

DOI: 10.19338/j.issn.1672-2019.2024.08.001

· 论 著 ·

基于机器学习方法预测妇科手术麻醉恢复时间*

蒋文琛¹, 屠骞阳²

(1. 湖南省妇幼保健院 麻醉科, 湖南 长沙 410008; 2. 湖南财政经济学院 财政金融学院, 湖南 长沙 410205)

摘要: **目的** 构建妇科手术中麻醉恢复时间预测模型并验证。**方法** 回顾性收集来自湖南省妇幼保健院2022年9月至2023年8月495例妇科手术, 数据预处理后, 构建逻辑回归(LR)模型、支持向量机(SVM)模型、多层感知器(MLP)模型、自适应提升(AdaBoost)模型、梯度提升决策树(GBDT)模型、随机森林(RF)模型、极限梯度提升(XGBoost)模型、类别提升(CatBoost)模型及引导聚集(Bagging)算法9个模型。为评估机器学习模型的预测准确性, 绘制了受试者操作特征(ROC)曲线并比较曲线下面积(AUC)。针对最佳模型, 探索各个特征在最佳模型中的重要性, 并进行十折交叉验证最佳模型的适用性和稳定性。**结果** 在495例患者中, 全身麻醉恢复时间 ≥ 2 h者为A组, 94例; < 2 h者为B组, 有401例。根据性能指标, 9个模型中最佳模型为XGBoost(AUC为0.8701)。特征重要性分析中发现拔管时间与全身麻醉恢复时间关系密切。在十折交叉验证, 该模型表现出了良好的普适性和稳定性。**结论** 利用多种数据构建的XGBoost模型, 有良好的预测表现和临床价值。

关键词: 麻醉恢复时间; 妇科手术; 机器学习

中图分类号: R614.2

Prediction of anesthesia recovery time for gynecological surgery by machine learning models*

JIANG Wenchen¹, TU Qianyang²

(1. Department of Anesthesiology, Hunan Provincial Maternal and Child Health Care Hospital, Changsha, Hunan 410008, China; 2. School of Finance and Economics, Hunan University of Finance and Economics, Changsha, Hunan 410205, China)

Abstract: **[Objective]** To construct and verify the prediction models of anesthesia recovery time during gynecological surgery. **[Methods]** All patients undergoing general anesthesia from September of 2022 to August of 2023 were collected retrospectively. After data pre-processing, using these vital sign vectors, 9 machine learning models were constructed: logistic regression (LR) Model, support vector machine (SVM) model, multilayer perceptron (MLP) model, adaptive boosting (AdaBoost) model, gradient boosting decision tree (GBDT) model, random forest (RF) model, extreme gradient boosting (XGBoost) model, categorical boosting (CatBoost) model, and bagging ensemble algorithm. The predictive accuracy was assessed by the receiver operating characteristic (ROC) curve and the area under the curve (AUC). In order to find the best model, the importance of each feature in the model was explored. Ten-fold cross-validation was conducted in the best model in order to explore the applicability and stability of the model. **[Results]** Among the 495 patients, 401 patients had a recovery time of less than 2 hours from general anesthesia and 94 patients had recovered from general anesthesia for 2 hours or more. Based on the performance metrics, the optimal model was the XGBoost model, which achieved an AUC value of 0.87. According to the importance of each feature in the model, the extubation time was the most valuable feature. Through the ten-fold cross-validation, XGBoost model showed good applicability and stability. **[Conclusion]** XGBoost model is constructed using a variety of data, which has satisfying prediction performance and clinical value.

Keywords: anesthesia recovery time; gynecological surgery; machine learning

收稿日期: 2024-03-21

* 基金项目: 湖南省卫健委科研计划课题(D202304116065)

麻醉为外科手术提供了安全保障, 麻醉技术的发展是外科技术发展的必要保证^[1]。全身麻醉是使用相关药物让患者在手术期间暂时失去意识, 麻醉医生会全程观察患者生命体征, 调整药物剂量, 保障手术顺利进行^[2]。麻醉恢复是麻醉管理的重要组成部分, 由于患者的个体差异和术中条件不同, 这一过程是复杂且不断变化的, 需在麻醉医生监测下完成。机器学习是一种计算机科学理论, 围手术期的麻醉数据是庞大而多变的, 传统的统计学方法往往不能充分利用, 随着电子病历系统的推广, 麻醉数据记录的电子化使得机器学习算法成为可能^[3]。机器学习可以通过对大数据的挖掘和分析, 建立稳定的模型, 预测其他数据集的结果^[4], 正因为这种优势, 机器学习也被越来越多的运用到了临床麻醉的工作中^[5]。传统的关于麻醉恢复的研究往往聚焦于某一项目, 如术后镇痛^[6]等, 对于麻醉恢复时间的决策帮助并不全面。本研究旨在通过回顾性分析评估妇科手术全身麻醉围术期的各项指标数据, 提高围术期安全, 加快手术运转效率, 建立预测妇科手术全身麻醉恢复时间模型。

1 资料与方法

1.1 一般资料

收集来自湖南省妇幼保健院 2022 年 9 月至 2023 年 8 月的 495 例妇科手术。纳入标准: ①妇科手术范围包括广泛子宫切除术、子宫切除术、子宫肌瘤剥除术; ②手术时长 ≥ 1 h; ③麻醉方式采用全身麻醉; ④术毕入麻醉恢复室进行麻醉恢复。排除标准: ①术前心功能Ⅲ、Ⅳ级, 肺功能检查提示重度通气功能障碍; ②术毕入麻醉恢复室后中转重症监护室; ③电子病例信息系统及电子麻醉信息系统数据缺失过多。

1.2 数据收集和预处理

所有数据均来源于湖南省妇幼保健院电子病例信息系统及电子麻醉信息系统。这些数据包括患者基本信息、术前准备数据、术中干预措施、术中监测数据、术后数据。患者的基本信息包括年龄、身高、体重等。术前准备数据包括: 基础生命体征、个人史、术前相关检查指标等。术中干预措施包括手术方式、麻醉时间、麻醉药物剂量、出入量、生命体征监测等。术后数据包括恢复时间、拔管时间、并发症等。每个患者都被视为一个独立的样本, 所有的变量都用于建模, 研

究共收集 119 个变量的数据来预测麻醉恢复时间。

笔者删除了一些无用的指标, 比如患者姓名、性别等。为了加快神经网络的收敛速度, 对所有连续指标进行了归一化处理。在所有模型中, 笔者使用单热编码方法将分类数据转换为二进制数据, 将麻醉恢复时间以 2 h 为分界转换为二进制数据。

1.3 部分特征数据的定义

全身麻醉恢复时间是从术毕麻醉结束时间到患者苏醒离开麻醉恢复室的时间。术毕患者进入麻醉恢复室, 经历拔管到苏醒的过程, 达到转出标准的患者可离开。转出标准采用 Aldrete 评分表, 评分 ≥ 9 分的患者可离开麻醉恢复室。

并发症是指麻醉恢复室内出现的苏醒延迟、术后急性高血压、寒战、发热、恶心呕吐等麻醉苏醒期并发症。

1.4 机器学习方法

本文将特征筛选后的数据集按 6 : 4 分割测试集和训练集。基于数据特征, 构建 9 种机器学习模型以预测分析妇科肿瘤患者的麻醉恢复时间, 包括逻辑回归 (logistic regression, LR) 模型、支持向量机 (support vector machine, SVM) 模型、多层感知器 (multilayer perceptron, MLP) 模型、自适应提升 (AdaBoost) 模型、梯度提升决策树 (gradient boosting decision tree, GBDT) 模型、随机森林 (random forest, RF) 模型、极限梯度提升 (XGBoost) 模型、类别提升 (CatBoost) 模型及引导聚集 (Bagging) 算法。

LR 模型可以处理线性可分问题, 通过逻辑函数 (sigmoid 函数) 将线性回归的输出值转换为概率值, 以实现分类^[7]。支持 SVM 模型通过在高维空间中构造一个最优超平面, 以最大化类别间的间隔 (即支持向量), 以实现分类^[8]。MLP 模型是一种前馈型人工神经网络, 由输入层、隐藏层和输出层组成。MLP 模型通过非线性的激活函数实现复杂函数的逼近, 采用反向传播算法, 通过调整网络参数以最小化预测误差^[9]。AdaBoost 模型通过逐次叠加多个弱分类器, 构建强分类器, 根据上一轮分类器的错误率调整样本权重, 使后续分类器更关注错分样本, 从而提高整体模型的分类性能^[10]。GBDT 模型是一种迭代的树模型, 逐步构建一系列决策树, 每棵树都对前面树的残差进行拟合, 通过梯度下降优化损失函数, 增强模型的预测精度^[11]。RF 模型是一种基于决策树的集

成学习方法，通过构建多个决策树模型，对样本和特征进行有放回抽样，并结合其预测结果进行决策^[12]。XGBoost 模型是一种高效的梯度提升框架，集成了线性模型求解器和树模型学习算法，通过优化计算效率和内存使用，具有处理速度快、支持并行计算和正则化、有效防止过拟合的特点^[13]。CatBoost 模型通过改进对类别特征的编码方式，提高模型的准确性和泛化能力^[14]。Bagging 算法通过对训练数据进行多次有放回抽样，能够有效减少模型的方差，提高预测的稳定性和准确性^[15]。

研究通过网格搜索（grid search），确定机器学习模型中最优的超参数组合。绘制模型的受试者操作特征（ROC）曲线，结合曲线下面积（AUC）、准确性（accuracy）、精确率（precision）、召回率（recall）和 F1 值评价二分类器的分类性能，据此选择最优预测模型。

1.5 统计学方法

采用 Python 3.10 进行描述性统计分析和机器学习模型构建。XGBoost 模型采用 Python XGBoost 程序实现，CatBoost 模型采用 Python CatBoost 程序实现，其他机器学习模型采用 Python scikit-learn 程序实现。数据统计分析中连续变量数据以均数±标准差（ $\bar{x} \pm s$ ）表示，组间均数比较采用 *t* 检验；分类变量数据以百分率（%）表示，组间比较采用 χ^2 检验。*P*<0.05 为差异有统计学意义。

2 结果

2.1 描述性统计

本研究一共纳入了 495 例患者，其中麻醉恢复时间≥2 h 的 94 例患者为 A 组，<2 h 的 401 例患者为 B 组。两组患者的年龄、体重、基础收缩压、淋巴细胞数、麻醉时长、拔管时间、出量等特征比较差异有统计学意义（*P*<0.05）。见表 1。

表 1 两组患者部分连续变量数据的特征比较 ($\bar{x} \pm s$)

特征变量	A 组(<i>n</i> =94)	B 组(<i>n</i> =401)	<i>t</i>	<i>P</i>	特征变量	A 组(<i>n</i> =94)	B 组(<i>n</i> =401)	<i>t</i>	<i>P</i>
年龄/岁	49.50±10.55	45.60±9.81	3.268	0.001	钾/(mmol/L)	3.37±1.54	3.34±1.67	0.167	0.868
身高/cm	153.36±23.48	153.89±27.69	-0.190	0.865	葡萄糖/(mmol/L)	4.01±2.45	3.86±2.57	0.529	0.591
体重/kg	56.26±7.93	58.30±8.37	-0.221	0.032	白蛋白/(g/L)	42.78±7.42	42.43±9.61	0.388	0.702
BMI/(kg/m ²)	22.44±4.58	22.42±5.02	0.037	0.977	尿素/(mmol/L)	4.52±1.72	4.56±1.69	-0.204	0.848
基础收缩压/mmHg	124.50±16.07	120.83±16.25	1.989	0.048	肌酐/(μmol/L)	53.90±15.43	53.34±13.55	0.324	0.747
基础舒张压/mmHg	77.56±9.69	77.91±9.56	-0.321	0.757	麻醉时长/min	221.38±81.78	195.66±71.27	2.809	0.006
基础心率/(次/min)	78.13±9.74	79.73±10.36	-1.448	0.159	出量/mL	699.73±485.82	536.48±401.98	3.024	0.003
白细胞/(×10 ⁹ /L)	5.59±1.60	5.88±1.64	-1.574	0.116	入量/mL	1909.57±649.95	1796.31±577.97	1.552	0.123
中性粒细胞/(×10 ⁹ /L)	3.45±1.36	3.53±1.42	-0.509	0.614	术中最高心率/(次/min)	80.07±11.01	78.40±9.67	1.353	0.176
淋巴细胞数/(×10 ⁹ /L)	1.58±0.53	1.75±0.55	-2.779	0.007	术中最低心率/(次/min)	58.44±9.26	58.40±7.19	0.039	0.973
血红蛋白/(g/L)	114.71±21.66	114.99±20.83	-0.115	0.910	丙泊酚/mg	1345.21±1612.95	1075.81±549.26	1.598	0.113
血小板/(×10 ⁹ /L)	245.74±76.44	252.14±66.70	-0.748	0.456	顺式阿曲库铵/mg	24.35±11.26	23.74±8.86	0.491	0.625
凝血酶原时间/s	12.07±2.04	12.24±1.36	-0.769	0.446	罗库溴铵/mg	57.82±48.27	50.67±16.96	1.416	0.160
活化部分凝血活酶时间/s	34.60±6.51	35.03±5.46	-0.593	0.555	舒芬太尼/μg	36.77±15.46	34.64±15.73	1.198	0.233
谷丙转氨酶(U/L)	18.47±23.53	14.58±11.70	1.558	0.122	瑞芬太尼/mg	1.51±0.55	1.43±0.56	1.265	0.214
谷草转氨酶(U/L)	21.46±15.99	18.42±8.25	1.877	0.076	七氟烷/mL	14.26±12.16	11.81±9.98	1.818	0.072
总胆红素(μmol/L)	9.66±5.16	9.55±6.10	0.179	0.856	拔管时间/min	73.62±20.29	45.48±15.43	12.618	<0.001

注：1 mmHg=0.133 kPa。

两组患者的并发症、心电图、肺部检查、腹部检查、手术范围、术后追加止痛药、Caprini 评分特征比较差异有统计学意义（*P*<0.05）。见表 2。

2.2 模型评价

ROC 曲线通过描绘不同阈值下的真阳性率（true positive rate, TPR）与假阳性率（false positive rate, FPR）之间的关系，评估模型的分类能力。图 1

显示了 9 个分类模型在本数据集上的 ROC 曲线。所有模型的 AUC 值均远高于 0.5，表明这些模型在本数据集上的分类能力均明显优于随机猜测。其中 XGBoost 模型的 AUC 为 0.8701，优于其他模型。

表 3 显示了模型性能指标，综合评估各模型 AUC、准确性、精确率、召回率和 F1 值，选取 XGBoost 模型预测麻醉恢复时间。

表 2 两组患者部分分类变量数据的特征比较 [n(%)]

特征变量	A 组(n=94)	B 组(n=401)	χ^2	P	特征变量	A 组(n=94)	B 组(n=401)	χ^2	P
心电图					血管活性药物				
正常	46(48.9)	245(61.1)	1.899	0.046	未应用	68(72.3)	301(75.1)	0.171	0.679
异常	33(35.1)	120(29.9)			应用	26(27.7)	100(24.9)		
肺部检查					肌松拮抗药				
正常	61(64.9)	305(76.1)	5.091	0.035	未应用	6(6.4)	44(11.0)	1.297	0.255
异常	33(35.1)	92(22.9)			应用	88(93.6)	357(89.0)		
腹部检查					术后追加止痛药				
正常	27(28.7)	110(27.4)	4.780	0.024	未应用	48(51.1)	263(65.6)	6.269	0.012
肝	23(24.5)	86(21.4)			应用	46(48.9)	138(34.4)		
肝肾	11(11.7)	18(4.5)			神经阻滞镇痛			0.652	0.419
肝胆肾囊	18(19.1)	57(14.2)			未应用	18(19.1)	95(23.7)		
ASA 分级					应用	76(80.9)	306(76.3)	0.357	0.550
Ⅰ级	0(0.0)	21(5.2)	5.828	0.120	术后镇痛泵应用				
Ⅱ级	92(97.9)	366(91.3)			未应用	20(21.3)	72(18.0)		
Ⅲ级	2(2.1)	13(3.2)			应用	74(78.7)	329(82.0)		
Ⅳ级	0(0.0)	1(0.2)			并发症			30.444	<0.001
手术类型					无	67(71.3)	370(92.3)		
开腹	12(12.8)	86(21.4)	3.783	0.151	有	27(28.7)	31(7.7)	25.178	0.001
腹腔镜	78(83.0)	296(73.8)			Caprini 评分				
阴式	4(4.3)	19(4.7)			0分	10(10.6)	82(20.4)		
手术范围					1分	37(39.4)	172(42.9)		
子宫全切	50(53.2)	166(41.4)	22.962	<0.001	2分	19(20.2)	81(20.2)		
肌瘤剔除	21(22.3)	189(47.1)			3分	8(8.5)	31(7.7)		
子宫全切+淋巴结清扫	5(5.3)	8(2.0)			4分	12(12.8)	28(7.0)		
广泛子宫全切	18(19.1)	38(9.5)			5分	4(4.3)	5(1.2)		
麻醉方法					6分	3(3.2)	0(0.0)		
全身麻醉	94(100.0)	398(99.3)	0.011	0.918	7分	1(1.1)	1(0.2)		
全身麻醉+椎管内麻醉	0(0.0)	3(0.7)			8分	0(0.0)	1(0.2)		




图 1 机器学习模型的 ROC 曲线

2.3 特征重要性分析

本研究使用 SHAP (SHapley Additive exPlanations) 方法对 XGBoost 模型的特征重要性进行分析。通过计算每个特征对预测结果的贡献，

表 3 模型性能评估表

模型	AUC	accuracy	precision	recall	F1 score
LR 模型	0.8581	0.8586	0.6389	0.6053	0.6216
SVM 模型	0.8595	0.8333	0.5714	0.5263	0.5479
MLP 模型	0.8424	0.8081	0.5000	0.6053	0.5476
AdaBoost 模型	0.8404	0.8586	0.6563	0.5526	0.6000
GBDT 模型	0.8637	0.8283	0.5500	0.5789	0.5641
RF 模型	0.8385	0.8485	0.6667	0.4211	0.5161
XGBoost 模型	0.8701	0.8687	0.7308	0.5000	0.5937
CatBoost 模型	0.8605	0.8535	0.6216	0.6053	0.6133
Bagging 算法	0.8598	0.8586	0.6563	0.5526	0.6000

量化各个特征对模型输出的影响。图 2 列示了影响麻醉恢复时间的前十大因素。拔管时间是对模型输出影响最大的特征，尿量、丙泊酚剂量、麻醉时长、高密度胆固醇等也是重要的影响因素。

2.4 模型的交叉验证

图 3 显示了 XGBoost 模型的十折交叉验证结果。模型最大 AUC 为 95.8% (95%CI: 78.4%~95.8%)，最小 AUC 为 77.2% (95%CI: 77.2%~95.8%)，总体

上保持较高的分类准确性，说明模型在处理数据集时具有较强的鲁棒性和泛化能力。




图 2 XGBoost 模型的特征重要性

3 讨论

目前国内麻醉医生资源短缺，在麻醉恢复室，一名麻醉医生往往需要同时监测数名麻醉恢复期的患者，如何高效的缓解麻醉恢复期的压力，在保障安全的同时，提高手术室医疗效率，节约成本，近年来逐渐受到医疗领域的重视。

本研究作为一项回顾性研究，构建了 9 种机器学习模型，利用围术期相关电子信息对麻醉恢复时间做出预测，并探索了各种特征在模型中的重要性，其中 XGBoost 模型为最优模型。相较于既往预测麻醉恢复时间的逻辑回归及随机森林模型，XGBoost 模型在处理复杂数据集、提升预测精度、处理缺失值和防止过拟合方面体现出优势，增强模型对妇科手术患者麻醉恢复时间的预测能力。在特征重要性方面，由于 XGBoost 模型能够处理复杂的非线性关系，因此增强了对拔管时间、尿量等变量与麻醉恢复时间之间关系的可解释性。在该模型中，拔管时间与麻醉恢复时间的相关性最为显著，这与 YANG 等^[16]对于麻醉恢复时间的研究结果一致。排在之后的影响因素分别是尿量、丙泊酚用量、麻醉时长、高密度胆固醇、术后血气分析 PaCO₂、Caprini 评分、顺式阿曲库铵用量、年龄、淋巴细胞数，这些影响因素与其他关于麻醉恢复的研究不全相同，但是其中麻醉时长是一个共同点。这为麻醉医生确定麻醉恢复时间提供

了判断依据。

在前十的影响因素当中，不仅包括术中干预因素，还包含了部分术前准备数据。这意味着麻醉苏醒虽然受术中干预的影响较大，但是患者自身情况也会在一定程度上影响恢复时间。由于患者的个体差异和术中条件不同，这一过程是复杂且不断变化的，甚至可以涉及到多系统多学科的知识，本研究对于影响因素的探讨为麻醉医生的恢复期的临床决策提供了一定的思考方向。对于手术患者的持续监测、反复评估，可以极大的保障麻醉恢复期的平稳度过，促进手术室的有效运转，避免医疗资源的浪费^[17]。

本研究存在局限性。作为回顾性研究，不能完全排除选择偏倚。用于预测模型训练的特征仅从一家医疗机构提取，收集到的数据量不可避免地会很少。笔者收集的数据只包括在湖南省妇幼保健院接受妇科手术治疗的患者，因此数据的分布有一定的地理局限性。在未来，笔者计划从多家医疗机构收集数据，并将研究扩展到其他预测任务。

综上所述，本研究利用多种数据构建机器学习模型，其中 XGBoost 模型有着良好的预测表现和临床价值。该模型综合分析多种影响因素，预测麻醉恢复时间，特征重要性排序可帮助麻醉医生优化临床决策。




图 3 XGBoost 模型十折交叉验证结果

参 考 文 献

- [1] JOHN DOYLE D, DAHABA AA, LEMANACH Y. Advances in anesthesia technology are improving patient care, but many challenges remain[J]. *BMC Anesthesiol*, 2018, 18(1): 39.
- [2] MIYAGUCHI N, TAKEUCHI K, KASHIMA H, et al. Predicting anesthetic infusion events using machine learning[J]. *Sci Rep*, 2021, 11(1): 23648.
- [3] CHAR DS, BURGART A. Machine-learning implementation in clinical anesthesia: opportunities and challenges[J]. *Anesth Analg*, 2020, 130(6): 1709-1712.
- [4] SONG YY, GAO SW, TAN WL, et al. Multiple machine learnings revealed similar predictive accuracy for prognosis of PNETs from the surveillance, epidemiology, and end result database[J]. *J Cancer*, 2018, 9(21): 3971-3978.
- [5] CONNOR CW. Artificial intelligence and machine learning in anesthesiology[J]. *Anesthesiology*, 2019, 131(6): 1346-1359.
- [6] GANDHI K, BARATTA JL, HEITZ JW, et al. Acute pain management in the postanesthesia care unit[J]. *Anesthesiol Clin*, 2012, 30(3): e1-e15.
- [7] BISONG E. Logistic regression[M]// *Building Machine Learning and Deep Learning Models on Google Cloud Platform*. Berkeley, CA: Apress, 2019: 243-250.
- [8] CERVANTES J, GARCIA-LAMONT F, RODRÍGUEZ-MAZAHUA L, et al. A comprehensive survey on support vector machine classification: applications, challenges and trends[J]. *Neurocomputing*, 2020, 408: 189-215.
- [9] TANG JX, DENG CW, HUANG GB. Extreme learning machine for multilayer perceptron[J]. *IEEE Trans Neural Netw Learn Syst*, 2016, 27(4): 809-821.
- [10] WANG WY, SUN DC. The improved AdaBoost algorithms for imbalanced data classification[J]. *Inf Sci*, 2021, 563: 358-374.
- [11] ZHANG CS, ZHANG Y, SHI XJ, et al. On incremental learning for gradient boosting decision trees[J]. *Neural Process Lett*, 2019, 50(1): 957-987.
- [12] DENISKO D, HOFFMAN MM. Classification and interaction in random forests[J]. *Proc Natl Acad Sci U S A*, 2018, 115(8): 1690-1692.
- [13] SAGI O, ROKACH L. Approximating XGBoost with an interpretable decision tree[J]. *Inf Sci*, 2021, 572: 522-542.
- [14] PROKHORENKOVA L, GUSEV G, VOROBIEV A, et al. CatBoost: unbiased boosting with categorical features[EB/OL]. 2017: arXiv: 1706.09516. <http://arxiv.org/abs/1706.09516>
- [15] LEE TH, ULLAH A, WANG R. Bootstrap aggregating and random forest[M]// *Macroeconomic Forecasting in the Era of Big Data*. Cham: Springer, 2020: 389-429.
- [16] YANG SM, LI HY, LIN ZZ, et al. Quantitative analysis of anesthesia recovery time by machine learning prediction models [J]. *Mathematics*, 2022, 10(15): 2772.
- [17] WEINBROUM AA, EKSTEIN P, EZRI T. Efficiency of the operating room suite[J]. *Am J Surg*, 2003, 185(3): 244-250.

(张咏 编辑)