DOI:10.16016/j.2097-0927.202301054

基于贝叶斯网络算法建立全膝关节置换术后认知功能障碍风险预测模型

李丹风[1],李昊洋[2],钟坤华[3],舒 欣[1],李雨捷[1],易 斌[1] 400038 重庆,陆军军医大学(第三军医大学):第一附属医院麻醉科[1],基础医学院学员五大队[2]; 400714 重庆,中国科学院重庆绿色智能技术研究院[3]

[**摘要**] **目的** 利用贝叶斯网络(Bayesian network,BN)算法建立全膝关节置换术(total knee replacement,TKR)后认知功能障碍(postoperative cognitive dysfunction,POCD)的风险预测模型,并探讨模型的预测性能。**方法** 采用病例-对照研究设计方案,选择陆军军医大学第一附属医院关节外科2017年1月至2021年12月行TKR的住院患者1 260例。入院主要诊断为左/右膝关节重度骨性关节炎,其中男性240例(19.0%),女性1 020例(81.0%);年龄23~79(66.73±8.46)岁;体质指数(BMI)(25.08±5.09)kg/m^2。将术后(手术结束至出院期间)发生POCD的患者(71例)按照7∶3随机分为A1组(70%)和B1组(30%),未发生POCD的患者(1 189例)按照7∶3随机分为A2组(70%)和B2组(30%)。A1组与A2组共同构成A组(训练数据集),B1组与B2组则为B组(测试数据集),其中A组用于模型训练,B组用于模型测试。筛选TKR相关围术期麻醉决策、病情转归及住院时间等36项指标作为节点,利用BN算法建立各节点的概率分布模型图,预测POCD发生风险的概率,以期住院时间最短,促进最大化患者康复。**结果** 基于BN算法建立的预测TKR后POCD发生风险模型,训练集的受试者工作曲线下面积(area under the subject curve,AUC)值为0.966 1(95%*CI*:0.954 1~0.978 4),测试集AUC值为0.897 4(95%*CI*:0.867 2~0.928 5),准确性分别为96.43%(95%*CI*:0.951 1~0.976 4)和93.44%(95%*CI*:0.909 2~0.959 6)。**结论** 基于BN算法建立的预测TKR后POCD发生风险的模型预测性能较好且准确率较高。

[**关键词**] 贝叶斯网络;人工智能;预测模型;术后认知功能障碍;全膝关节置换术
[**中图法分类号**] R319; R687.4; R749 [**文献标志码**] A

Risk prediction model for postoperative cognitive dysfunction after total knee replacement based on Bayesian network algorithm

LI Danfeng[1], LI Haoyang[2], ZHONG Kunhua[3], SHU Xin[1], LI Yujie[1], YI Bin[1] [1]Department of Anesthesiology, First Affiliated Hospital, [2]Regiment Five, Basical Medicine College, Army Medical University (Third Military Medical University), Chongqing, 400038; [3]Chongqing Institute of Green and Intelligent Technology, Chinese Academy of Sciences, Chongqing, 400714, China

[**Abstract**] **Objective** To establish a prediction model of risk for postoperative cognitive dysfunction (POCD) after total knee replacement (TKR) by Bayesian network (BN) algorithm and investigate its predictive performance. **Methods** A case-control trial was conducted on 1 260 inpatients who underwent TKR from January 2017 to December 2021 in the Department of Joint Surgery of our hospital. Their main diagnosis of inclusion was severe osteoarthritis of left/right knee joint. They were 240 cases of male (19.0%) and 1 020 cases of female (81.0%), at an average age of 66.73±8.46 (23~79) years and a mean body mass index (BMI) of 25.08±5.08 kg/m^2. The POCD patients (n=71) after surgery (from the end of

[**基金项目**] 国家重点研发计划(2018YFC0116702);2019年重庆市技术创新与应用研究发展专项(cstc2019jscx-msxmX0237)
[**通信作者**] 易 斌,E-mail:yibin1974@163.com

2097-0927/Copyright © 2022, 陆军军医大学(第三军医大学)。这篇开放获取文章遵循 CC BY 许可协议(https://creativecommons.org/licenses/by/4.0/)

surgery to discharge) were randomly divided into A1 group and B1 group at a ratio of 7∶3, and those without POCD (1 189 cases) were also randomly divided into A2 group and B2 group at a same ratio. The patients from A1 and A2 groups were combined together as training set, and those out of B1 and B2 groups as test set. Thirty-six indexes related to perioperative anesthesia decision, disease outcome and length of stay in TKR were selected as nodes, and the probability distribution model diagram of each node was established by using BN algorithm to predict the probability of risk for POCD, so as to minimize the length of stay and promote the maximum recovery of patients. **Results** The prediction model of risk for POCD after TKR was established based on BN algorithm. The area value under receiver operating characteristic curve (ROC-AUC) of the training set was 0.966 1 (95% *CI*: 0.954 1~0.978 4), and the ROC-AUC value of the test set was 0.897 4 (95% *CI*: 0.867 2~0.928 5), with an accuracy of 96.43% (95% *CI*: 0.951 1~0.976 4) and 93.44% (95% *CI*: 0.909 2~0.959 6), respectively. **Conclusion** Our risk prediction model for POCD after TKR based on BN algorithm has good performance and high accuracy

[**Key words**] Bayesian network; artificial intelligence; prediction model; postoperative cognitive dysfunction; total knee replacement

Supported by the National Key R&D Program of China (2018YFC0116702) and the Special Project of Chongqing Technology Innovation and Application Research and Development in 2019 (cstc2019jscx-msxmX0237). Corresponding author: YI Bin, E-mail: yibin1974@163.com

术后认知功能障碍(postoperative cognitive dysfunction, POCD)作为术后中枢神经系统常见并发症之一,可延长患者的住院时间,增加住院费用及死亡率,威胁患者的生命安全,既往 POCD 相关的研究多集中于 65 岁以上的老年患者,年龄是 POCD 的独立危险因素[1-2]。临床上行全膝关节置换术(total knee replacement,TKR)的患者多为老年患者,但导致 TKR 患者发生 POCD 的原因较为复杂。近年来,人工智能被广泛应用于医疗领域的研究[3-4]。贝叶斯网络(Bayesian network,BN)作为其应用分支机器学习算法(machine learning,ML)的一种特殊算法,在解释复杂不确定性方面有其独特的优势[5]。BN 是贝叶斯方法的扩展,是人工智能、概率理论、图论和决策分析相结合的产物。它通过有向无环图定性地表示随机变量之间的相互依赖关系,并以条件概率分布对这种依赖关系进行量化,是随机变量联合概率分布的图形化表示,具有很强的可解释性。

本研究拟引入 BN 算法,旨在通过 BN 在解释复杂不确定性方面的独特优势来构建预测 TKR 后 POCD 发生风险的概率模型,并绘制 BN 模型图,以期降低 POCD 发生风险,缩短患者住院时间,合理分配医疗资源,促进最大化患者康复。

1 资料与方法

1.1 研究对象

本研究采用病例-对照研究[6]设计方案。利用陆军军医大学第一附属医院大数据平台通过条件树检索方式筛选关节外科 2017 年 1 月至 2021 年 12 月行 TKR 的住院患者病例,入院主要诊断为左/右膝关节重度骨性关节炎。纳入标准:①首次行 TKR 患者;②18~80 岁;③麻醉前 ASA 分级Ⅰ~Ⅲ级。排除标准:①术前存在严重器官功能不全(出院诊断包含心力衰竭、心功能不全,呼吸衰竭,肾衰竭,肝硬化失代偿);②关节日间手术患者;③正在参加其他临床试验者;④数据缺失>30%。本研究通过陆军军医大学第一附属医院伦理委员会批准(KY2019157)。

1.2 研究方法

1.2.1 数据筛选 通过查阅 TKR 相关的文献、指南以及专家共识,本课题组筛选出了 TKR 相关的麻醉决策 12 项,包括患者的基本信息、生命体征、检验指标、术前合并症、ASA 分级、麻醉方式、是否采用多模式镇痛,术中是否采取保温措施,维持血流动力学稳定,预防术后恶心、呕吐发生,预防静脉血栓栓塞症发生以及麻醉药物的使用情况等。利用我院大数据平台检索上述 TKR 相关的麻醉决策实施情况。筛选 TKR 相关围术期麻醉决策、病情转归及住院时间等 36 项指标作为节点,利用 BN 算法建立各节点的概率分布模型图,预测 POCD 发生风险的概率,以期住院时间最短,促进最大化患者康复。

1.2.2 研究分组 将 TKR 后发生 POCD 的患者(71 例)按照 7∶3 随机分为 A1 组(70%)和 B1 组(30%),未发生 POCD 的患者(1 189 例)按照 7∶3随机

分为 A2 组(70%)和 B2 组(30%)。A1 组与 A2 组共同构成 A 组(训练数据集),用于模型训练;B1 组与 B2 组为 B 组(测试数据集),用于模型测试。通过筛选 TKR 相关围术期麻醉决策、病情转归及住院时间等 36 项指标作为节点,利用 BN 算法建立各节点的概率分布模型图,预测并描述 POCD 发生风险的概率。参照本课题组前期研究[7-8]按照 7∶3的比例分为训练数据集和测试数据集符合机器学习算法及 BN 算法的建模要求。

1.2.3 数据预处理 利用 Excel 表格当中的函数(包括 VLOOKUP、IF、SUM、IFERROR 等)以及数据透视表等,将上述各项指标进行数据预处理,使之符合机器学习的数据要求。性别、疾病史、手术史、输血史、过敏史、吸烟史、饮酒史等二分类变量采用 0 和 1 表示。如性别用 0 和 1 分别表示男和女。年龄等连续性数值型变量按照临床意义进行分段处理。如年龄分为青年(18~34 周岁)、壮年(35~49 周岁)、中年(50~64 周岁)、老年(65~80 周岁),然后采用 Z-score 归一化(Z-score normalization)处理对特征值进行缩放处理后,数据的均值为 0,标准差为 1。对于有 5 个取值水平的 ASA 分级,则采用 one-hot 进行编码,处理后将其转换成(0,0,0,0,1)、(0,0,0,1,0)、(0,0,1,0,0)、(0,1,0,0,0)、(1,0,0,0,0)。

1.2.4 模型构建 机器学习过程在 Python 平台进行,由本项目组成员钟坤华(中国科学院重庆绿色智能技术研究院)负责机器学习算法编程及 BN 模型构建。本研究基于 BN 对数据库进行建模分析,首先将数据按照 7∶3分为训练数据集和测试数据集。在训练数据集上构建 BN 模型,采用爬山算法(Hill Climbing Algorithm)自动构建 BN 结构,并结合医学专家知识对所得网络结构进行调整;然后,采用贝叶斯参数估计方法学习网络参数,即所得网络结构中每个节点的条件概率分布。

1.2.5 模型评估方法 在测试数据集上,通过敏感度、特异度、受试者工作特征曲线(receiver operating characteristic curve,ROC)曲线下面积、准确率(accuracy)、F1 分数对模型进行性能评估,并计算相应的 95%*CI*。模型评估过程中,采用变量消除法推断测试数据集中每个节点的概率,并以此给出术后 POCD 预测结果。

此外,本研究还计算了 BN 模型中每个节点的边缘概率分布,即在不给定任何证据信息情况下,提供每个节点的取值概率分布。

1.2.6 BN 模型的实验环境 基于 Python 平台构建的预测 TKR 后 POCD 发生风险的 BN 模型,模型的代码共计 600 余行。

实验运行硬件环境为:联想扬天 P780-10 台式机;Intel i9-10900@2.80GHz 2.81GHz CPU;64GB 内存;512GB SSD+2T 存储;win 10 64 位操作系统。

实验运行软件环境为:在 PyCharm 2021.2.2 集成开发环境;Python 3.9.7 编程语言;pandas、numpy、networkx、pgmpy 以及 sklearn 等 Python 包。

1.3 统计学分析

本研究数据采用 SPSS 23.0 进行统计学分析,正态分布的计量资料使用 $\bar{x}\pm s$ 表示,非正态分布的计量资料使用 $M(P_{25},P_{75})$ 表示,计数资料使用频次(%)表示。组间比较采用 χ^2 检验、t 检验、*Fisher* 精确检验分析,Kruskal-Wallis 检验。所有统计学检验为双侧,取 $P<0.05$ 为差异有统计学意义。

2 结果

2.1 研究对象基本情况

试验最终纳入的患者数量为 1 260 例,其中男性 240 例(19.0%),女性 1 020 例(81.0%);年龄 23~79(66.73±8.46)岁;BMI 为(25.08±5.09)kg/m^2;ASA 分级为Ⅰ级的 108 例(8.6%),ASA 分级为Ⅱ级的 1 152 例(91.4%)。POCD 组和非 POCD 组患者的性别分布、ASA 分级、BMI 等资料比较,差异无统计学意义($P>0.05$),2 组患者年龄比较,差异有统计学意义($P<0.05$),见表 1。

表 1 POCD 组与非 POCD 组基本资料(例,$\bar{x}\pm s$)

项目	n	男/女	年龄/岁	BMI/kg·m^{-2}	ASA 分级(Ⅰ级/Ⅱ级)
非 POCD 组	1 189	228/961	66.43±8.52	25.10±5.05	102/1 087
POCD 组	71	12/59	71.65±5.35	24.75±5.75	6/65
t/χ^2		0.225	−7.662	0.578	0.001
P		0.635	<0.001	0.563	0.970

2.2 BN 节点筛选

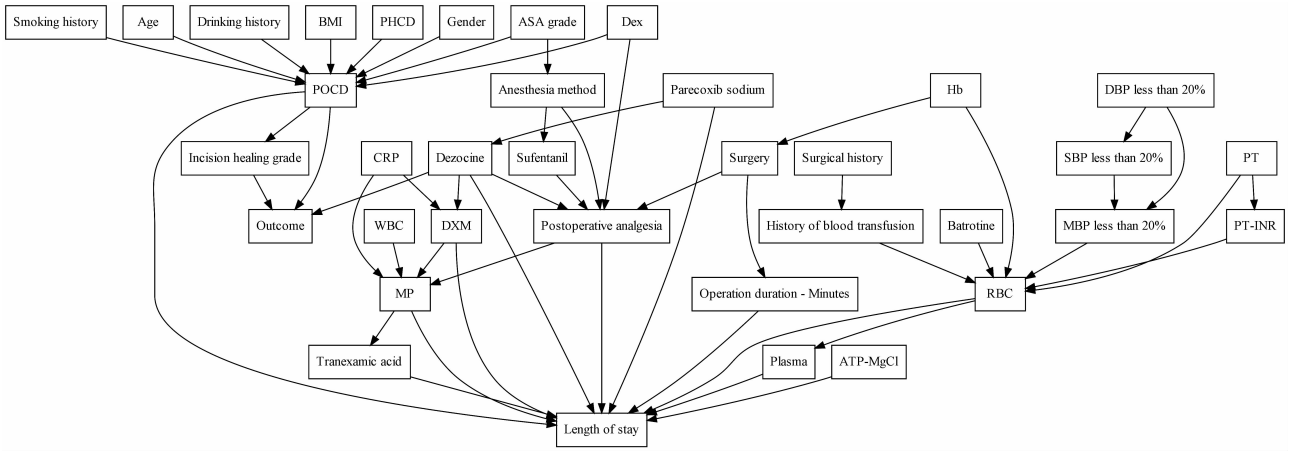
将所有纳入研究的患者数据按照 7∶3随机分为训练集和测试集。其中 70%用于模型训练后得到的 BN 包含 52 个节点及 56 条有向边。性别、关节是否交锁、10%氯化钾、吸烟史、是否关节红肿、手术级别、BMI、是否绝经共 8 个节点并未出现在 BN 关系图中。随后,我们利用所有数据再次建模,结果并没有增加 BN 节点,只是有向边增加到 62 条。将数据拟合后再次建

模,BN 包含 54 个节点,有向边增加到 93 条。增加的有向边致使节点间的条件概率分布(CPD)结果呈现指数级的增长,增加了模型训练的难度。我们根据 BN 节点的时序性及因果关系对节点进行了选择,最终筛选出 36 个节点,并建立 BN 模型(图 1)。BN 模型节点对应的临床指标及期望值见表 2。

表 2 BN 预测 TKR 患者 POCD 发生率的临床指标、期望值及变量类型

序号	BN 节点	临床指标	期望值[a]	变量类型
1	Age	年龄	0.695 1	连续型变量
2	Gender	性别	0.996 4	离散型变量
3	BMI	体质指数	0.398 4	连续型变量
4	ASA grade	ASA 分级	0.923 7	离散型变量
5	Smoking history	吸烟史	0.987 9	离散型变量
6	Drinking history	饮酒史	0.943 7	离散型变量
7	Surgical history	手术史	0.478 6	离散型变量
8	History of blood transfusion	输血史	0.928 0	离散型变量
9	PHCD	长托宁	0.987 9	离散型变量
10	POCD	术后认知功能障碍	0.919 8	离散型变量
11	Incision healing grade	手术切口愈合等级	0.984 2	离散型变量
12	Outcome	病情转归	0.847 7	离散型变量
13	WBC	白细胞	0.272 8	连续型变量
14	RBC	悬浮红细胞	0.971 6	连续型变量
15	Plasma	血浆	0.979 5	连续型变量
16	CRP	C 反应蛋白	0.672 6	连续型变量
17	Hb	血红蛋白	0.720 8	连续型变量
18	PT	凝血酶原时间	0.427 5	连续型变量
19	PT-INR	凝血 INR	0.357 6	连续型变量
20	DXM	地塞米松磷酸钠注射液	0.537 4	离散型变量
21	Tranexamic acid	氨甲环酸氯化钠	0.944 6	离散型变量
22	ATP-MgCl	注射用三磷酸腺苷二钠氯化镁	0.950 8	离散型变量
23	Dezocine	地佐辛注射液	0.357 3	离散型变量
24	Sufentanil	枸橼酸舒芬太尼注射液	0.943 7	离散型变量
25	Parecoxib sodium	注射用帕瑞昔布钠	0.732 5	离散型变量
26	Batrotine	巴曲亭	0.016 4	离散型变量
27	MP	甲强龙	0.903 2	离散型变量
28	Dex	右美托嘧啶	0.882 3	离散型变量
29	DBP less than 20%	术中舒张压<20%	0.797 0	离散型变量
30	SBP less than 20%	术中收缩压<20%	0.732 8	离散型变量
31	MBP less than 20%	术中平均压<20%	0.845 5	离散型变量
32	Postoperative analgesia	术后镇痛	0.611 1	离散型变量
33	Anesthesia method	麻醉方式	0.942 5	离散型变量
34	Surgery	手术	0.973 6	离散型变量
35	Operation duration-Minutes	手术时长/分	0.503 9	连续型变量
36	Length of stay	住院天数	0.893 4	连续型变量

a:为有向边对应的父节点对子节点影响的概率期望值



BN 模型图(36 个 BN 节点, 55 条有向边数);有向边箭头指向的节点为子节点,起始端的节点则为父节点

图 1 基于 BN 算法预测 TKR 患者 POCD 发生率的有向非循环图

表 3 BN 模型预测术后 POCD 发生风险的 AUC、敏感性、特异性

BN 模型	AUC,95%*CI*	敏感性(%)	特异性(%)	准确性(%),95%*CI*
训练集	0.966 1,0.954 1~0.978 4	86.01	97.02	96.43,0.951 1~0.976 4
测试集	0.897 4,0.867 2~0.928 5	77.14	95.53	93.44,0.909 2~0.959 6

表 4 MLP 模型预测术后 POCD 发生风险的 AUC、敏感性、特异性

MLP 模型	AUC,95%*CI*	敏感性(%)	特异性(%)	准确性(%),95%*CI*
训练集	0.871 5,0.818 9~0.924 2	74.01	89.52	96.15,0.946 6~0.973 2
测试集	0.681 9,0.567 3~0.796 5	70.76	88.59	83.44,0.803 7~0.855 6

2.3 模型的预测性能

为验证模型的预测性能,本研究绘制了模型的 ROC(图 2),训练集构建的预测模型的受试者工作曲线下面积(area under the subject curve,AUC)值为 0.966 1(95%*CI*:0.954 1~0.978 4),敏感性、特异性分别为 86.01%和 97.02%,准确性为 96.43%(95%*CI*:0.951 1~0.976 4)。通过测试数据集验证及评价 BN 模型对 TKR 后 POCD 发生风险概率的预测性能,结果显示,测试集的 AUC 值为 0.897 4(95%*CI*:0.867 2~0.928 5),敏感性、特异性分别为 77.14%、95.53%,准确性为 93.44%(95%*CI*:0.909 2~0.959 6)。模型有较好的预测性能且准确率较高(表 3)。

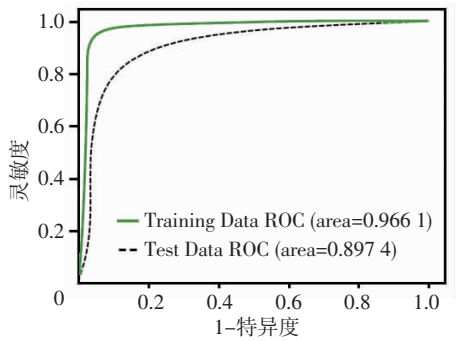


图 2 基于 BN 模型预测 TKR 患者 POCD 发生率的 ROC 曲线

3 讨论

POCD 作为术后常见的并发症,严重影响患者的术后恢复,延长住院时间,造成医疗资源浪费。本研究利用 BN 算法建立预测 TKR 后 POCD 发生风险的模型,以期住院时间最短,合理分配医疗资源,促进最大化患者康复。可为临床医生及护理提供一定的参考。

3.1 BN 算法在医疗领域的应用优势

近年来,ML 在医疗健康领域广泛应用,其在数据挖掘、处理方面具有很大的潜力,且比人工具有更高效、更准确的优势。BN 作为 ML 的一种特殊算法,在解释复杂不确定性方面有其独特的优势。BN 本质上是描绘多变量间的条件独立关系的概率模型,属概率图模型的一种[9-10]。过去的十年间,BN 以其在多变量间概率关系的描绘及推理能力而成为医疗领域研究的热点之一[11]。

如今,BN 广泛应用于预测疾病的诊断及预后。SANDRI 等[12-13]基于时序 BN 对 ICU 患者的器官衰竭进行了预测,结果显示,在第一次器官衰竭发生的时间及种类给定后,模型能够合理预测接下来有可能发生器官衰竭的情况。SESEN 等[14-15]基于 BN 预测了肺

癌患者的1年期存活率,并以最大化存活率为预测目标,为患者提供最优治疗方案。结果显示,模型在疗法类别层面推荐效果为76%,但在疗法推荐层面的准确率偏低,仅为29%。

BN是通过有向非循环图来解释各节点的概率分布问题,各节点间的有向边出现一个闭环则会陷入无限循环。本研究在模型的构建过程中出现过类似的闭环,如('注射用帕瑞昔布钠','地佐辛注射液')('地佐辛注射液')('地塞米松磷酸钠注射液')('地塞米松磷酸钠注射液')('注射用帕瑞昔布钠'),影响了模型的建立,后通过节点间的因果关系及时序性调整了模型的节点及有向边规避了此类问题。

3.2 基于BN算法建立的预测TKR后POCD发生风险的模型预测性能较好

本研究结果显示,训练集的ROC-AUC值为0.966 1,说明模型有较好的性能,测试集的ROC-AUC值为0.897 4,说明模型有较好预测性能。为验证其他机器学习算法在本研究中的预测效果,本课题组利用医疗领域常用的几种机器学习算法,包括极端梯度提升(XGBoost),随机森林(RF),支持向量机(SVM),多层感知机(MLP)对数据进行建模。结果显示,XGBoost、SVM出现过拟合问题,RF预测性能较差,仅MLP训练集在敏感性、特异性有不错的表现,AUC为0.871 5(95%*CI*:0.818 9~0.924 2)。但测试集AUC为0.681 9(95%*CI*:0.567 3~0.796 5)(表4),训练集、测试集存在一定的偏差,模型鲁棒性不及BN。这可能跟MLP的原理相关,最典型的MLP包括3层:输入层、隐层和输出层,MLP神经网络不同层之间是全连接的,即上一层的任何一个神经元与下一层的所有神经元都有连接。其神经元之间的连接强度由权重表示,权重的大小表示可能性的大小[16-17]。BN则是通过有向非循环边来解释各节点的概率分布问题,在解释复杂不确定性关系问题中相较于MLP有一定的优势。KLANN等[18-19]先后使用关联规则挖掘、协同过滤及BN后发现BN在模型的可解释性、描述多变量间复杂关系的能力以及预测结果的准确性方面均是最优的。相比于关联规则挖掘,BN有着更好的提取数据中有用关联的能力,进而可提供更加准确的预测结果。此外,本研究也存在一定局限性:研究为单中心、回顾性、观察性研究,样本量偏少,难以避免选择偏倚。后续仍需进行更大样本量的多中心、前瞻性研究,并引入其他机器学习算法进一步验证。本课题组前期已经开展基于多生理参数智能监护数据库MIMIC Ⅲ的机器学习相关预测研究,该数据库拥有足够的样本量,下一步的研究也可基于此数据库对模型进一步验证。

综上,基于BN算法建立的预测TKR后POCD发生风险的模型预测性能较好且准确率较高。

参考文献:

[1] 都义日, 米卫东. 术后认知功能障碍的研究进展[J]. 重庆医学, 2019, 48(6): 1021-1024. DOI: 10.3969/j.issn.1671-8348.2019.06.032.
DU Y R, MI W D. Research progress of postoperative cognitive dysfunction[J]. Chongqing Med, 2019, 48(6): 1021-1024. DOI: 10.3969/j.issn.1671-8348.2019.06.032.

[2] 边志民. 老年肿瘤患者合并术后认知功能障碍的影响因素及诊断防治策略[J]. 中国现代医学杂志, 2021, 31(13): 1-4. DOI: 10.3969/j.issn.1005-8982.2021.13.001.
BIAN Z M. Advances in prevention and treatment of elderly cancer patients with postoperative cognitive dysfunction[J]. China J Mod Med, 2021, 31(13): 1-4. DOI: 10.3969/j.issn.1005-8982.2021.13.001.

[3] TOPOL E J. High-performance medicine: the convergence of human and artificial intelligence[J]. Nat Med, 2019, 25(1): 44-56. DOI: 10.1038/s41591-018-0300-7.

[4] RAVIZZA S, HUSCHTO T, ADAMOV A, *et al*. Predicting the early risk of chronic kidney disease in patients with diabetes using real-world data[J]. Nat Med, 2019, 25(1): 57-59. DOI: 10.1038/s41591-018-0239-8.

[5] KLANN J G, SZOLOVITS P, DOWNS S M, *et al*. Decision support from local data: creating adaptive order menus from past clinician behavior[J]. J Biomed Inform, 2014, 48: 84-93. DOI: 10.1016/j.jbi.2013.12.005.

[6] GRIMES D A, SCHULZ K F. An overview of clinical research: the lay of the land[J]. Lancet, 2002, 359(9300): 57-61. DOI: 10.1016/S0140-6736(02)07283-5.

[7] 支鸿羽. 基于机器学习的腹部手术患者术后死亡风险预测的研究[D]. 重庆: 中国人民解放军陆军军医大学, 2020.
ZHI H Y. Prediction of postoperative risk of death in patients undergoing abdominal surgery based on machine learning[D]. Chongqing: Army Medical University, 2020.

[8] 邓鹏, 陈芋文, 李雨捷, 等. 利用支持向量机预测重症监护室患者死亡风险的研究[J]. 陆军军医大学学报, 2022, 44(17): 1764-1769. DOI: 10.16016/j.2097-0927.202206112.
DENG P, CHEN Y W, LI Y J, *et al*. Prediction of in-hospital mortality risk in intensive care unit with support vector machine[J]. J Army Med Univ, 2022, 44(17): 1764-1769.

DOI: 10.16016/j.2097-0927.202206112.

[9] ABBASS R, BHATTI U, ASINGER S. Bayesian networks: making the most of a history[J]. Clin Teach, 2021, 18(2): 140-141. DOI: 10.1111/tct.13263.

[10] KYRIMI E, DUBE K, FENTON N, *et al*. Bayesian networks in healthcare: what is preventing their adoption?[J]. Artif Intell Med, 2021, 116: 102079. DOI: 10.1016/j.artmed.2021.102079.

[11] LUCAS P J F, VAN DER GAAG L C, ABU-HANNA A. Bayesian networks in biomedicine and health-care[J]. Artif Intell Med, 2004, 30(3): 201-214. DOI: 10.1016/j.artmed.2003.11.001.

[12] SANDRI M, BERCHIALLA P, BALDI I, *et al*. Dynamic Bayesian Networks to predict sequences of organ failures in patients admitted to ICU[J]. J Biomed Inform, 2014, 48: 106-113. DOI: 10.1016/j.jbi.2013.12.008.

[13] PEELEN L, DE KEIZER N F, JONGE E. Using hierarchical dynamic Bayesian networks to investigate dynamics of organ failure in patients in the Intensive Care Unit[J]. J Biomed Inform, 2010, 43(2): 273-286. DOI: 10.1016/j.jbi.2009.10.002.

[14] SESEN M B, NICHOLSON A E, BANARES-ALCANTARA R, *et al*. Bayesian networks for clinical decision support in lung cancer care[J]. PLoS One, 2013, 8(12): e82349. DOI: 10.1371/journal.pone.0082349.

[15] SESEN M B, PEAKE M D, BANARES-ALCANTARA R, *et al*. Lung Cancer Assistant: a hybrid clinical decision support application for lung cancer care[J]. J R Soc Interface, 2014, 11(98): 20140534. DOI: 10.1098/rsif.2014.0534.

[16] KUMAR M, VERMA G. Machine learning intrusion detection system based on MLP and RNN stochastic optimization technology[J]. J Res Sci Eng, 2022,4(6): 6-9. DOI: 10.53469/jrse.2022.04(06).02.

[17] ILIADIS L, NIKOLAIDIS S, SARIGIANNIDIS P, *et al*. Artwork style recognition using vision transformers and MLP mixer[J]. Technologies, 2021, 10(1): 2. DOI: 10.3390/technologies10010002.

[18] KLANN J, SCHADOW G, MCCOY J M. A recommendation algorithm for automating corollary order generation[J]. AMIA Annu Symp Proc, 2009, 2009: 333-337.

[19] KLANN J, SCHADOW G, DOWNS S M. A method to compute treatment suggestions from local order entry data[J]. AMIA Annu Symp Proc, 2010, 2010: 387-391.

(收稿:2023-01-01;修回:2023-02-16)

(编辑 栾 嘉)