

基于机器学习的 Stanford A 型主动脉夹层术后院内主要不良事件的风险预测研究

裴旺^{1,2}, 王雪², 姜文溪², 安美玉², 薛冰洁^{1,2}, 高培³, 王媛², 杜杰^{1,2}

(1. 天津医科大学生理学与病理生理学系 天津医学表观遗传学协同创新中心, 天津市 300070; 2. 首都医科大学附属北京安贞医院 北京市心肺血管疾病研究所血管生物研究室 教育部重塑相关心血管疾病重点实验室 心血管重大疾病防治协同创新中心, 北京市 100029; 3. 北京大学公共卫生学院流行病学与生物统计学系, 北京市 100191)

[关键词] Stanford A 型主动脉夹层; 机器学习; 院内主要不良事件; 预测; 模型; 列线图

[摘要] **目的** 基于临床一般变量, 使用机器学习方法构建模型, 用于预测手术治疗后的 Stanford A 型主动脉夹层(TAAD)患者院内主要不良事件(MAE)的发生风险。**方法** 纳入 2013 年 1 月至 2017 年 12 月在北京安贞医院进行手术治疗的 TAAD 患者 1 641 例, 收集患者个体特征变量、临床体征以及入院首次临床血清标志物等。结局定义为院内 MAE, 包含院内死亡、夹层后新发急性心脏衰竭、呼吸衰竭、神经系统障碍、急性肾功能衰竭、感染, 以及无计划的二次开胸。使用机器学习筛选变量后构建模型; 采用受试者工作特征曲线(ROC)分析模型预测院内 MAE 的能力; 使用净重新分类指数(NRI)和整体鉴别指数(IDI)对新模型与临床常用模型进行比较, 评价新模型在预测 TAAD 术后预后方面的改善效果; 最后建立列线图预测 TAAD 术后患者院内 MAE 发生风险。**结果** 使用机器学习筛选变量, 确定了由 D-二聚体、肌酸激酶同工酶、尿素、白细胞计数、年龄、异常心电图和手术时间组成的 TAAD 术后院内 MAE 的风险预测模型, 模型预测院内 MAE 的 ROC 曲线下面积为 0.776(95%CI 0.718~0.734, $P<0.001$)。与临床常用模型比较, 本研究构建的模型其 NRI 为 0.654(95%CI 0.540~0.750, $P<0.001$), IDI 为 0.136(95%CI 0.117~0.155, $P<0.001$), 提高了对 TAAD 术后院内 MAE 的预测能力。将模型通过列线图形式呈现, 列线图模型评分能够评估 TAAD 术后发生院内 MAE 的风险。**结论** 基于机器学习使用患者临床变量构建模型, 该模型综合评估患者个体特征变量、炎症水平、脏器受损状况以及手术情况, 对 TAAD 患者术后院内 MAE 具有预测价值。

[中图分类号] R54; R654

[文献标识码] A

Risk prediction of in-hospital major adverse events of postoperative Stanford type A aortic dissection based on machine learning

PEI Wang^{1,2}, WANG Xue², JIANG Wenxi², AN Meiyu², XUE Bingjie^{1,2}, GAO Pei³, WANG Yuan², DU Jie^{1,2}

(1. Department of Physiology and Pathophysiology of Tianjin Medical University & Collaborative Innovation Center of Tianjin for Medical Epigenetics, Tianjin 300070, China; 2. Beijing Anzhen Hospital Affiliated to Capital Medical University & Department of Vascular Biology, Beijing Institute of Heart, Lung and Blood Vessel Disease & Key Laboratory of Remodeling-related Cardiovascular Diseases, Ministry of Education & Collaborative Innovation Center for Cardiovascular Disorders, Beijing 100029, China; 3. Department of Epidemiology and Biostatistics, School of Public Health, Peking University, Beijing 100191, China)

[KEY WORDS] Stanford type A aortic dissection; machine learning; in-hospital major adverse event; predicting; model; nomogram

[ABSTRACT] **Aim** To build a model based on general clinical variables and machine learning method to predict the risk of in-hospital major adverse events (MAE) in patients with Stanford a type aortic dissection (TAAD) after surgery. **Methods** A total of 1 641 patients with TAAD who underwent surgical treatment in Beijing Anzhen Hospital from January 2013 to December 2017 were included in this study. The individual characteristic variables, clinical signs

[收稿日期] 2021-02-22

[修回日期] 2021-03-17

[基金项目] 国家自然科学基金项目(81930014)

[作者简介] 裴旺, 硕士研究生, 研究方向为心血管病因学, E-mail 为 pei wang110@126.com。通信作者杜杰, 教授, 博士生导师, 研究方向为心血管病因学, E-mail 为 jiedu@yahoo.com。

and the first clinical serum markers on admission were collected. The outcome was defined as in-hospital MAE, including in-hospital death, new acute heart failure after mezzanine, respiratory failure, nervous system disorders, acute renal failure, infection, and unplanned secondary chest opening. The model was constructed after using machine learning to screen variables. Receiver operating characteristic curve (ROC) was used to analyze the ability of the model to predict in-hospital MAE. Net reclassification index (NRI) and integrated discrimination index (IDI) were used to compare the new model with the commonly used clinical models to evaluate the improvement effect of the new model in predicting the prognosis of postoperative TAAD. Finally, the nomogram was established to predict the risk of MAE in patients after TAAD operation.

Results The risk prediction model of in-hospital MAE after TAAD operation was determined by using machine learning screening variables, which consisted of D-dimer, creatine kinase isoenzyme, urea, leukocyte count, age, abnormal electrocardiogram and operation time. The area under curve of ROC of in-hospital MAE predicted by the model was 0.776 (95%CI 0.718-0.734, $P < 0.001$). Compared with the commonly used clinical models, the NRI of our model was 0.654 (95%CI 0.540-0.750, $P < 0.001$), and the IDI was 0.136 (95%CI 0.117-0.155, $P < 0.001$), which improved the predictive ability for in-hospital MAE after TAAD operation. The model was presented in the form of nomogram, and the score of nomogram model could evaluate the risk of in-hospital MAE after TAAD operation.

Conclusions Based on machine learning, a model is constructed by using clinical variables of patients. The model can comprehensively evaluate individual characteristic variables, inflammation level, organ damage status and operation status of patients, which has predictive value for postoperative in-hospital MAE of patients with TAAD.

主动脉夹层是主动脉壁内出血引起的内膜破裂,导致主动脉壁层分离,形成真腔和假腔的一种高风险高死亡率疾病^[1]。主动脉夹层分为 Stanford A 型与 B 型,其中 Stanford A 型主动脉夹层(type A aortic dissection, TAAD)累及升主动脉,更为凶险^[2]。对于 TAAD 患者,手术是唯一的治疗方法^[3-4]。尽管手术和麻醉技术有所改善,但是经过手术治疗后,围手术期死亡率仍高达 18%^[5],并且伴发其他并发症,如急性肾功能衰竭、神经系统功能障碍等。临床需要对患者进行风险评估,识别术后院内主要不良事件(major adverse event, MAE)发生的高风险患者。

目前临床常用的是根据国际急性主动脉夹层注册队列(International Registry of Acute Aortic Dissection, IRAD)开发的死亡风险预测模型^[6]。但是该模型有一定的局限性,IRAD 预测模型包含变量为患者发病时症状体征,不包含患者病史以及能够评估各器官状态的实验室检查等。临床需要从各个方面综合评估 TAAD 患者状态,包括人口学特征、临床体征、实验室检查等。数据挖掘和机器学习通过从大型数据库中提取模式来自主获取信息^[7]。随着电子病历的普及,可以收集到有价值的患者信息,也有越来越多的研究将机器学习与医学相结合,进行诊断预测等工作^[8-11]。本研究的目的是应用机器学习算法,构建 TAAD 术后院内 MAE 的风险预测模型。

1 资料和方法

1.1 研究对象及流程

回顾性收集 2013 年 1 月至 2017 年 12 月期间于北京安贞医院确诊为 TAAD 且进行开胸手术治疗的患者 1 664 例。排除标准:15 天内手术史;外伤导致的主动脉夹层;支架或主动脉置换后吻合口漏。最终纳入 1 641 例患者。研究流程见图 1。

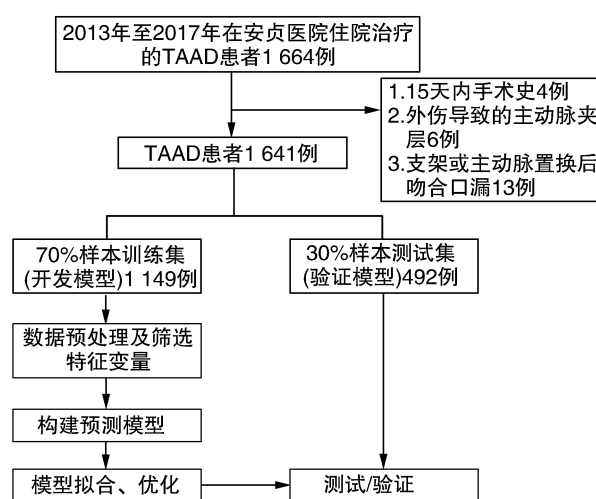


图 1. 研究流程图

Figure 1. Flow chart of research

1.2 收集资料

在本院病例管理及检验系统收集患者一般资料,包括:(1)患者个体特征资料:性别、年龄、身高、体质量、吸烟史;(2)病史:冠心病史、高血压史、糖

尿病史、高脂血症史,术前是否存在肾功能衰竭、马凡综合征、主动脉瓣二叶瓣化畸形;(3)临床表现:发病时是否伴发突发疼痛、腹痛、四肢缺血,发病时间,是否有休克、脉搏波动异常、异常心电图、心包填塞;(4)影像学检查结果:左心室射血分数、主动脉宽度;(5)手术相关指标:手术时间、主动脉阻断时间、心肺转流(cardiopulmonary bypass, CPB)时间;(6)实验室检查结果:白细胞计数、中性粒细胞计数、中性粒细胞与淋巴细胞比值(neutrophil-to-lymphocyte ratio, NLR)、单核细胞计数、红细胞计数、血红蛋白、D-二聚体、丙氨酸氨基转移酶、天冬氨酸转氨酶、尿素、尿酸、肌酐、血糖、肌酸激酶同工酶、肌钙蛋白I。院内MAE包含院内死亡、夹层后新发急性心脏衰竭、呼吸衰竭、神经系统障碍、急性肾功能衰竭、感染,以及无计划的二次开胸。

1.3 统计学处理

使用R语言4.0.2和Stata 15.1对数据进行分析。分类变量用频数和百分比表示,使用卡方检验进行组间比较。符合正态分布的计量资料用 $\bar{x} \pm s$ 表示,使用独立样本 t 检验进行组间比较;不符合正态分布的计量资料用中位数(P25%, P75%)表示,使用秩和检验进行比较。实验室检查结果将数据对

数转换后进行组间差异分析。全研究队列随机分为70%的训练集和30%的测试集。使用逐步向前法、Lasso、基于梯度提升决策树(Xgboost)算法在训练集中进行变量筛选,使用Logistic回归构建模型。在测试集采用受试者工作特征曲线(receiver operating characteristic curve, ROC)分析模型对院内MAE的预测能力,使用净重新分类指数(net reclassification index, NRI)和整体鉴别指数(integrated discrimination index, IDI)与传统模型进行增量比较分析,使用Logistic回归分析变量与院内MAE风险的关系,使用R语言进行列线图模型建立。所有 P 值均为双侧检验, $P < 0.05$ 被认为差异具有统计学意义。

2 结果

2.1 一般临床资料

随机抽样按照训练集和测试集对患者分组,进行基线数据描述(表1)。可以看出训练集与测试集患者基线数据无较大差异,院内MAE发生率也相近(26.2%比25.4%, $P = 0.738$)。两组患者分布相近,构造模型有较强的可信度。

表1. 研究人群基线数据
Table 1. Baseline data of the study population

项目	训练集($n=1\ 149$)	测试集($n=492$)	P 值
年龄/岁	48.09 \pm 11.41	47.27 \pm 11.54	0.183
男性/[例(%)]	857(74.6)	363(73.8)	0.732
体质量指数/(kg/m ²)	25.73 \pm 3.99	25.69 \pm 3.80	0.855
吸烟史/[例(%)]	530(46.1)	222(45.1)	0.708
冠心病史/[例(%)]	55(4.8)	17(3.5)	0.228
糖尿病史/[例(%)]	59(5.1)	15(3.0)	0.062
高血压史/[例(%)]	846(73.6)	342(69.5)	0.087
高脂血症史/[例(%)]	98(8.5)	45(9.1)	0.685
肾功能衰竭/[例(%)]	33(2.9)	15(3.0)	0.846
马凡综合征/[例(%)]	24(2.1)	10(2.0)	0.942
主动脉瓣二叶瓣化畸形/[例(%)]	14(1.2)	6(1.2)	0.999
收缩压/mmHg	126 \pm 19	125 \pm 20	0.313
舒张压/mmHg	69 \pm 14	69 \pm 14	0.821
发病时间/[例(%)]			0.642
急性(<14天)	868(75.5)	368(74.8)	
亚急性(14天至2月)	165(14.4)	67(13.6)	
慢性(>2月)	116(10.1)	57(11.6)	
突发疼痛/[例(%)]	1 068(93.0)	469(95.3)	0.070
腹痛/[例(%)]	81(7.0)	30(6.1)	0.482
四肢缺血/[例(%)]	99(8.6)	38(7.7)	0.549
异常心电图/[例(%)]	835(74.9)	345(72.2)	0.258

续表

项目	训练集 ($n=1\,149$)	测试集 ($n=492$)	P 值
休克/[例(%)]	40(3.5)	22(4.5)	0.335
脉搏波动异常/[例(%)]	9(0.8)	7(1.4)	0.227
左心室射血分数/%	61.31±7.29	61.87±6.43	0.152
主动脉宽度/cm	4.83±1.99	4.83±1.19	0.985
心包填塞/[例(%)]	223(19.4)	98(19.9)	0.811
NYHA 心功能分级/[例(%)]			0.426
I 级	943(82.1)	405(82.3)	
II 级	115(10.0)	56(11.4)	
III 级	83(7.2)	30(6.1)	
IV 级	8(0.7)	1(0.2)	
院内 MAE/[例(%)]	301(26.2)	125(25.4)	0.738
手术时间/min	420.00(360.00,480.00)	420.00(360.00,480.00)	0.369
CPB 时间/min	191.50(163.00,225.00)	190.00(160.00,229.00)	0.813
主动脉阻断时间/min	107.00(87.75,131.25)	106.00(83.00,135.00)	0.950
白细胞计数/($\times 10^9/L$)	10.03(7.26,13.00)	9.81(7.23,13.01)	0.678
中性粒细胞计数/($\times 10^9/L$)	7.77(4.92,10.87)	7.72(4.82,10.77)	0.718
NLR	6.26(3.24,11.35)	6.27(3.07,10.66)	0.402
单核细胞计数/($\times 10^9/L$)	0.58(0.40,0.81)	0.57(0.37,0.83)	0.453
红细胞计数/($\times 10^9/L$)	4.44(4.09,4.79)	4.47(4.11,4.86)	0.298
血红蛋白/(g/L)	136.00(125.00,147.00)	136.00(123.00,148.00)	0.763
D-二聚体/($\mu g/L$)	1 142.00(542.75,2 667.50)	1 083.00(463.00,2 638.00)	0.396
丙氨酸氨基转移酶/(U/L)	22.00(15.00,36.00)	23.00(14.00,37.00)	0.345
天冬氨酸转氨酶/(U/L)	23.00(17.00,33.00)	23.00(17.00,32.00)	0.746
尿素/($\mu mol/L$)	6.40(5.00,8.00)	6.00(4.73,7.90)	0.258
尿酸/($\mu mol/L$)	353.85(273.88,444.05)	351.45(268.85,444.75)	0.728
肌酐/($\mu mol/L$)	77.85(65.00,99.00)	79.85(65.33,98.30)	0.605
血糖/(mmol/L)	6.70(5.65,7.90)	6.76(5.66,8.01)	0.423
肌酸激酶同工酶/($\mu g/L$)	1.20(0.70,2.60)	1.20(0.70,2.30)	0.048
肌钙蛋白 I/($\mu g/L$)	0.02(0.01,0.09)	0.02(0.01,0.09)	0.610

2.2 模型构建及变量权重

使用逐步向前、Lasso 和 Xgboost 三种方法在训练集中进行变量筛选,使用 Logistic 回归进行模型建立,每种方法筛选出变量(表 2)。通过 Logistic 回归得到未标准化系数,将未标准化系数经过标准化处理后,消除量纲、数量级等差异的影响,该系数则可独立的反映不同变量对结局影响的相对作用大小,使得不同变量之间具有可比性;因此使用标准化回归系数来比较模型中变量对 TAAD 患者预后的影响大小,即为变量权重(表 2)。

2.3 测试集中模型表现能力评价

根据模型预测 TAAD 术后院内 MAE 概率绘制 ROC 曲线,各模型对于各院内 MAE 的 ROC 曲线下面积(area under curve, AUC)如表 3 所示。结果显示,对于患者术后不同的院内 MAE,模型 1 的 AUC 均在 0.7~0.9 之间;对于急性肾功能衰竭,模型 1

表 2. 各模型中的变量所占权重

Table 2. The weight of variables in each model

模型中变量	模型 1	模型 2	模型 3
年龄	0.114	—	0.099
白细胞计数	0.114	—	—
D-二聚体	0.180	0.229	0.198
肌酸激酶同工酶	0.073	0.109	0.100
NLR	—	—	0.037
尿素	0.115	0.125	0.109
异常心电图	0.117	—	—
主动脉宽度	—	—	0.033
左心室射血分数	—	—	0.060
手术时间	0.263	0.131	0.190
CPB 时间	—	0.152	0.110

注:模型 1:逐步向前 Logistic 回归;模型 2:Lasso 筛选变量后进行 Logistic 回归;模型 3:Xgboost 筛选变量后进行 Logistic 回归。—:代表此模型中不包含此变量。

的 AUC 为 0.818(95% CI 0.755 ~ 0.881),模型 2 的 AUC 为 0.774(95% CI 0.698 ~ 0.850),模型 3 的 AUC 为 0.802(95% CI 0.734 ~ 0.871),模型 1 的 AUC 优于模型 2、模型 3($P=0.004$)。模型 1 预测院内总 MAE 的 AUC 为 0.776(95% CI 0.718 ~ 0.734, $P<0.001$)。根据 3 个模型对各种院内 MAE

的预测能力,结合临床模型选择原则,综合模型中变量数量、变量获得难易度以及变量临床意义,模型 1 更精简以及更能全面(个体特征变量、炎症水平、脏器受损状况等)评估患者风险,选择模型 1 为最终模型。

表 3. 3 种模型对术后院内 MAE 预测价值的比较
Table 3. Comparison of the predictive value of three models for postoperative MAE in hospital

MAE	AUC(95CI%)		
	模型 1	模型 2	模型 3
院内死亡	0.930(0.884 ~ 0.976)	0.900(0.832 ~ 0.968)	0.920(0.870 ~ 0.972)
呼吸衰竭	0.721(0.578 ~ 0.863)	0.675(0.520 ~ 0.830)	0.695(0.535 ~ 0.855)
急性心脏衰竭	0.712(0.515 ~ 0.910)	0.652(0.444 ~ 0.862)	0.683(0.467 ~ 0.900)
神经系统障碍	0.772(0.693 ~ 0.852)	0.762(0.678 ~ 0.846)	0.784(0.705 ~ 0.864)
急性肾功能衰竭	0.818(0.755 ~ 0.881)	0.774(0.698 ~ 0.850)	0.802(0.734 ~ 0.871)
感染	0.740(0.630 ~ 0.849)	0.693(0.555 ~ 0.831)	0.738(0.619 ~ 0.856)
二次开胸	0.738(0.645 ~ 0.830)	0.715(0.620 ~ 0.810)	0.721(0.628 ~ 0.814)
院内总 MAE	0.776(0.718 ~ 0.734)	0.751(0.690 ~ 0.812)	0.772(0.712 ~ 0.831)

2.4 构建模型与临床常用模型比较

对于 TAAD 患者风险评估,现临床常用模型是基于 IRAD 开发的院内死亡预测模型^[6]。将我们构建的模型 1 与 IRAD 预测模型使用 NRI 和 IDI 分析进行比较,结果显示,NRI 为 0.654(95% CI 0.540 ~ 0.750, $P<0.001$),IDI 为 0.136(95% CI 0.117 ~ 0.155, $P<0.001$)。相较于 IRAD 预测模型,我们构建的模型重新分类正确的比例和整体判别能力有所提高。使用全部研究人群 1 641 例患者评估模型 1,模型 1 的准确率为 77.0%,精确率为 65.3%。

2.5 模型中变量与院内 MAE 的相关性分析

使用 Logistic 回归分析模型 1 中变量与 TAAD 术后院内 MAE 发生的相关性。单因素分析结果显示,模型中变量 D-二聚体、尿素、肌酸激酶同工酶、白细胞计数、年龄、异常心电图、手术时间均为 TAAD 患者发生院内 MAE 的影响因素;多因素分析结果显示了模型中变量之间相互作用之后的效应(表 4)。我们根据多因素 Logistic 回归分析,将模型 1 通过列线图形式呈现。列线图模型评分能够评估每位 TAAD 患者发生院内 MAE 的风险(图 2)。

表 4. 逐步向前 Logistic 回归筛选变量及建立模型 1
Table 4. Stepwise forward Logistic regression to screen variables and build the model 1

模型变量	单因素分析			多因素分析		
	OR	95% CI	P	OR	95% CI	P
D-二聚体	1.537	1.387 ~ 1.702	<0.001	1.261	1.118 ~ 1.423	<0.001
白细胞计数	2.910	2.051 ~ 4.128	<0.001	1.673	1.086 ~ 2.578	0.019
尿素	2.885	2.000 ~ 4.163	<0.001	1.724	1.146 ~ 2.593	0.009
肌酸激酶同工酶	1.412	1.259 ~ 1.583	<0.001	1.129	0.987 ~ 1.292	0.076
年龄	1.022	1.010 ~ 1.034	<0.001	1.018	1.004 ~ 1.032	0.009
手术时间	1.004	1.003 ~ 1.006	<0.001	1.004	1.003 ~ 1.005	<0.001
异常心电图	1.550	1.121 ~ 2.143	0.008	1.622	1.149 ~ 2.288	0.006




图 2. 模型 1 的列线图

Figure 2. Nomogram of model 1

3 讨论

本研究入选 2013 年 1 月至 2017 年 12 月北京安贞医院手术治疗的 TAAD 患者,使用机器学习进行模型构建,最终确定了由逐步向前 Logistic 回归建立的由 D-二聚体、肌酸激酶同工酶、尿素、白细胞计数、年龄、异常心电图和手术时间组成的模型,结合列线图模型可评估患者院内 MAE 的发生风险,可较准确的将患者进行风险分层。

模型中变量是欧洲心脏病学会 (European Society of Cardiology, ESC) 在 2014 年提出的主动脉疾病诊治指南中推荐的评估主动脉夹层患者状态的变量^[1]。我们构建的模型 1 中,手术时间所占权重最大。主动脉疾病诊治指南中指出发生神经系统障碍等 MAE 的风险依赖于修复手术时间^[1];我们的研究符合既往研究以及临床实际情况。D-二聚体为变量权重第 2 位,它是胸痛、肺栓塞、主动脉夹层的鉴别诊断标志物^[12],其血浆浓度增加是因为暴露于主动脉夹层的组织因子引起级联反应,内源性纤溶活性抵消了外源性凝血级联途径的激活,D-二聚体的浓度可以反映夹层的撕裂程度,是主动脉夹层死亡的独立预测因子^[13]。模型中的肌酸激酶同工酶、异常心电图和血浆尿素水平反映了患者心脏、肾脏受损状态,是评估患者是否存在脏器灌注不良的变量。夹层发生后由于主动脉或分支动脉真腔狭窄塌陷导致内脏动脉缺血,灌注不良造成全身各器官功能受损,灌注不良所涉及的器官数量和灌注不良类型对夹层预后影响很大^[14]。白细胞反

映患者炎症水平,已有研究显示入院白细胞计数升高可预测 TAAD 患者近期死亡风险^[15]。本研究显示年龄越大结局越差,与先前的报道^[16]一致。我们构建的模型可综合评估患者个体特征变量、炎症水平、脏器受损状况以及手术情况,预测患者发生院内 MAE 的风险。

国际急性主动脉夹层注册队列是由 6 个国家的 12 个医院参与建设的队列,评估急性主动脉夹层的表型、治疗和预后^[5]。本研究在收集变量时,首先在 IRAD 基础上进行临床变量收集,接着增加了指南中推荐的入院临床血清学检查结果和与手术相关的变量。与 IRAD 相比,我们构建的模型重新分类正确的比例和整体判别能力有所提高。这可能是因为 IRAD 模型^[6]中的变量如突发疼痛、心包填塞等,虽然可能是更严重的主动脉撕裂的表现,但是由于患者可能有不同的临床特征^[17],影响模型的预测效能。我们的模型中增加了临床血清学检查,这样可以在一定程度上排除患者发病时个体差异性的影响,进一步增加模型的预测效能。

与传统的统计方法相比,机器学习方法可以通过包含更多变量的更高维度和可能的非线性效应来提高预测效果^[18]。机器学习利用已有的知识,通过组织数据、识别模型,对医疗数据整合分析,进一步指导临床实践,尽可能准确的预测患者结局^[19]。我们的研究通过比较机器学习方法构建的 TAAD 不同预测模型,选出了一种临床实用性最强的模型。通过赋予临床变量新的权重,使用客观的变量来解释疾病复杂的相互作用,提升模型的预测价值。

本研究有一定的局限性。本研究为单中心回顾性研究,有少量数据缺失以及实验室检查结果呈非正态分布,同时由于主动脉夹层的高风险性,病情进展快的患者可能在到达医院前已经死亡,这部分患者未纳入研究。虽然机器学习算法分析能力很高,但是要求大量患者的真实临床数据,否则可能会产生错误结果^[20]。在本研究中,我们反复对数据进行核查,保证数据准确性与真实性,以提高模型的准确性。

综上,本研究使用临床可常规获得的临床变量,使用机器学习构建模型,并使用列线图进行模型可视化,可对TAAD患者进行风险评估,识别高风险患者。预测模型可以被临床医师用作评估TAAD患者预后的工具,帮助医师向患者及家属阐述该疾病的风险与预后情况。未来需要对本模型进行更大规模的多中心研究,以验证模型的应用价值。

[参考文献]

- [1] Erbel R, Aboyans V, Boileau C, et al. 2014 ESC guidelines on the diagnosis and treatment of aortic diseases: document covering acute and chronic aortic diseases of the thoracic and abdominal aorta of the adult. The task force for the diagnosis and treatment of aortic diseases of the European Society of Cardiology (ESC) [J]. *Eur Heart J*, 2014, 35(41): 2873-2926.
- [2] Goldfinger JZ, Halperin JL, Marin ML, et al. Thoracic aortic aneurysm and dissection [J]. *J Am Coll Cardiol*, 2014, 64(16): 1725-1739.
- [3] Pape LA, Awais M, Woznicki EM, et al. Presentation, diagnosis, and outcomes of acute aortic dissection: 17-year trends from the international registry of acute aortic dissection [J]. *J Am Coll Cardiol*, 2015, 66(4): 350-358.
- [4] 周楚芝, 杨建安, 温隽珉, 等. 急性A型主动脉夹层患者术后谵妄发生的危险因素分析 [J]. *中国动脉硬化杂志*, 2016, 24(12): 1253-1257.
- [5] Evangelista A, Isselbacher EM, Bossone E, et al. Insights from the international registry of acute aortic dissection: a 20-year experience of collaborative clinical research [J]. *Circulation*, 2018, 137(17): 1846-1860.
- [6] Mehta RH, Suzuki T, Hagan PG, et al. Predicting death in patients with acute type a aortic dissection [J]. *Circulation*, 2002, 105(2): 200-206.
- [7] Al'Aref SJ, Anchouche K, Singh G, et al. Clinical applications of machine learning in cardiovascular disease and its relevance to cardiac imaging [J]. *Eur Heart J*, 2019, 40(24): 1975-1986.
- [8] Angraal S, Mortazavi BJ, Gupta A, et al. Machine learning prediction of mortality and hospitalization in heart failure with preserved ejection fraction [J]. *JACC Heart Fail*, 2020, 8(1): 12-21.
- [9] Al'Aref SJ, Singh G, Choi JW, et al. A boosted ensemble algorithm for determination of plaque stability in high-risk patients on coronary cta [J]. *JACC Cardiovasc Imaging*, 2020, 13(10): 2162-2173.
- [10] Al'Aref SJ, Maliakal G, Singh G, et al. Machine learning of clinical variables and coronary artery calcium scoring for the prediction of obstructive coronary artery disease on coronary computed tomography angiography: analysis from the confirm registry [J]. *Eur Heart J*, 2020, 41(3): 359-367.
- [11] Huo D, Kou B, Zhou Z, et al. A machine learning model to classify aortic dissection patients in the early diagnosis phase [J]. *Sci Rep*, 2019, 9(1): 2701.
- [12] Suzuki T, Distant A, Zizza A, et al. Diagnosis of acute aortic dissection by D-dimer: the international registry of acute aortic dissection substudy on biomarkers (IRAD-Bio) experience [J]. *Circulation*, 2009, 119(20): 2702-2707.
- [13] Weber T, Rammer M, Auer J, et al. Plasma concentrations of D-dimer predict mortality in acute type a aortic dissection [J]. *Heart*, 2006, 92(6): 836-837.
- [14] Czerny M, Schoenhoff F, Etz C, et al. The impact of pre-operative malperfusion on outcome in acute type a aortic dissection: results from the geraada registry [J]. *J Am Coll Cardiol*, 2015, 65(24): 2628-2635.
- [15] Fan X, Huang B, Lu H, et al. Impact of admission white blood cell count on short-and long-term mortality in patients with type a acute aortic dissection: an observational study [J]. *Medicine (Baltimore)*, 2015, 94(42): e1761.
- [16] Ehrlich M, Fang WC, Grabenwöger M, et al. Perioperative risk factors for mortality in patients with acute type a aortic dissection [J]. *Circulation*, 1998, 98(19 Suppl): II294-II298.
- [17] Nienaber CA, Fattori R, Mehta RH, et al. Gender-related differences in acute aortic dissection [J]. *Circulation*, 2004, 109(24): 3014-3021.
- [18] Mortazavi BJ, Downing NS, Bucholz EM, et al. Analysis of machine learning techniques for heart failure readmissions [J]. *Circ Cardiovasc Qual Outcomes*, 2016, 9(6): 629-640.
- [19] 熊日新, 林英忠. 人工智能在心血管疾病风险评估中的应用研究进展 [J]. *中国临床新医学*, 2020, 13(5): 537-540.
- [20] Connor CW. Artificial intelligence and machine learning in anesthesiology [J]. *Anesthesiology*, 2019, 131(6): 1346-1359.

(此文编辑 曾学清)