENG Y, XU Z, SUN X, et al. Machine learning for predicting preoperative red blood cell demand [J]. Transfus Med, 2021, 31(4):262-270.

[21] XIE X, HUANG Y, HUANG X, GUI R. Multi-center retrospective study of factors affecting perioperative transfusion of packed red blood cells for pelvic fracture patients[J]. Orthop Surg, 2022, 14(8):1778-1789.

[22] CHEN S, LIU L P, WANG Y J, et al. Advancing prediction of risk of intraoperative massive blood transfusion in liver transplantation with machine learning models. a multicenter retrospective study[J]. Front Neuroinform, 2022, 16:893452-893463.

[23] WANG Y, LIU L, FAN K, et al. Machine learning for the prediction of blood transfusion risk during or after mitral valve surgery:a multicenter retrospective cohort study [J]. Sci Rep, 2025, 15(1):32380-32392.

[24] HUANG X, WANG Y, CHEN B, et al. Ability of a machine learning algorithm to predict the need for perioperative red blood cells transfusion in pelvic fracture patients:a multicenter cohort study in China[J]. Front Med (Lausanne), 2021, 16(8):694733-694746.

[25] FENG Y N, XU Z H, LIU J T, SUN X L, WANG D Q, YU Y. Intelligent prediction of RBC demand in trauma patients using decision tree methods[J]. Mil Med Res, 2021, 8(1):33-46.

[26] 蔡晓谕,封彦楠,马春娅,等. 外科手术红细胞需求预测模型应用评价[J]. 中国输血杂志, 2026, 39(1):51-55.
CAI X Y, FENG Y N, MA C Y, et al. Evaluation of the application of a predictive model for red blood cell demand in surgical procedures[J]. Chin J Blood Transfusion, 2026, 39(1):51-55.

[27] 陈麟凤,冯宇,田宗梅,等. 智能输血系统应用于术中红细胞输注的效果评价[J]. 中国输血杂志, 2025, 38(11):1495-1501.
CHEN L F, FENG Y, TIAN Z M, et al. Efficacy assessment of an intelligent blood transfusion system in intraoperative red blood cell transfusion [J]. Chin J Blood Transfusion, 2025, 38(11):1495-1501.

[28] DENG J, DENG T, ZHANG Y C, et al. Interpretable multiomics models for predicting surgical interventions and blood transfusion requirements in traumatic brain in-

jury[J]. NPJ Digit Med, 2025, 8(1):693-702.
[29] DENG J, ZHOU C, XIAO F, et al. Construction of a predictive model for blood transfusion in patients undergoing total hip arthroplasty and identification of clinical heterogeneity[J]. Sci Rep, 2024, 14(1):724-741.
[30] LIANG D, PANG Y, HUANG J, et al. Predicting postoperative blood transfusion in elderly patients undergoing total hip and knee arthroplasty using machine learning models[J]. Risk Manag Healthc Policy, 2025, 21(18):1697-1711.
[31] LIU S, ZHOU R, XIA X Q, et al. Machine learning models to predict red blood cell transfusion in patients undergoing mitral valve surgery[J]. Ann Transl Med, 2021, 9(7):530-542.
[32] CHE J, YANG B, XIE Y, et al. A precise blood transfusion evaluation model for aortic surgery:a single-center retrospective study[J]. J Clin Monit Comput, 2024, 38(3):691-699.
[33] SUN Z D, FANG Y M, LIN Y L, et al. Construction and validation of a perioperative blood transfusion model for patients undergoing total hip arthroplasty with osteonecrosis of the femoral head based on machine learning[J]. Front Med (Lausanne), 2025, 11(12):1471746.
[34] PARK I, PARK J H, YOON J, et al. Assessment of machine learning classifiers for predicting intraoperative blood transfusion in non-cardiac surgery[J]. Transfus Clin Biol, 2025, 32(1):1-8.
[35] ZHANG J, JIANG L, ZHU X. A machine learning-modified novel nomogram to predict perioperative blood transfusion of total gastrectomy for gastric cancer[J]. Front Oncol, 2022, 11(12):826760-826771.
[36] KWON D, MI JUNG Y, LEE H C, et al. Non-invasive prediction of massive transfusion during surgery using intraoperative hemodynamic monitoring data[J]. J Biomed Inform, 2024, 156:104680.
[37] CHEN Y, CAI X, CAO Z, et al. Prediction of red blood cell transfusion after orthopedic surgery using an interpretable machine learning framework[J]. Front Surg, 2023, 2(10):1047558.
[38] LUO M, LEI X, DING Z, et al. Machine learning prediction for spinal deformity surgery blood transfusion[J]. World Neurosurg, 2025, 203:124468.
[39] MITTERECKER A, HOFMANN A, TRENTINO K M, et al. Machine learning-based prediction of transfusion[J]. Transfusion, 2020, 60(9):1977-1986.
[40] HUANG Z, HUANG C, XIE J, et al. Analysis of a large data set to identify predictors of blood transfusion in primary total hip and knee arthroplasty[J]. Transfusion, 2018, 58(8):1855-1862.
[41] KAHVECI M. Machine learning approaches for predicting intraoperative blood transfusion in partial hip arthroplasty[J]. J Clin Med, 2025, 14(21):7657-7671.
[42] LI M, LIN J, DU H, et al. Optimal model for predicting intraoperative blood transfusion in elective surgery patients: a comparative study of eight machine learning methods[J]. Blood Transfus, 2026, 24(2):164-171.
[43] HUANG Z, MARTIN J, HUANG Q, et al. Predicting postoperative transfusion in elective total HIP and knee arthroplasty: Comparison of different machine learning models of a case-control study[J]. Int J Surg, 2021, 96:106183.
[44] SUN Z, CUI Z, XIE Y, et al. Evaluation of the factors influencing blood transfusion during minimally invasive direct coronary artery bypass surgery[J]. Cardiology, 2025, 150(1):98-110.
[45] AHMADZIA HK, DZIENNY AC, BOPF M, et al. Machine learning models for prediction of maternal hemorrhage and transfusion: model development study[J]. JMIR Bioinform Biotechnol, 2024, 5:e52059.
[46] COHEN-LEVY W B, KLEMT C, TIRUMALA V, et al. Artificial neural networks for the prediction of transfusion rates in primary total hip arthroplasty[J]. Arch Orthop Trauma Surg, 2023, 143(3):1643-1650.
[47] CHEN X, PAN J, LI Y, et al. Application of machine learning model in predicting the likelihood of blood transfusion after hip fracture surgery[J]. Aging Clin Exp Res, 2023, 35(11):2643-2656.
[48] SHUNG D, HUANG J, CASTRO E, et al. Neural network predicts need for red blood cell transfusion for patients with acute gastrointestinal bleeding admitted to the intensive care unit[J]. Sci Rep, 2021, 11(1):8827-8841.
[49] TSAI H-T, WU J, GUPTA P, et al. Predicting blood transfusions for coronary artery bypass graft patients using deep neural networks and synthetic data[J]. Neural Comput Appl, 2026, 36:21153-21162.
[50] VALADE G, LIBERT N, MARTINAUD C, et al. Therapeutic potential of mesenchymal stromal cell-derived extracellular vesicles in the prevention of organ injuries induced by traumatic hemorrhagic shock[J]. Front Immunol, 2021,29(12):749659-74966.
[51] GAUSS T, RICHARDS JE, TORTÙ C, et al. Association of early norepinephrine administration with 24-hour mortality among patients with blunt trauma and hemorrhagic shock[J]. JAMA Netw Open, 2022, 5(10):e2234258.
[52] 中华人民共和国国家卫生健康委员会. 输血医学术语 WS/T 203—2020[S]. 2020.

National Health Commission of the People's Republic of China. Terminology of transfusion medicine WS/T 203—2020[S]. 2020.

[53] NEDERPELT C J, MOKHTARI A K, ALSER O, et al. Development of a field artificial intelligence triage tool: Confidence in the prediction of shock, transfusion, and definitive surgical therapy in patients with truncal gunshot wounds[J]. J Trauma Acute Care Surg, 2021, 90(6):1054-1060.

[54] COBLER-LICHTER M D, DELAMATER J M, COLLIE B L, et al. MIASurviveMTP:Machine learning for immediate assessment and survival prediction after massive transfusion protocol[J]. PLoS One, 2025, 20(10):e0335151.

[55] MEYER CH, NGUYEN J, ELHABR A, et al. TiME OUT: time-specific machine-learning evaluation to optimize ultramassive transfusion[J]. J Trauma Acute Care Surg, 2024, 96(3):443-454.

[56] AVITAL G, GELIKAS S, RADOMISLENSKY I, et al. A prehospital scoring system for predicting the need for emergent blood product transfusion[J]. Transfusion, 2021, 61(1):S195-S205.

[57] ZADOROZNY E V, WEIGEL T, GALVAGNO S M, et al. Identifying trigger cues for hospital blood transfusions based on ensemble of machine learning methods[J]. Int J Emerg Med, 2024, 17(1):76-82.

[58] GAUSS T, MOYER J D, COLAS C, et al. Pilot deployment of a machine-learning enhanced prediction of need for hemorrhage resuscitation after trauma-the ShockMatrix pilot study[J]. BMC Med Inform Decis Mak, 2024, 24(1):315-331.

[59] GAUSS T, JAMES A, COLAS C, et al. Comparison of machine learning and human prediction to identify trauma patients in need of hemorrhage control resuscitation (ShockMatrix study): a prospective observational study[J]. Lancet Reg Health Eur, 2025, 12(55):101340-101357.

[60] SHAHI N, SHAHI A K, PHILLIPS R, et al. Decision-making in pediatric blunt solid organ injury: A deep learning approach to predict massive transfusion, need for operative management, and mortality risk[J]. J Pediatr Surg, 2021, 56(2):379-384.

[61] SULLIVAN T M, MILESTONE Z P, TEMPEL P E, et al. Development and validation of a Bayesian belief network predicting the probability of blood transfusion after pediatric injury[J]. J Trauma Acute Care Surg, 2023, 94(2):304-311.

[62] KIM M S, SIPPEL G J, SULLIVAN T M, et al. Development of an algorithm for adjudicating actionable hemorrhage in pediatric trauma patients[J]. J Trauma Acute Care Surg, 2026, 99(3):364-372.

[63] 吴承高, 刘强, 熊伟, 等. 重度颅脑创伤患者临床输血预测模型构建[J]. 中国输血杂志, 2023, 36(11):990-994.
WU G C, LIU Q, XIONG W, et al. Construction of blood transfusion prediction model for patients with severe traumatic brain injury[J]. Chin J Blood Transfusion, 2023, 36(11):990-994.

[64] 刘威, 吴承高, 刘强, 等. 颅脑创伤患者临床输血影响因素分析及预测模型构建[J]. 临床神经外科杂志, 2024, 21(4):365-370.
LIU W, WU C G, LIU Q, et al. Influencing factors of clinical blood transfusion in patients with traumatic brain injury and construction of prediction model[J]. J Clinical Neurosurgery, 2024, 21(4):365-370.

[65] 刘威, 熊紫清, 吴承高, 等. 基于机器学习预测模型探究单纯性颅脑创伤患者临床输血的风险因素[J]. 中国输血杂志, 2024, 37(12):1358-1364.
LIU W, XIONG Z Q, WU C G, et al. Exploring the risk factors of blood transfusion in patients with isolated traumatic brain injury based on machine learning prediction models[J]. Chin J Blood Transfusion, 2024, 37(12):1358-1364.

[66] 刘威, 侯君, 唐龙泉,等. 基于多中心的儿童颅脑创伤患者临床输血影响因素分析及预测模型构建[J]. 实用医学杂志, 2025, 41(4):553-560.
LIU W, HOU J, TANG L Q, et al. Analysis of influencing factors of blood transfusion in children with traumatic brain injury and construction of prediction model: a multi-center retrospective study[J]. The J Practical Medicine, 2025, 41(4):553-560.

[67] 刘强, 曹磊, 熊伟, 等. 创伤性颅脑损伤输血预测模型的特征加权选择方法研究[J]. 中国数字医学, 2024, 19(2):84-89.
LIU Q, CAO L, XIONG W, et al. Research on feature-weighted selection method of blood transfusion prediction model for traumatic craniocerebral injury[J]. China Digital Medicine, 2024, 19(2):84-89.

[68] FAURE N, KNECHT S, TRAN P, et al. Prediction of transfusion risk after total knee arthroplasty:use of a machine learning algorithm[J]. Orthop Traumatol Surg Res, 2025, 111(1):103985-103996.

[69] HAYTER E, BADIAL V, BARTER R, et al. Predicting red blood cell transfusion for primary hip and knee arthroplasty:Designing a hub and spoke high-volume arthroplasty model[J]. J Clin Orthop Trauma, 2026, 12(64):102974-102991.

[70] LIU Q, CHEN A T, LI R, et al. Development and vali-

dation of machine learning models for intraoperative blood transfusion prediction in severe lumbar disc herniation[J]. iScience, 2024, 27(11):111106-111121.

[71] SHI X, CUI Y, WANG S, et al. Development and validation of a web-based artificial intelligence prediction model to assess massive intraoperative blood loss for metastatic spinal disease using machine learning techniques [J]. Spine J, 2024, 24(1):146-160.

[72] DE REUS D C, KUIJTEN R H, SAHA P, et al. External validation of a machine learning prediction model for massive blood loss during surgery for spinal metastases:a multi-institutional study using 880 patients[J]. Spine J, 2025, 25(7):1386-1399.

[73] ZHOU R, LI Z, LIU J, et al. Prediction of intraoperative red blood cell transfusion in valve replacement surgery:machine learning algorithm development based on non-anemic cohort[J]. Front Cardiovasc Med, 2024, 29(11):1344170.

[74] CATALANO G, ALAIMO L, ENDO Y, et al. Development and validation of a predictive risk score for blood transfusion in patients undergoing curative-intent surgery for intrahepatic cholangiocarcinoma[J]. J Surg Oncol, 2025, 131(2):242-251.

[75] LEE SW, PARK B, SEO J, et al. Development of a machine learning approach for prediction of red blood cell transfusion in patients undergoing Cesarean section at a single institution[J]. Sci Rep, 2024, 14(1):16628-16635.

[76] HONG S, LIU C, KANG X, et al. The development and validation of postpartum hemorrhage prediction models for pregnancies with placenta previa totalis based on coagulation function indexes:a retrospective cohort study[J]. BMC Pregnancy Childbirth, 2025, 25(1):925-933.

[77] WOO EG, ZIGHELBOIM I, GIFFORD T, et al. Predicting postpartum hemorrhage using clinical features extracted with large language models[J]. O&G Open, 2025, 2(5):e128-141.

[78] CHEN H, CAO B, YANG J, et al. Construction and effect evaluation of prediction model for red blood cell transfusion requirement in cesarean section based on artificial intelligence[J]. BMC Med Inform Decis Mak, 2023, 23(1):213-233.

[79] LOU S S, KUMAR S, GOSS C W, et al. Multicenter validation of a machine learning model for surgical transfusion risk at 45 us hospitals[J]. JAMA Netw Open, 2025, 8(6):e2517760.

[80] COLLINS G S, MOONS K, DHIMAN P, et al. TRIPOD+AI statement:updated guidance for reporting clinical prediction models that use regression or machine learning methods[J]. BMJ, 2024, 385:e078378-078391.

[81] EFTHIMIOU O, SEO M, CHALKOU K, et al. Developing clinical prediction models:a step-by-step guide[J]. BMJ, 2024, 386:e078276-078291.

[82] SIM J H, OH A R, KIM S, et al. Development and validation of a predictive model for transfusion in major abdominal surgery:a multicentre retrospective study[J]. Br J Anaesth, 2025, 135(3):623-631.

[83] MOONS K, WOLFF RF, RILEY RD, et al. PROBAST:A tool to assess risk of bias and applicability of prediction model studies:explanation and elaboration[J]. Ann Intern Med, 2019, 170(1):W1-W33.

[84] WOLFF RF, MOONS K, RILEY RD, et al. PROBAST:A tool to assess the risk of bias and applicability of prediction model studies[J]. Ann Intern Med, 2019, 170(1):51-58.

[85] MOONS K, DAMEN J, KAUL T, et al. PROBAST+AI:an updated quality, risk of bias, and applicability assessment tool for prediction models using regression or artificial intelligence methods[J]. BMJ, 2025, 388:e082505-082524.

[86] YANG P, YUAN J, HE J, et al. Investigating the feasibility of machine learning to guide personalized red blood cell (RBC) transfusion:analyzing the heterogeneity of RBC transfusion in septic patients with hemoglobin levels of 7-9 g/dL based on the causal forest model[J]. Front Pharmacol, 2025, 16:1615618.

[87] TUNTHANATHIP T, SAE-HENG S, OEARSAKUL T, et al. Economic impact of a machine learning-based strategy for preparation of blood products in brain tumor surgery[J]. PLoS One, 2022, 17(7):e0270916-0270932.

[88] DONG S, LI W, TANG Z R, et al. Development and validation of a novel predictive model and web calculator for evaluating transfusion risk after spinal fusion for spinal tuberculosis:a retrospective cohort study[J]. BMC Musculoskelet Disord, 2021, 22(1):825-833.

(2026-03-04 收稿,05-11 修回,06-27 接收)

本文编辑:闻欣