

中图分类号: R969.3 文献标志码: A 文章编号: 1006-4931(2025)24-0088-05
doi:10.3969/j.issn.1006-4931.2025.24.018



腹膜透析相关性腹腔感染风险预测模型构建*

徐 涛, 葛齐敏, 黄 磊, 王阿明, 魏 筱, 宋 璐[△]

(南京大学医学院附属盐城第一医院·江苏省盐城市第一人民医院, 江苏 盐城 224000)

摘要:目的 构建腹膜透析相关性腹腔感染风险预测模型, 筛选关键预测因子。方法 回顾性选择医院肾内科2022年1月至2024年8月收治的接受腹膜透析治疗的患者232例, 按腹膜透析后是否发生腹腔感染分为感染组(64例)和无感染组(168例)。收集人口学特征、既往病史、实验室检查相关指标等资料, 经中心化与标准化预处理后, 按7:3比例随机分为训练集和测试集。构建极限梯度提升树(XGBoost)和Logistic回归(LR)、随机森林(RF)、支持向量机(SVM)共4种机器学习模型; 通过受试者工作特征曲线评估模型效能得出最佳模型, 并采用校准曲线进行验证。结果 在测试集中, LR模型综合性能最优, 其曲线下面积(AUC)为0.878, 敏感度为0.814、特异度为0.579、准确度为0.688, F1分数为0.629。校准曲线显示校准曲线斜率0.967(理想值=1.0)、截距0.014(理想值=0.0), $R^2 = 0.875$ 。LR模型筛选出的5个重要性变量分别为糖尿病视网膜病变、钾离子浓度、糖尿病肾病、总胆固醇、磷离子浓度。结论 基于LR模型可较好预测腹膜透析患者发生腹腔感染情况, 为高危患者的早期识别提供了量化依据。

关键词:腹膜透析; 腹腔感染; 机器学习; 模型构建; 药学服务

Construction of A Risk Prediction Model for Peritoneal Dialysis - Associated Intra - Abdominal Infection

XU Tao, GE Qimin, HUANG Lei, WANG Aming, WEI Xiao, SONG Lu

(Yancheng First Hospital, Affiliated Hospital of Nanjing University Medical School · The First People's Hospital of Yancheng, Yancheng, Jiangsu, China 224000)

Abstract: Objective To construct a risk prediction model for peritoneal dialysis - associated intra - abdominal infection and identify key predictors. **Methods** A retrospective study was conducted, a total of 232 patients who underwent peritoneal dialysis in the department of nephrology of the hospital from January 2022 to August 2024 were selected. They were divided into the infection group ($n = 64$) or the non - infection group ($n = 168$) according to the whether intra - abdominal infection occurred after peritoneal dialysis. Datas including demographic characteristics, past medical history, and laboratory test indexes were collected. Following centralized and standardized preprocessing, the data were randomly split into a training set and a test set at a ratio of 7:3. Four machine learning models were constructed: eXtreme Gradient Boosting (XGBoost), Logistic Regression (LR), Random Forest (RF), and Support Vector Machine (SVM). The model performance was evaluated using the receiver operating characteristic (ROC) curve to identify the optimal model, which was subsequently validated with a calibration curve. **Results** In the test set, the LR model demonstrated the best overall performance, with area under the curve (AUC) of 0.878, sensitivity of 0.814, specificity of 0.579, accuracy of 0.688, and F1 - score of 0.629. The calibration curve showed a slope of 0.967 (ideal value = 1.0), an intercept of 0.014 (ideal value = 0.0), and $R^2 = 0.875$. The five most important variables identified by the LR model were diabetic retinopathy, potassium ion concentration, diabetic nephropathy, total cholesterol, and serum phosphorus concentration. **Conclusion** The LR model demonstrates good performance in predicting the risk of intra - abdominal infection in patients undergoing peritoneal dialysis, which can provides a quantitative tool for the early identification of high - risk patients.

Key words: peritoneal dialysis; intra - abdominal infection; machine learning; model construction; pharmaceutical care

随着人口老龄化加剧及糖尿病、高血压等慢性疾病患病率不断升高, 慢性肾脏病(CKD)^[1-2]的发病率持续上升, 已成为一个日益严峻的公共卫生问题。据预测, 至2040年, CKD可能成为全球导致寿命缩短的五大疾病之一。CKD的诊断依据包括持续3个月以上估计肾小球滤过率(eGFR)低于 $60 \text{ mL} / (\text{min} \cdot 1.73 \text{ m}^2)$ ^[3], 和/或尿白蛋白排泄量 $\geq 30 \text{ mg} / 24 \text{ h}$ 。CKD的终末阶段, 即

终末期肾脏病(ESRD)^[2], 严重威胁患者的生存质量及影响长期预后。随着ESRD患者数的不断增加, 全球对肾脏替代治疗的需求也随之增长。在此背景下, 腹膜透析(PD)^[4]作为一种居家透析方式, 因其操作便捷及医疗成本较低等优势, 在亚洲等地区得到了广泛应用。然而, 接受透析治疗的患者, 尤其是PD患者, 发生感染的风险较普通人群显著增加, 其主要原因是透析导管相

*基金项目: 江苏省研究型医院学会精益化用药石药专项科研基金资助项目[JY202242]。

第一作者: 徐涛, 男, 大学本科, 工程师, 研究方向为医院信息处理, (电子信箱)649223152@qq.com。

[△]通信作者: 宋璐, 女, 硕士, 主管药师, 研究方向为肾脏内科学, (电子信箱)903166574@qq.com。

关感染及腹膜炎的发生。鉴于此,本研究中拟收集大量 ESRD^[5]患者临床数据,结合我院持续不卧床腹膜透析(CAPD)^[6]患者的检查数据,构建基于机器学习算法^[7]的感染风险预测模型,以实现 CAPD 患者腹腔感染发生风险的早期评估。机器学习法在处理高维数据、识别变量间复杂的交互作用及非线性关系方面有显著优势,目前已广泛应用于疾病诊断和风险预测模型构建中^[8-9],包括极限梯度提升树(XGBoost)、随机森林(RF)^[10]、支持向量机(SVM)和 Logistic 回归(LR)等。本研究中拟探讨 CAPD 患者腹腔感染的相关危险因素^[11],并构建相应预测模型,实现对高危患者的早期识别和预防性干预,以为减轻医疗系统财政负担、提升患者生活质量、延长患者生存期、降低病死率提供参考^[12]。现报道如下。

1 资料和方法

1.1 一般资料

纳入标准:规律透析至少 3 个月;资料完整。

排除标准:在随访时间节点内发生手术或外伤;随访无效;需行血液透析(HD)。

病例选择与分组:回顾性选取医院肾内科 2022 年 1 月至 2024 年 8 月收治的接受 PD 治疗的患者 232 例,按 PD 后是否发生腹腔感染分为感染组(64 例)和无感染组(168 例)。

1.2 数据收集

资料收集:收集患者的一般人口学特征、既往病史、实验室检查及感染后住院或门诊就诊的相关随访指标。基线资料包括性别、年龄、身高、体质量,合并症[糖尿病(DM)、糖尿病肾病(DN)、糖尿病视网膜病变(DR)]发生情况,以及血清铁蛋白、N 端脑利钠肽(NT-proBNP)、甲状旁腺激素(PTH)、白细胞计数(WBC)、血红蛋白(Hb)、血小板计数(PLT)、中性粒细胞百分比(N%)、尿酸(UA)、肌酐(CREA)、血钾(K⁺)、血钙(Ca²⁺)、血磷(P)、甘油三酯(TG)、总胆固醇(TC)水平。

结局指标:由 2 名临床药师和 1 名医师^[13]共同诊断并得出结论。

模型构建:首先,对 21 项临床指标进行单因素分析,以识别与腹腔感染发生风险相关的潜在因素。选出两组间存在显著差异的指标,进一步进行多变量分析。采用 XGBoost、LR、RF、SVM 4 种机器学习法,对有差异的指标进行影响因素的重要性分析。每种模型均采用直接训练法进行训练与验证,将患者按 7:3 比例随机分为训练集和测试集,以确保模型评估的稳健性。XGBoost 模型使用 Python 语言,基于 xgboost 1.2.1 库进行构建;LR、RF 和 SVM 模型基于 Python 的 sklearn 0.22.1

库实现;上述模型的性能可通过受试者操作特征(ROC)曲线(评估各模型的区分度,越接近 1 表示模型效果越好)及其曲线下面积(AUC)、敏感度、特异度、准确度和 F1 分数(是精准率和召回率的加权调和平均值,反映模型预测的敏感性,为 1 时模型效果最佳,为 0 时最差)等指标进行综合评价。

1.3 统计学处理

采用 SPSS 25.0 统计学软件及 Python 软件分析。排除缺失率 ≥ 30% 的指标,小于 30% 的数据采用线性多重填补法填补。服从正态分布的计量资料以 $\bar{X} \pm s$ 表示,行独立样本 *t* 检验;计数资料以例(%)表示,行 χ^2 检验。检验水准 $\alpha = 0.05$, $P < 0.05$ 为差异有统计学意义。

2 结果

2.1 单因素分析

两组患者的性别、年龄、身高、体质量,DM 例数、铁蛋白、NT-proBNP、PTH、UA、CREA、Ca²⁺、TG 水平比较,差异无统计学意义($P > 0.05$)。感染组 DN、DR 患者例数及 WBC、PLT、N%、TC 水平显著高于无感染组, Hb、K、P 水平显著低于无感染组($P < 0.05$)。详见表 1。

表 1 两组患者基线资料比较

Table 1 Comparison of baseline data between the two groups

项目	无感染组(<i>n</i> = 168)	感染组(<i>n</i> = 64)	χ^2/t 值	<i>P</i> 值
性别[例(%)]	男	109(64.88)	0.605	0.437
	女	59(35.12)		
身高($\bar{X} \pm s$, cm)	166.47 ± 9.77	165.97 ± 7.64	0.372	0.710
体质量($\bar{X} \pm s$, kg)	66.86 ± 11.15	64.83 ± 11.24	1.237	0.217
年龄($\bar{X} \pm s$, 岁)	48.08 ± 14.33	51.58 ± 15.55	1.624	0.106
DM[例(%)]	59(35.12)	31(48.44)	3.462	0.063
DN[例(%)]	19(11.31)	30(46.87)	35.187	< 0.001
DR[例(%)]	16(9.52)	30(46.87)	40.674	< 0.001
铁蛋白($\bar{X} \pm s$, ng/mL)	289.83 ± 292.76	241.51 ± 248.04	1.170	0.243
NT-proBNP($\bar{X} \pm s$, pg/mL)	12 659.74 ± 12 471.43	14 946.30 ± 12 485.64	1.248	0.213
PTH($\bar{X} \pm s$, pg/mL)	373.67 ± 418.33	439.32 ± 494.65	1.014	0.311
WBC($\bar{X} \pm s$, × 10 ⁹ /L)	6.77 ± 3.19	9.42 ± 4.43	5.054	< 0.001
Hb($\bar{X} \pm s$, g/L)	104.92 ± 27.47	94.77 ± 18.50	2.729	0.007
PLT($\bar{X} \pm s$, × 10 ⁹ /L)	188.04 ± 72.75	225.05 ± 81.57	3.347	0.001
N%($\bar{X} \pm s$, %)	72.28 ± 10.41	79.89 ± 10.10	5.022	< 0.001
UA($\bar{X} \pm s$, μmol/L)	390.56 ± 129.89	370.30 ± 87.66	1.151	0.251
CREA($\bar{X} \pm s$, μmol/L)	996.03 ± 315.49	911.40 ± 357.12	1.759	0.080
K ⁺ ($\bar{X} \pm s$, mmol/L)	3.90 ± 0.90	3.39 ± 0.62	4.147	< 0.001
Ca ²⁺ ($\bar{X} \pm s$, mmol/L)	2.12 ± 0.24	2.04 ± 0.24	2.084	0.038
P($\bar{X} \pm s$, mmol/L)	1.83 ± 0.58	1.51 ± 0.49	3.854	< 0.001
TG($\bar{X} \pm s$, mmol/L)	1.98 ± 1.47	1.90 ± 1.41	0.363	0.717
TC($\bar{X} \pm s$, mmol/L)	3.93 ± 1.20	4.43 ± 1.40	2.676	0.008

2.2 风险影响因素特征

将单因素分析中有统计学意义的9个影响因素分别通过4个模型进行参数的重要性分析,重要性指标取前5位,发现不同机器学习模型中重要性存在较大差异。其中LR、SVM模型参数重要性主要集中在DR与K⁺,而RF分析模型主要为WBC、N%及K⁺,XGBoost分析模型主要为DN、WBC、DR。详见图1。




Fig.1 Ranking of the importance of machine learning indicators

2.3 模型构建

将9个影响因素分别输入4种学习模型,采用直接训练法对各模型进行训练与验证,测试集占整体30%。XGBoost模型参数为objective(优化目标函数)=binary,logistic;learning_rate(学习速率)=0.3;n_estimators(树数目)=100。RF模型参数为criterion(度量指标)=gini;max_depth(最大树木深度)=15;min_impurity_decrease(最小分叉纯度收益)=2;n_estimators(树数目)=100。SVM模型参数为C(正则化因子)=1;kernel(核类型)=rbf。LR模型参数为C(正则化因子)=1;penalty(正则化类型)=l2;Solver=Lbfgs。各模型性能评价见表2、表3(训练集中XGBoost所有指标与RF模型相等)。测试集中,LR模型的AUC、敏感度、准确度、F1分数较高,优于其他模型,其校准曲线斜率为0.967,截距为0.014,R²=0.875。各模型ROC曲线见图2。

表2 训练集各模型性能评价

Tab.2 Performance evaluation of various models in the training set

模型	AUC	敏感度	特异度	准确度	F1 分数
LR	0.899	0.839	0.667	0.732	0.698
RF	1.000	1.000	1.000	1.000	1.000
SVM	0.896	0.889	0.800	0.800	0.800
XGBoost	1.000	1.000	1.000	1.000	1.000

表3 测试集各模型性能评价

Tab.3 Performance evaluation of various models in the test set

模型	AUC	敏感度	特异度	准确度	F1 分数
LR	0.878	0.814	0.579	0.688	0.629
RF	0.838	0.757	0.421	0.571	0.485
SVM	0.873	0.771	0.526	0.588	0.556
XGBoost	0.836	0.757	0.474	0.563	0.514




Fig.2 ROC curves of various models

3 讨论

全球范围内,ESRD发病率呈显著的地域性差异,美国、东亚及东南亚地区发病率较高^[14-15]。其原因可能与上述地区早期CKD患者群及携带ESRD前期危险因素的人群规模较大有关。这些危险因素包括DM、高血压、肥胖和肾小球疾病等^[16-17]。尽管部分高收入国家由DM引起的ESRD发病率已趋于稳定或逐渐下降,反映系统性管控和延缓CKD发生及进展的措施取得了一定成效。然而,在东亚和东南亚地区,ESRD的发病率仍呈逐年上升,需引起关注^[18]。在我国,ESRD患者的肾脏替代治疗措施主要包括PD和HD^[19]。感染是影响这些患者长期生存质量和短期生存状态的重要危险因素,长期研究表明,感染是导致ESRD患者在接受PD治疗过程中死亡的第二大原因^[20]。此外,尽管PD和HD患

者的死亡风险无显著差异且生存结局相似^[21],但 PD 患者感染相关的总体再入院风险更高,这种风险主要是由透析相关的感染引起的。

本研究中,感染组患者合并 DN 和 DR 的比例显著高于无感染组^[22],表明 DM 患者由于免疫功能受损和微血管病变,更易发生感染,与已有结论^[23]一致。DM 患者的高血糖状态可能导致白细胞功能异常,包括趋化、吞噬和杀菌能力下降,从而削弱了机体对感染的防御能力。此外,DN 的存在可能进一步加剧患者的免疫缺陷,增加感染风险。DM 患者易感染的机制包括细胞因子产生受损、白细胞募集抑制、病原体识别缺陷、中性粒细胞功能障碍、巨噬细胞功能障碍及自然杀伤细胞功能障碍等。此外,Hb 水平的降低也与感染风险增加相关^[24],贫血是 CKD 患者常见并发症,低 Hb 水平可能反映了患者的整体健康状况较差,从而增加了感染的风险。有研究表明慢性透析患者 Hb 水平 < 11 g/dL (110 g/L) 的死亡率显著高于 12~14 g/dL (120~140 g/L) 的患者^[24]。

本研究中成功构建并验证了基于机器学习的预测模型,并对 4 种机器学习模型进行比较,其中 XGBoost 为基于梯度提升决策树的集成学习算法,通过构建多棵决策树并进行迭代优化,以提高模型的预测性能^[25];LR 为经典的统计模型,主要用于解决二分类问题,其核心是通过 logit 函数将线性组合映射到概率空间^[26];RF 为基于决策树的集成方法,通过构建多棵随机决策树并进行投票或平均,以提高模型的泛化能力和抗过拟合能力^[27];SVM 为基于最大间隔分类的算法,通过将数据映射到高维空间并寻找最优超平面,适用于小样本和高维数据的分类问题^[28]。这 4 种模型在机器学习中各有特点,XGBoost 和 RF 属于集成学习方法,适用于复杂数据模式的建模;LR 和 SVM 则分别在处理线性可分和非线性可分问题上具有优势。本研究结果显示,LR 预测模型显示出良好的预测性能,可用于预测 PD 患者感染风险^[29]。

综上所述,本研究中基于机器学习的预测模型为 PD 患者腹腔感染的风险评估提供了新的视角。此模型通过识别关键的风险因素,有助于临床医师提前识别高风险患者,并采取预防措施,以减少感染的发生,改善患者预后。未来的研究应继续探索和优化这些模型,以进一步提高预测的准确性和临床应用价值。此外,还应强调在 ESRD 患者管理中,严格控制 DM、DR 和贫血等并发症的重要性,因为这些因素不仅影响患者的透析效果和生存质量,也是感染风险的重要预测指标^[30-31]。未来的研究应进一步探索这些风险因素之间的相互作用^[32],及其影响 PD 患者的感染风险的机制,

以便开发出更全面、更有效的预防策略。

参考文献

- [1] Improving Global Outcomes (KDIGO) CKD Work Group. KDIGO 2024 Clinical Practice Guideline for the Evaluation and Management of Chronic Kidney Disease[J]. *Kidney Int*, 2024, 105(4S):S117-S314.
- [2] KUEHN BM. End-stage Kidney Disease Doubles[J]. *JAMA*, 2022, 327(16):1540.
- [3] INKER LA, TITAN S. Measurement and Estimation of GFR for Use in Clinical Practice: Core Curriculum 2021 [J]. *Am J Kidney Dis*, 2021, 78(5):736-749.
- [4] GOKAL R, MALLICK NP. Peritoneal dialysis [J]. *Lancet*, 1999, 353(9155):823-828.
- [5] The Lancet Global Health. End-stage kidney disease in LMICs: rising to the challenge[J]. *Lancet Glob Health*, 2017, 5(4):e370.
- [6] TEEHAN BP, HAKIM R. Continuous ambulatory peritoneal dialysis — quo vadis? [J]. *J Am Soc Nephrol*, 1995, 6(2):139-143.
- [7] GREENER JG, KANDATHIL SM, MOFFAT L, et al. A guide to machine learning for biologists [J]. *Nat Rev Mol Cell Biol*, 2022, 23(1):40-55.
- [8] DEO RC. Machine Learning in Medicine[J]. *Circulation*, 2015, 132(20):1920-1930.
- [9] SIDEY - GIBBONS JAM, SIDEY - GIBBONS CJ. Machine learning in medicine: a practical introduction [J]. *BMC Med Res Methodol*, 2019, 19(1):64.
- [10] JIN Y, LAN A, DAI Y, et al. Development and testing of a random forest-based machine learning model for predicting events among breast cancer patients with a poor response to neoadjuvant chemotherapy [J]. *Eur J Med Res*, 2023, 28(1):394.
- [11] CHO Y, CHOW KM, KAM - TAO LP, et al. Peritoneal Dialysis - Related Infections [J]. *Clin J Am Soc Nephrol*, 2024, 19(5):641-649.
- [12] KHAN SF. Updates on Infectious and Other Complications in Peritoneal Dialysis: Core Curriculum 2023 [J]. *Am J Kidney Dis*, 2023, 82(4):481-490.
- [13] Corrigendum to 2022 ISPD Peritonitis Guidelines: 2022 update on prevention and treatment [J]. *Perit Dial Int*, 2023, 43(3):279.
- [14] WOUK N. End-stage Renal Disease: Medical Management [J]. *Am Fam Physician*, 2021, 104(5):493-499.
- [15] FRANCIS A, HARHAY MN, ONG ACM, et al. Chronic kidney disease and the global public health agenda: an international consensus [J]. *Nat Rev Nephrol*, 2024, 20(7):473-485.
- [16] SILVA GFS, FAGUNDES TP, TEIXEIRA BC, et al. Machine Learning for Hypertension Prediction: a Systematic Review [J]. *Curr Hypertens Rep*, 2022, 24(11):523-533.
- [17] OKADA E, OISHI D, SAKURADA T, et al. A Comparison