· 论著 ·

弱季节性视角下的采供血需求预测方法论

——从竞争模型到归因范式的探讨

苏武锦 陈楠

(南宁中心血站,广西 南宁 530007)

摘要:目的 通过以经典时间序列模型 ARIMA 模型为基线,研究 1 套适用于弱季节性场景下的方法框架,将血液需求预测中的单纯模型精度比较转向具解释力的归因预测,为采供血垂类模型提供参考方案。**方法** 收集南宁地区 2018 年 1 月—2025 年 12 月的月度临床红细胞需求记录作为模型训练数据。通过 STL 分解计算季节强度指数,采用 ADF 与 KPSS 检验联合判定序列的平稳性,然后分别构建 ARIMA、SARIMA、Holt-Winters、ARIMAX 及 ARIMA-XGBoost 混合模型,从模型结构、预测误差与业务解释力 3 个维度进行比较分析;采用动态时间规整(DTW)距离度量结合 K-means 对各年度月度序列进行形态聚类,分析弱季节性的年度差异,提出血液需求预测的方法论原则。**结果** SARIMA 自动定阶为 ARIMA(4,1,0),Holt-Winters 季节平滑系数 $\gamma=1.00$,季节强度指数 $F_S=0.18$,3 项检验均认为该序列为弱季节性时间序列。DTW-KMeans 聚类($k=3$)显示 2020—2022 年归为低值模式簇(年均约 27 002.3 U),2018 年与 2023 年归为中值模式簇(年均约 38 755 U),2019 年与 2024—2025 年归为高值模式簇(年均约 44 284 U),说明弱季节性源于不同阶段的临床用血需求发生了变化。样本外预测验证中,ARIMAX 模型表现最优,显著优于 ARIMA((DM 检验 $P=0.011$);时间序列交叉验证证实 ARIMAX 在最近两折中 RMSE、MAE、MAPE 3 项指标均最优,平均 RMSE(8 954.46±3 530.61)和 MAPE(18.75%±6.83%)标准差最小。ARIMA-XGBoost 混合模型未表现出实质性精度提升(RMSE=10 802.20,MAPE=21.99%),劣于纯 ARIMA 模型。**结论** 数据序列呈现弱季节性波动,同时存在阶段性结构变化的场景下,融合业务解释变量的回归时序模型(ARIMAX)更具鲁棒性与管理价值的预测范式,提示血液需求预测应先验验证季节性假设、优先编码业务知识为外生变量、谨慎评估机器学习混合模型的适用边界。

关键词:竞争模型;需求预测;弱季节性;方法论;ARIMAX;DTW 聚类;归因范式

中图分类号:R457 R193 **文献标识码:**A **文章编号:**1004-549X(2026)8-1067-07

DOI:10.13303/j.cjbt.issn.1004-549x.2026.08.011

Weak seasonality perspective on blood collection and supply demand forecasting methodology: from model competition to attribution paradigm

SU Wujin, CHEN Nan.

Nanning Blood Center, Nanning 530007, *China*

Abstract: Objective To develop a forecasting framework suitable for weak-seasonality time series using the classical autoregressive integrated moving average (ARIMA) model as the baseline. Rather than focusing exclusively on predictive accuracy, we propose an interpretive, attribution-oriented approach to blood demand forecasting that emphasizes explanatory power over pure precision. The aim is to provide a domain-specific modeling reference for the blood collection and supply sector. **Methods** Monthly clinical red blood cell (RBC) demand data from Nanning, China (January 2018-December 2025) were collected. Seasonal strength was assessed by STL decomposition; stationarity was tested using ADF and KPSS procedures. ARIMA, seasonal ARIMA (SARIMA), Holt-Winters, ARIMAX, and a hybrid ARIMA-XGBoost model were built and compared in terms of model structure, forecast error, and operational interpretability. Annual monthly series were further subjected to DTW-based K-means morphological clustering to examine inter-annual variation under weak seasonality. **Results** SARIMA auto-selection resulted in an ARIMA(4,1,0) specification. The Holt-Winters seasonal smoothing parameter γ was 1.00, and the seasonal strength index (F_S) was 0.18, confirming weak seasonality. DTW-KMeans clustering ($k=3$) identified three phases: a low-demand cluster (2020-2022, annual mean≈27 002.3 U), a medium-demand cluster

基金项目:广西壮族自治区卫生健康委员会自筹经费科研课题(Z-A20251073)

第一作者简介:苏武锦(1980-),男,副主任技师,Email:35893139@qq.com

(2018 and 2023, annual mean≈38 755 U), and a high-demand cluster (2019 and 2024-2025, annual mean≈44 284 U), suggesting that weak seasonality mainly reflects shifting clinical demand patterns across different stages. In out-of-sample validation, ARIMAX achieved the best performance (RMSE=8 374.88; MAE=6 669.88; MAPE=14.31%), significantly outperforming ARIMA (Diebold-Mariano test $P=0.011$). Time series cross-validation further confirmed that ARIMAX performed best in the last two folds, with the smallest standard deviations in RMSE (8,954.46±3,530.61) and MAPE (18.75%±6.83%), indicating superior predictive stability. The ARIMA-XGBoost hybrid showed no meaningful improvement (RMSE=10,802.20; MAPE=21.99%) and performed worse than standalone ARIMA. **Conclusion** For weakly seasonal blood demand series with structural change, ARIMAX—which explicitly incorporates explanatory variables—offers better stability and practical relevance than purely data-driven or hybrid machine learning alternatives. We recommend that blood demand forecasts test seasonal assumptions before model selection, encode domain knowledge as exogenous inputs where possible, and critically assess whether machine learning hybrids are warranted in low-seasonality settings.

Key words: model competition; demand forecasting; weak seasonality; methodology; ARIMAX; DTW clustering; attribution paradigm

血站血液供应和临床需求量受各种外部环境及献血政策的共同影响,呈现不规则和非线性特征,因此与一般商品需求预测不同,血液临床需求预测面临多重约束:一是血液供应受献血者行为影响波动性大;二是临床用血受诊疗模式、公共卫生事件、节假日安排等多重因素影响;三是血液不能长期储存,短缺会危及患者,过剩又会造成资源浪费,库存平衡很难把握。

ARIMA 作为时间序列研究中最重要的建模方法之一,近年来常被应用于临床用血需求预测研究[1-5]。这类研究通常隐含 1 个核心假设:血液需求遵循稳定的日历周期,如春季用血多、秋季用血少,或寒暑假用血下降、开学后回升。随着诊疗模式变革、分级诊疗推进、突发公共卫生事件频发,临床用血模式并不一定具备有稳定的周期性特征。如新冠疫情影响,导致择期手术暂停、门诊量压缩、献血招募方式改变。在这现实背景下,季节性是否存在应作为先验检验的前提假设,而不是默认成立的假设。

与此同时,面对数据的严重异变,研究者通常是利用 MA(1)模型对去除趋势性和季节周期性的序列进行拟合分析,然后完善修正 MA(1)预测模型,降低预测偏差。或者使用若干候选模型对同一数据集进行比较分析,以预测误差大小选出最优模型,较少关注模型假设是否成立、误差来源是否可解释、以及模型是否适配数据生成过程的特征。这种范式我们称之为竞争模型(model competition)[6]。

因此,我们尝试通过真实数据的建模来探讨 1 个更深层次的方法论问题:在临床用血需求预测中,当经典模型的核心假设不再成立时,如何根据数据本身的特征来选择模型。我们通过系统比较 5 种代表性模型的表现,并引入 DTW 与 K-means 相结合的年度序列聚类分析,从年度异质性的角度对弱季节性内在结构的理解,现报告如下。

1 资料与方法

1.1 数据来源

研究数据来源于南宁中心血站 2018 年 1 月—2025 年 12 月的月度临床红细胞使用量记录,共 96 条观测值,经清洗后无缺失值与极端异常值。原始数据中标注 6 个节假日事件哑变量(SF“春节”、SY3“三月三节”、QM“清明节”、LD“劳动节”、MAF“中秋节”、ND“国庆节”)。

1.2 方法

1.2.1 季节性诊断

从季节性诊断、年度聚类分析、模型构建与评估 3 个维度系统分析临床红细胞需求量时间序列特征。1)STL 分解与季节强度指数:使用基于局部加权回归的趋势-季节分解法(seasonal and trend decomposition using loess, STL)将序列分解为趋势 T、季节 S、余项 R 3 个分量,计算季节强度指数。$Fs=1-Var(R)/Var(S+R)$,F_S 越接近 1 表示季节性越强,通常 $Fs<0.333$ 为弱季节性,$0.333\leqslant Fs<0.666$ 为中等季节性,$Fs\geqslant 0.666$ 为强季节性。2)SARIMA 自动定阶:使用 auto.arima 函数(seasonal=TRUE),如果自动定阶结果为(p,d,q)$(0,0,0)_{12}$,则表明季节分量未被纳入模型,间接验证季节性不强,即是弱季节性。3)Holt-Winters 季节平滑系数:拟合加法 Holt-Winters 模型,观察季节平滑系数 γ,若 $\gamma\approx 0$ 说明模型倾向于不更新季节分量;

若 γ=1.00 则表明季节成分每月被完全重置,年度季节模式存在不稳定性。

1.2.2 DTW-KMeans 时间序列聚类分析

为识别全局弱季节性掩盖下的年度形态异质性,采用动态时间规整距离结合 K-means 的聚类方法。1)DTW 距离计算:计算南宁中心血站 2018 年 1 月—2025 年 12 月的月度临床红细胞需求量的两两序列间 DTW 距离。2)K-means 聚类:以动态时间规整(dynamic time warping, DTW)距离矩阵作为 K-means 算法的输入特征空间,设置聚类数 k=3,通过 nstart=25 的多次随机初始化确保结果稳定性。聚类结果用于识别年度需求模式的异质性。3)聚类有效性分析:计算各簇的平均时间序列、标准差及年均值统计量,评估聚类结果的可解释性。

1.2.3 基准模型:ARIMA 与 SARIMA

自回归移动平均模型(autoregressive integrated moving average, ARIMA)与季节性自回归移动平均模型(seasonal autoregressive integrated moving average, SARIMA)作为基准模型,ARIMA 模型采用 auto. arima 自动定阶,以 AICc 为准则选择最优阶数。SARIMA 模型同样使用 auto. arima,设置 seasonal=TRUE。

1.2.4 外生变量模型:ARIMAX

在 ARIMA 误差结构基础上引入 6 个外生哑变量,ARIMAX 模型形式为:$y_t = \beta X_t + \varepsilon_t$, $\varepsilon_t \sim ARIMA(4,1,0)$。其中 Xt 为节假日事件哑变量向量,β 为相应的回归系数。

1.2.5 Holt-Winters 季节性指数平滑

采用加法 Holt-Winters 模型,其水平方程、趋势方程、季节性方程及预测方程按标准公式设定。

1.2.6 混合模型:ARIMA-XGBoost

使用 ARIMA(4,1,0)拟合序列并提取残差;以残差为学习目标,极端梯度提升树(extreme gradient boosting, XGBoost)输入特征含月份、年份、时间索引、ARIMA 拟合值、lag1-lag3 及滚动均值。混合模型预测值=ARIMA 预测值+XGBoost 残差预测值。

1.2.7 模型评估指标

平均误差(ME)、均方根误差(RMSE)、平均绝对误差(MAE)和平均绝对百分比误差(MAPE)4 个指标综合评价。

1.2.8 统计学分析

所有分析在 R4.5.0 环境中进行,使用的主要 R 包包括:readxl、dplyr、lubridate、zoo forecast、tseries、dtw、xgboost、caret、rsample、ggplot2、reshape2、RColorBrewer、gridExtra、viridis、stats、base、graphics。模型残差使用 Ljung-Box 进行检验,不同预测模型误差对比使用 Diebold-Mariano 检验,以 $P<0.05$ 为具有统计学意义。

2 结果

2.1 季节性诊断结果

1)平稳性检验:时间序列非平稳,一阶差分后序列达到平稳,见表 1。2)季节强度指数:STL 分解得 $F_S=0.18<0.333$,定量确认为弱季节性。3)SARIMA 自动定阶:auto. arima 自动定阶结果为 ARIMA$(4,1,0)(0,0,0)_{12}$,即季节性参数完全退化。4)Holt-Winters 季节平滑系数:拟合加法 Holt-Winters 模型,得水平分量 α=0.49,趋势分量 β=0.00,季节分量 γ=1.00。γ=1.00 说明模型无法积累跨年度稳定季节信息,每月季节成分均被最新观测完全重置,与 STL 分解($F_S=0.18$)和 SARIMA 自动定阶的结论一致。

表 1 平稳性检验结果

Table 1 Results of stationarity tests

	统计量	*P*	结论
ADF(原始系列)	−1.151	0.909	非平稳
KPSS(原始系列)	0.399	0.078	平稳
ADF(一阶差分)		<0.010	平稳
KPSS(一阶差分)		>0.100	平稳

2.2 DTW-KMeans 聚类

1)簇 2(低值模式):2020 年(26 426 U)、2021 年(28 485 U)、2022 年(26 096 U),整体位于较低水平,反映疫情期间临床用血持续低位运行。2)簇 1(中值模式):2018 年(40 022 U)、2023 年(37 488 U),对应诊疗秩序相对稳定或逐步恢复的过渡期。3)簇 3(高值模式):2019 年(43 046 U)、2024 年(43 376 U)、2025 年(46 430 U),用血量显著回升形成新稳态。2018—2025 年月度红细胞需求量时间序列见图 1,年度时间序列 DTW 距离矩阵见图 2,各簇平均时间序列,见图 3。

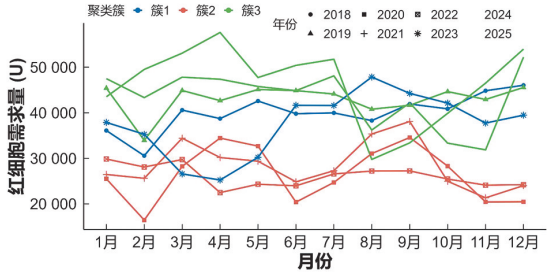


图 1 2018—2025 年月度红细胞需求量时间序列

Figure 1 Monthly red blood cell demand time series from 2018 to 2025

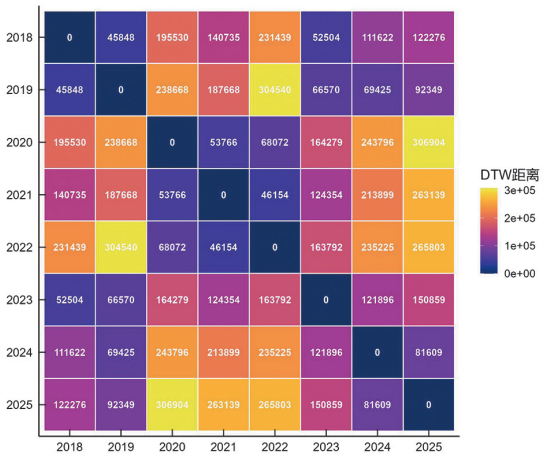


图 2　年度时间序列 DTW 距离矩阵

Figure 2　DTW distance matrix of annual time series

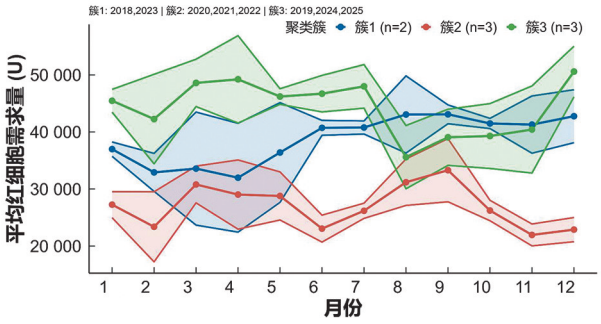


图 3　各簇平均时间序列

Figure 3　Average time series of each cluster

2.3　模型拟合效能对比

1)残差诊断:ARIMA、SARIMA、ARIMAX 的残差均通过了白噪声检验(均为 $P>0.05$),Holt-Winters 模型的残差存在显著自相关($P=0.003$,见表 2。2)训练集误差:ARIMAX 在 RMSE 与 MAE 上均最优,见表 3。3)样本外预测误差及 DM 检验:以 2025 年全年 12 个月作为独立测试集,ARIMAX 在 RMSE 与 MAPE 2 项指标上表现最优,预测误差差异在 $\alpha=0.05$ 水平上具有统计学显著性($P=0.011$),见表 4、表 5。4)时间序列交叉验证:ARIMAX 在最近的两折(第 4、5 折)表现更好,在 RMSE、MAE 和 MAPE 3 项指标上均表现最优,且标准差相对较小,表明其预测稳定性较好。SARIMA 次之,Holt-Winters 表现最差,见表 6。

表 2　模型残差 Ljung-Box 检验结果

Table 2　Results of the Ljung-Box test for model residuals

	Q 统计量	自由度	P	结论
ARIMA	13.52	13	0.409	白噪声
SARIMA	13.52	13	0.409	白噪声
ARIMAX	13.29	13	0.426	白噪声
Holt-Winters	32.61	14	0.003	非白噪声

2.4　外生变量的解释力

ARIMAX 模型中 6 个外生变量的系数估计及显著性揭示了节假日是导致血液需求产生非平稳、跳跃性变化的关键驱动因素,见表 7。

表 3　不同预测模型训练集误差对比

Table 3　Comparison of training set errors among different prediction models

	结构	ME	RMSE	MAE	MAPE(%)
ARIMA	(4,1,0)	187.39	5 449.44	3 887.45	12.05
SARIMA	$(4,1,0)(0,0,0)_{12}$	187.39	5 449.44	3 887.45	12.05
Holt-Winters	加法				
ARIMAX	(4,1,0)+xreg	2 226.4	4 754.46	3 245.99	10.02

注:Holt-Winters 模型因残差非白噪声($P=0.003$),其训练集误差不作为可靠参考。

表 4　样本外预测误差对比(2025 年测试集)

Table 4　Comparison of out-of-sample prediction errors (2025 test set)

	ME	RMSE	MAE	MAPE(%)
ARIMA	3 176.92	9 230.69	7 921.61	17.50
SARIMA	3 176.92	9 230.69	7 921.61	17.50
ARIMAX	3 908.92	8 374.88	6 669.88	14.31
Holt-Winters	−2 739.13	9 273.36	6 387.12	16.74
ARIMA-XGBoost	−7 116.95	10 802.20	8 480.30	21.99

表 5　Diebold-Mariano 检验结果

Table 5　Results of the Diebold-Mariano test

	DM 统计量	P
ARIMAX vs ARIMA	2.534	0.011
ARIMAX vs SARIMA	2.534	0.011
ARIMAX vs Holt-Winters	−0.748	0.455
ARIMAX vs ARIMA-XGBoost	−0.798	0.425

表 6　时间序列交叉验证结果

Table 6　Results of time series cross-validation

		模型	RMSE	MAE	MAPE(%)
Fold	3	ARIMA	4 033.82	3 273.65	11.37
	3	SARIMA	3 901.47	3 380.68	12.22
	3	ARIMAX	5 498.24	3 665.13	12.52
	3	Holt-Winters	6 772.71	4 740.94	15.81
	4	ARIMA	14 058.22	13 017.28	29.33
	4	SARIMA	12 920.46	11 971.79	26.90
	4	ARIMAX	12 555.03	11 558.59	26.05
	4	Holt-Winters	13 095.08	12 041.74	27.19
	5	ARIMA	9 600.36	8 775.49	20.02
	5	SARIMA	9 076.99	7 985.59	19.22
	5	ARIMAX	8 810.11	7 856.42	17.68
	5	Holt-Winters	10 524.02	8 822.42	18.92
	平均	ARIMA	9 230.80±5 022.41	8 355.47±4 885.38	20.24±8.98
	平均	SARIMA	8 632.97±4 525.86	7 779.35±4 299.26	19.45±7.34
	平均	ARIMAX	8 954.46±3 530.61	7 693.38±3 949.26	18.75±6.83
	平均	Holt-Winters	10 130.60±3 179.49	8 535.03±3 658.87	20.64±5.88

注:第 1、2 折因训练集长度不足 48 个月而被跳过。

表 7 ARIMAX 模型外生变量系数估计

Table 7 Estimates of exogenous variable coefficients in the ARIMAX model

	含义	系数	标准误	Z	*P*
SF	春节	-5 096.01	1 297.68	-3.927	<0.001
SY3	三月三节	-3 208.96	1 618.98	-1.982	0.047
QM	清明节	-730.93	1 422.39	-0.514	0.607
LD	劳动节	1 192.90	1 467.25	0.813	0.416
MAF	中秋节	-139.09	1 526.87	-0.091	0.927
ND	国庆节	-4 281.03	1 690.11	-2.533	0.011

3 讨论

竞争模型是指多个预测模型在同一数据集上“竞争”,以误差大小选择最优模型,而很少关注模型假设是否成立或结果是否可解释。近年来,采供血需求预测或者其他领域的时间序列预测研究虽开始通过引入 LSTM、XGBoost 或 ARIMA-LSTM 混合模型来提升拟合精度,但普遍未经先验验证季节性假设是否成立,如无 STL 季节强度指数或 SARIMA 退化检验,且较少将影响观测数据的关键业务事件(如节假日、突发公卫事件)编码为外生变量参与建模[7-11]。多数依赖模型内置季节处理(如 Prophet)或直接假设强季节性,并未进行先验量化季节性强度(F_S)并据此选择模。

我们收集的数据虽然为月度序列,但是通过 STL 分解(F_S=0.18)、SARIMA 自动定阶为非季节模型、Holt-Winters 季节平滑系数(γ=1.00)3 项检验,一致认为月度序列具有弱季节性的特征。同时,DTW-KMeans 聚类分析发现,簇 2(低值模式)对应 2020—2022 年 3 年疫情,反映了疫情期间临床用血持续低位运行;簇 1(中值模式)对应 2018 年与 2023 年,用血随诊疗秩序逐步恢复但尚未达新稳态的过渡期;簇 3(高值模式)对应 2019 年与 2024—2025 年,显示用血量显著回升形成新稳态。这些结果真实反映了月度序列呈现弱季节性并非统计假象,而是反映了近几年南宁地区血液供应环境的真实变化。DTW-KMeans 聚类分析进一步提示,弱季节性的根源在于年度间存在明显的阶段性模式变化,而非年内规律的消失。

ARIMA 与 Holt-Winters 虽然都属于经典的建模方法,前者通过差分消除趋势,后者通过指数平滑追踪局部水平,但 2 者在本研究中表现出了共同的局限性,都是仅依靠历史历史数据的规律,无法分析到结构性的突变。本研究所使用的数据,其过程经历低值簇、过渡簇、高值簇 3 个阶段的转变,模型参数估计实质上对各阶段的差异进行了折中平均,这是 ARIMA(RMSE=9 230.69)和 Holt-Winters(RMSE=9 273.36)样本外预测精度偏低的重要机制原因。更重要的是,这 2 种模型都无法解释某个月份用血增多或减少的原因,预测完全依赖历史数据生成机制,当数据生成过程发生结构性变化(如长假、突发公共卫生事件)时,其捕捉新信息的能力明显下降。

基于外生变量演变出的 ARIMAX 模型,核心改进不是算法层面的创新,而是将业务知识转化为模型输入。6 个外生哑变量(SF、SY3、QM、LD、MAF、ND)是血站日常要面对的关键影响因素。把这些外生哑变量纳入模型,不是对模型复杂度进行增加,只是对信息维度进行了拓展。在样本外预测中,ARIMAX 的 RMSE(8 374.88)较 ARIMA(9 230.69)下降 9.3%,MAPE(14.31%)较 ARIMA(17.50%)下降 3.19 个百分点。同时,ARIMAX 通过外生变量系数有效揭示了春节(-5 096.01)、国庆节(-4 281.03)等节假日导致的用血量显著下降,以及劳动节(+1 192.90)的正向影响,有效捕捉了节假日引起的阶段性需求波动,而不是常规的季节性波动。

时间序列交叉验证的结果,进一步说明了在弱季节性的特征下,融合业务解释变量的回归时序模型(ARIMAX)更具鲁棒性与管理价值的预测范式。本研究采用滚动窗口交叉验证:在第 4 折(对应 2023 年下半年—2024 年初)和第 5 折(对应 2024—2025 年初)中,ARIMAX 的 RMSE(分别为 12 555.03 和 8 810.11)、MAE(分别为 11 558.59 和 7 856.42)和 MAPE(分别为 26.05%和 17.68%)均优于其他模型。从平均值来看,ARIMAX 的 RMSE 标准差(±3 530.61)和 MAPE 标准差(±6.83%)均为最小,表明其预测性能在不同时间窗口下波动最小,稳定性最好。需要指出的是,在第 3 折(对应 2022 年下半年—2023 年初)中,ARIMAX 的 RMSE(5 498.24)高于 ARIMA(4 033.82)和 SARIMA(3 901.47),这可能与该时段正处于疫情管控向恢复期过渡的阶段有关,外生变量的编码规则在该特殊时期未能完全反映实际情况。当从整体上看,ARIMAX 在近期数据上的表现优于其他模型,对于采供血机构临床用血的滚动预测实践具有重要参考意义,越靠近当前时刻的预测越可靠,符合血液库存实际管理的需求。

近年来,ARIMA+机器学习混合模型在各领域

广泛报道,其基本思路是用 ARIMA 捕捉线性结构,再用机器学习拟合残差中的非线性模式[4-5,7-11]。然而在本研究中,ARIMA-XGBoost 混合模型的 RMSE(10 802. 20)和 MAE(8 480. 30)均劣于纯 ARIMA 模型。分析其原因有三:一是残差可学习性不足,ARIMA(4,1,0)已提取序列的主要线性结构,残差序列趋近白噪声,缺乏可供 XGBoost 识别的稳定非线性模式;二是特征空间线性重叠,输入的滞后项与滚动均值与 ARIMA 的自回归结构高度重叠,未能提供增量信息;三是修正幅度有限,残差的量级远小于原始序列,即使 XGBoost 对残差做出了一定拟合,其对最终预测的修正幅度也十分有限。因此,混合模型并非万能方案,其适用性取决于 ARIMA 残差中是否还存在可学习的结构。

综上,竞争模型范式将多个模型放到同一数据集上,以预测误差大小选择最优模型的方式,其在操作上简便,但存在者至少 2 个根本性缺陷:一是忽视了模型假设与数据特征的匹配性,如果当数据为弱季节性时,强季节性假设的模型(如 SARIMA、Holt-Winters)直接套用,就无法发挥其理论优势;二是将预测简化为纯技术问题,脱离了业务知识的联系。本研究提出应倡导归因预测范式,是因为预测模型不仅能输出未来的预测值,还能够回答解释为什么某个月度用血量的升降问题、哪些因素对用血量的影响最大等。在采供血领域,未来专用预测模型的训练,需要考虑的不是 1 个黑箱数字,而是 1 个可沟通、可干预的决策支持工具,归因预测范式相比竞争模型范式,更符合实际管理需求。

本研究同样存在不少研究局限性:一是数据时间跨度有限(2018—2025 年,共 96 个月),未来需在包含疫情前稳定期更长跨度数据上验证;二是本研究所用的外生变量编码规则基于当前业务实践,若未来献血用血政策发生重大调整模型需要重新校准;三是研究对象仅仅聚焦红细胞总量,未能按血型(A、B、O、AB)或 Rh 因子进行细分,不同血型的需求模式可能存在差异,分型预测是重要的后续方向;四是预测时域为月度,尚不足以支撑血站的周度或日度库存预警与调度决策。

需要指出的是,DTW-KMeans 识别出低、中、高 3 个簇后,本研究未采用分簇建模,主要基于以下因素:一是样本量限制,每簇仅含 1-3 年(12-36 个观测),独立估计 ARIMA 类参数稳定性不足;二是在工作实际中,阶段转换(如疫后恢复)由外部事件驱动,具不确定性,硬性分段需预知分界点,而 ARIMAX 的本身优势已经可实时获取的节假日/事件外生变量动态捕捉跃迁,更具操作性;三是分簇增加模型选择与集成复杂度,对新未知阶段预测造成困难。ARIMAX 本身已可通过外生变量动态捕捉阶段性变化,结构简洁、可解释,更契合血站滚动前瞻性预测的管理实际。因此聚类是用来的揭示异质性的,是建模策略选择归因而非硬性分段。

本研究的出发点并非否定模型比较的必要性,归因预测范式与单纯的模型竞赛的本质区别在于:竞争模型试图用 1 个模型去拟合 1 条曲线,而归因范式试图用数学语言去复述业务的逻辑。在本研究中,ARIMAX 之所以优于 ARIMA-XGBoost,不是算法更高级,而是它能够地将“节假日”这一业务逻辑编码进了模型中,解释了弱季节性背后的结构性跃迁,而非仅仅拟合了历史数据的统计惯性。

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

苏武锦:研究设计、数据分析、文章撰写;陈楠:数据统计、文献查询、论文审阅。

[参考文献]

[1] 杨旭,刘舒琦,黄慧,等. ARIMA 模型的临床红细胞需求预测研究[J]. 医学新知,2025,35(11):1272-1278.
YANG X, LIU S Q, HUANG H, et al. Clinical red blood cell demand prediction based on ARIMA model [J]. New Medicine, 2025, 35(11):1272-1278.

[2] 谢淑红,张思静,严伟斌,等. 基于 ARIMA 模型的临床红细胞类血液需求预测研究[J]. 蚌埠医学院学报,2023,48(5):633-636.
XIE S H, ZHANG S J, YAN W B, et al. Research on clinical demand prediction of red blood cell blood components based on ARIMA model[J]. J Bengbu Med Coll, 2023, 48(5):633-636.

[3] 刘奇,陈红梅,罗川. 基于改进的蝗虫优化算法的红细胞供应预测方法[J]. 计算机科学,2021,48(2):224-230.
LIU Q, CHEN H M, LUO C. Red blood cell supply forecasting method based on improved grasshopper optimization algorithm[J]. Comput Sci, 2021, 48(2):224-230.

[4] 倪茹玉,胡婉,张恒川,等. ARIMA 乘积季节模型与

LSTM 神经网络模型对我国麻疹发病数预测效果的比较[J]. 现代预防医学,2023,50(1):177-182.
NI R Y, HU W, ZHANG H C, et al. Comparison of predictive effect between ARIMA multiplicative seasonal model and LSTM neural network model on the number of measles cases in China[J]. Modern Preventive Medicine, 2023, 50(1):177-182.

[5] 邱亚娟,张建平,罗佳,等. 三种时间序列模型预测红细胞类血液需求趋势效果对比[J]. 中国输血杂志,2025,38(2):257-262.
QIU Y J, ZHANG J P, LUO J, et al. Comparison of three time series models in forecasting the demand trend of red blood cells[J]. Chin J Blood Transfus, 2025, 38(2):257-262.

[6] DIEBOLD F X, MARIANO R S. Comparing predictive accuracy[J]. Journal of Business & Economic Statistics, 1995, 13(3):253-263.

[7] ZEBARI R R, ZEBARI G M, AL-ZEBARI A, et al. LSTM-XGBoost: an ensemble model for blood demand distribution forecasting-a case study in Zakho City, Kurdistan Region, Iraq[J]. Oper Res Forum, 2025, 6(1):1-22.

[8] MIRI-MOGHADDAM E, KHOSRAVI BIZHAM S, MOEZZI F Z, et al. Long-term prediction of Iranian blood product supply using LSTM: a 5-year forecast[J]. BMC Med Inform Decis Mak, 2024, 24(1):1-8.

[9] MOTAMEDI M, DAWSON J, LI N, et al. Demand forecasting for platelet usage: from univariate time series to multivariable models[J]. PLos One, 2024, 19(4):1-30.

[10] 冯晨,陈志德. 基于 XGBoost 和 LSTM 加权组合模型在销售预测的应用[J]. 计算机系统应用,2019,28(10):226-232.
FENG C, CHEN Z D. Application of weighted combination model based on XGBoost and LSTM in sales forecasting[J]. Computer Systems & Applications, 2019, 28(10):226-232.

[11] SCHAFFER A L, DOBBINS T A, PEARSON S A. Interrupted time series analysis using autoregressive integrated moving average (ARIMA) models: a guide for evaluating large-scale health interventions[J]. BMC Med Res Methodol, 2021, 21(1):1-12.

(2026-07-07 收稿,07-20 修回,07-25 接收)

本文编辑:闻欣