

DOI: 10.3969/j.issn.1671-024x.2025.04.003

基于连续无创生理参数驱动的死亡事件动态预警

赵喆^{1,2,3}, 赵鑫浩^{1,2,3}, 郭宇^{1,2}, 徐佳盟^{1,2,3}, 耿雪荞⁴

(1. 天津工业大学 生命科学学院, 天津 300387; 2. 天津工业大学 纺织未来技术研究中心, 天津 300387; 3. 天津工业大学 天津市医疗器械质量控制与评价重点实验室, 天津 300387; 4. 天津工业大学 校医院, 天津 300387)

摘要: 为实现基于无创生理参数的重症患者死亡事件动态预警, 从 eICU 合作研究数据库中提取了 4 738 名成年患者的 30 个参数, 经过独热编码、采样率一致性处理和数据插补等预处理后, 作为 LightGBM 模型输入并训练模型; 在学习窗口与预测窗口之间加入前瞻窗口, 为医生决策提供宝贵时间, 并采用 10 折交叉验证方法优化模型参数, 以构建最佳死亡事件动态预警模型。研究结果表明: 所构建模型预测准确率为 0.852, ROC 曲线下的面积为 0.875; 该模型预测性能与学习窗口呈正相关, 与前瞻窗口呈负相关; 基于连续无创参数的死亡事件动态预警模型可实现对重症患者死亡事件的及时发现, 避免了传统方法对实验室参数的依赖, 为患者救治策略的制定争取了宝贵的前瞻时间, 大大提高了医务人员的工作效率和患者的救治效果。

关键词: 无创参数; 机器学习; 死亡事件预测; 动态预警

中图分类号: TP391; R195.1

文献标志码: A

文章编号: 1671-024X(2025)04-0013-06

Dynamic warning of mortality events based on continuous noninvasive physiological parameters

ZHAO Zhe^{1,2,3}, ZHAO Xinhao^{1,2,3}, GUO Yu^{1,2}, XU Jiameng^{1,2,3}, GENG Xueqiao⁴

(1. School of Life Science, Tiangong University, Tianjin 300387, China; 2. Research Center for Future Textile Technology, Tiangong University, Tianjin 300387, China; 3. Tianjin Key Laboratory of Quality Control and Evaluation Technology for Medical Devices, Tiangong University, Tianjin 300387, China; 4. University Hospital, Tiangong University, Tianjin 300387, China)

Abstract: To achieve dynamic early warning of mortality events in critically ill patients based on non-invasive physiological parameters, 30 parameters from 4 738 adult patients were extracted from the eICU Collaborative Research Database. After preprocessing including one-hot encoding, sampling rate consistency processing, and data imputation, the data were input into and used to train a LightGBM model. A lookahead window was added between the learning window and the prediction window to provide valuable decision-making time for doctors, and a 10-fold cross-validation method was used to optimize the model parameters, constructing the optimal dynamic early warning model for mortality events. The results showed that the prediction accuracy of the constructed model was 0.852, and the area under the ROC curve was 0.875. The predictive performance of the model was positively correlated with the learning window and negatively correlated with the lookahead window. The dynamic early warning model based on continuous non-invasive parameters can timely detect mortality events in critically ill patients, avoiding the dependence on laboratory parameters in traditional methods, gaining valuable foresight time for the formulation of patient treatment strategies, and greatly improving the work efficiency of medical staff and patient treatment outcomes.

Key words: non-invasive parameter; machine learning; death events prediction; dynamic warning

随着电子病历数据的不断积累, 传统的统计方法在处理高维度和庞杂数量的重症监护数据时显现出

效率低和准确性低等不足之处^[1-3]。挖掘和分析患者生理参数中的潜在规律, 探索基于无创参数建立死亡

收稿日期: 2023-12-25 基金项目: 国家重点研发计划项目(2023YFC3011800)

第一作者: 赵喆(1986—), 女, 博士, 副教授, 主要研究方向为信号处理。E-mail: zhaozhe@tiangong.edu.cn

通信作者: 耿雪荞(1977—), 女, 主治医师, 主要研究方向为内科常见病诊疗、传染病防控及健康教育。E-mail: gengxueqiao@aliyun.com

事件实时动态预警模型的可行性,能够使得医护人员及时制定治疗方案、提供早期临床干预,从而有效降低死亡率。临床上有许多现有的患者病情程度评分模型,如序贯性器官衰竭评估(SOFA)^[4]、急性生理与慢性健康评分(APACHE-I)^[5]和简化急性生理评分(SAPAAII)^[6]等。然而,上述方法使用率较低,据研究表明只有 12%的重症患者使用了上述评分模型^[7]。现有的患者病情程度评分模型主要存在以下问题:高度依赖实验室参数和医护人员主观评分,难以做到实时检测,导致无法在第一时间敏锐捕捉到患者病情中潜藏的恶化迹象,错失及时干预的最佳时机;现有系统多采用逻辑回归,把变量间关系简单设为线性叠加,不能反映真实病情,难以满足临床要求^[8-9];现有方法大多只考虑生理参数的当前值,没有考虑参数在时间维度上的变化和统计特征,因此丢失了大量有用的多维信息^[10]。如何分析海量的生理参数,从中提取有价值的信息,降低预测成本,已成为医学和数据挖掘领域的热点和难点^[11-13]。

机器学习技术在死亡事件预测和多种并发症概率评估预测领域具有明显优势^[14-15]。Weissman 等^[16]评估了 logistic 回归、随机森林和弹性网络模型在死亡事件预测中的性能。结果表明,该模型 ROC 曲线下面积(AUC)为 0.89。然而,该模型使用了一些难以实时连续采集的实验室参数,如白细胞最大数量、血小板最大数量等。Rongali 等^[17]使用电子健康记录数据开发了一种预测死亡事件的深度学习模型,其 AUC 为 0.95,但是由于深度学习模型需要大量计算,这些模型的临床应用受到普通处理器相对较低计算能力的限制。预

测患者死亡概率的研究对于辅助临床决策、提高危重患者的生存率具有重要意义。然而,上述研究方法皆依赖实验室生理参数,在院前急救场景下,面临数据采集不便、成本高昂、耗时久等难题,致使无法实时、动态地预测患者潜在死亡风险。另一方面,输入特征繁杂、计算复杂度大,并且严重依赖高性能硬件,这些因素极大地限制了其应用场景。

为了预判重症患者的死亡事件,以便及时采取救治措施,本文利用机器学习方法开发了一种基于连续无创参数的死亡事件动态预警模型。为了让医护人员在模型报警后有充足时间制定临床治疗方案,模型在预测患者死亡事件的时间之前加入了前瞻时间,作为医生收到预测结果后的决策时间,此窗口为患者的救治提供珍贵的前瞻时间。前瞻时间长度可以根据使用场景进行灵活调整,进一步提高了该方法的实用性。此外,本文进一步分析了输入模型的数据时间长度和前瞻时间长度对死亡事件实时动态预测模型的性能影响,验证了机器学习模型在死亡事件实时动态预测上的可行性和有效性。

1 死亡事件动态预警模型

本文研究路线如图 1 所示。首先对数据库数据进行挑选;其次对无创参数进行预处理,获取完整结构化数据;最后基于无创参数,建立死亡事件动态预警模型并分析模型性能。

1.1 数据来源及人群

本文使用飞利浦医疗公司开发的一个远程医疗

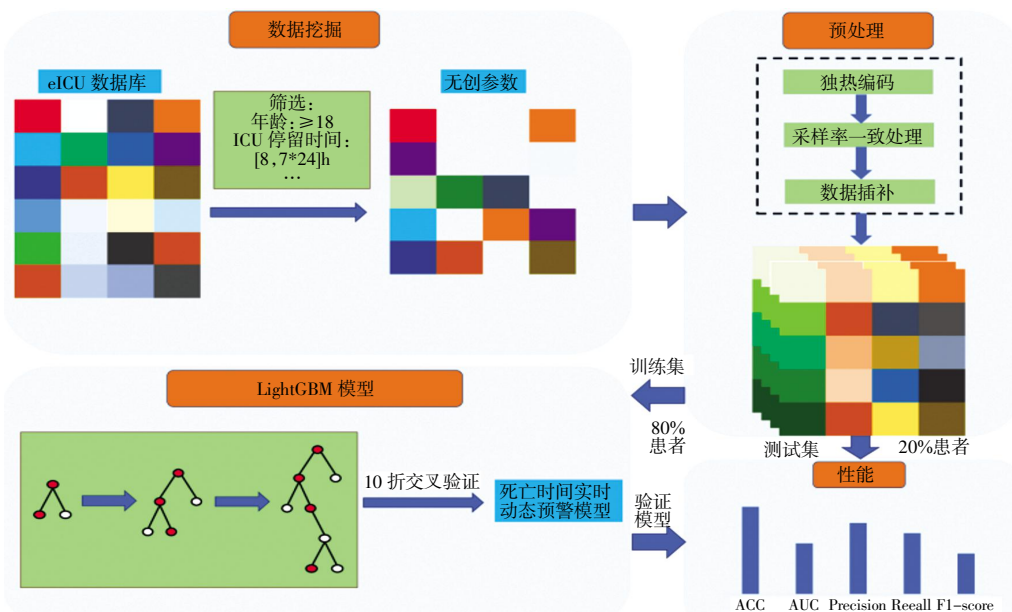


图 1 技术路线框图

Fig.1 Block diagram of technical route

数据库——eICU 合作研究数据库。该数据库涵盖生命体征测量数据、护理计划文档、疾病严重程度评估结果、诊断详情、治疗信息等,数据来源覆盖 208 家医院的患者^[18]。本文将数据库中所有年龄 ≥ 18 岁、在 ICU 停留时间超过 8 h 但不超过 7 d 的患者作为研究对象,共计来自 159 个医院的 4 738 名患者。

1.2 数据预处理

从电子病历中提取 30 个无创参数,包括 10 个人工测量参数和来自监测仪的 20 个无创生理参数。其中,人工测量参数包括年龄、性别、BMI 指数、排尿量、机械通气状态、格拉斯哥评分、疼痛分数、液体排除量;无创生理参数包括吸入氧气浓度、心率、无创收缩压、无创舒张压、无创平均压、动脉氧饱和度、呼气末正压、氧气流速、呼气末二氧化碳、呼吸率(患者)、每千克潮气量、平台压、吸气峰压、平均气道压、压力支持、高峰流速、氧流量、潮气量(患者)、潮气量(实际)、分钟通气量。

对所提取的数据进行以下处理:首先对性别和机械通气状态进行独热编码^[19]处理,将性别和机械通气状态的二维特征转化为四维特征,分为是否为男[1,0,0,0]、是否为女[0,1,0,0]、是否进行机械通气[0,0,1,0]和是否不进行机械通气[0,0,0,1]。其他参数采用电子病历中每小时数据的中位数,以统一采样频率。如果参数在 1 h 内没有有效值则视为数据缺失,使用式(1)做前向插补处理^[20]。

$$y_t = y_{t-1} \quad (1)$$

式中: y_{t-1} 为时间点 $t-1$ 的数据; y_t 为时间点 t 的数据。

特别的,对出现机械通气状态缺失的患者,如果缺失点为患者进入 ICU 的第 1 h,则以患者未进行通气状态进行插补,否则用前 1 h 数据进行前向插补。对出现排尿量缺失的患者,如果缺失点为患者进入 ICU 的第 1 h,则使用固定 0 值进行插补,否则用前 1 h 数据进行前向插补。

在数据对齐方面,首先在时间对齐上,通过以入院时间为基准来对齐时间,确保了所有患者数据的一致性。此外,将无创生理参数设置为结构化数据,并对性别和机械通气状态进行独热编码处理,有助于保持数据的整洁和一致性,提高模型的可解释性。每行数据代表从患者入院开始的某个相对时间点的所有无创生理参数特征值,便于在后续分析中追踪和比较不同时间点的数据变化。

1.3 模型开发和评价方法

本文基于 LightGBM^[21]模型,使用预处理后的数据作为模型输入,根据患者入住的医院编号作为分组标准,按照 4:1 比例划分训练集和测试集,保证测试集

没有信息泄露。在训练集中采用 10 折交叉验证训练模型,并采用贝叶斯公式获取所有在训练之前需要设定或调整的参数(超参),从而获得最佳模型。

本文根据学习窗口、前瞻窗口和预测窗口建立死亡事件预测模型。学习窗口为特征提取时间段,利用该窗口的数据训练模型;预测窗口为模型预测死亡事件的时间段;前瞻窗口作为预测窗口的前瞻时间,为医生提供决策时间,三者关系如图 2 所示。




图2 学习窗口、前瞻窗口、预测窗口关系示意

Fig.2 Schematic diagram of relationship between learning window, lookahead window, and forecasting window

图 2 中, T_0 代表患者入住 ICU 的时间点, T_1 为当前时间点,学习窗口定义为 $[T_1 - x_1: T_1]$ ($x_1 = 1, 4, 8, 12$ h)。 x_2 ($x_2 = 1, 4, 8, 12$ h)定义为前瞻窗口的时间长度。 $[T_1 + x_2: T_1 + x_2 + 4]$ 时间段定义为预测窗口。随着 T_1 的后移,3 个窗口一起移动,从而实现实时动态预测。LightGBM 模型的目标函数表示为:

$$L(\Theta) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^n \Omega(f_k) \quad (2)$$

式中: $l(y_i, \hat{y}_i)$ 为 LightGBM 模型的损失函数,以衡量真实值 y_i 和预测值 \hat{y}_i 之间的差;同时为了解决过拟合问题,引入 $\Omega(f_k)$ 以控制树的复杂度。在引入学习窗口、前瞻窗口和预测窗口后,预测时间段 t 可表示为:

$$t = T_1 + x_2 \quad (x_2 = 1, 4, 8, 12) \quad (3)$$

则 LightGBM 的目标函数可进一步表示为:

$$L(\Theta) = \sum_{i=1}^n l(y_{(T_1+x_2)}, \hat{y}_{(T_1+x_2)}) + \sum_{k=1}^n \Omega(f_k) \quad (4)$$

本文利用 10 折交叉验证,基于训练集对模型进行训练调整,使用 ROC 曲线下的面积(AUC)作为模型评价指标,进行重点分析。

2 预警性能分析

2.1 相关性分析

对提取的所有特征进行统计学分析,使用 Pearson 相关系数计算特征之间相关性,并进行显著性分级,如图 3 所示,其中 * 为 $P \leq 0.05$,** 为 $P \leq 0.01$ 。

当 2 个指标之间相关性超过 0.8 并且显著性(P) < 0.01 时,认为两特征之间存在冗余,当某一特征与其




图 3 特征之间相关性分析

Fig.3 Correlation analysis between features

他所有特征存在冗余时,认为该特征可以被其他特征表示。由图 3 可看出,有 4 组特征之间存在冗余,比如无创收缩压和无创平均压,但是不存在某一特征与其他所有特征都冗余,故所有特征都保留。

2.2 死亡事件动态预警模型性能分析

本文计算了不同学习窗口和前瞻窗口下的死亡事件预警模型的指标。学习窗口和前瞻窗口均设置为 1、4、8 和 12 h^[22]。窗口设为 1 h 时,模型是基于最小数据集构建的,可以作为评估不同模型准确性的基准。考虑到 8 h 为典型的护士轮班时长,将窗口设定为 8 h 旨在降低模型复杂度的同时,最大化模型的预测精度。此外,鉴于本研究为回顾性分析,本文以 8 h 为中心,额外设置了 4 h 和 12 h 的适中窗口大小,以全面评估模型的性能。选择 AUC 值最大的窗口,即学习窗口为 12 h,前瞻窗口为 1 h,绘制死亡事件动态预警模型的混淆矩阵和 ROC 曲线,如图 4 和图 5 所示。图 5 中 AUC 值为 0.875,表明模型具有较高的准确性。

表 1 为不同学习窗口和前瞻窗口下死亡事件动态预警模型的 AUC 值。

由表 1 可以看出,当学习窗口为 12 h 且前瞻窗口为 1 h 时,模型 AUC 值最大,达到 0.875;当学习窗口为 1 h 且前瞻窗口为 12 h 时,模型 AUC 最小,达到 0.708。当前瞻窗口固定不变时,模型 AUC 值随着学习窗口的增大而增大,当前瞻窗口为 12 h 时,与学习窗口为 1 h 相比,学习窗口为 12 h 的模型 AUC 增加了 0.059,在所




图 4 学习窗口 12 h 和前瞻窗口 1 h 下的死亡事件动态预警模型混淆矩阵

Fig.4 Confusion matrix for dynamic early warning model for fatalities under learning window of 12 h and lookahead window of 1 h




图 5 学习窗口 12 h 和前瞻窗口 12 h 下的死亡事件动态预警模型 ROC 曲线

Fig.5 ROC curves of dynamic early warning model for fatal events under learning window of 12 h and lookahead window of 1 h

表 1 不同学习窗口和前瞻窗口下的死亡事件动态预警模型的 AUC 值

Tab.1 AUC values of dynamic early warning models for fatal events with different learning and lookahead windows

学习窗口	前瞻窗口			
	1 h	4 h	8 h	12 h
1 h	0.820	0.818	0.795	0.708
4 h	0.840	0.836	0.799	0.767
8 h	0.874	0.830	0.819	0.713
12 h	0.875	0.857	0.821	0.767

有前瞻窗口中差异最大;当学习窗口固定不变时,模型 AUC 值随着前瞻窗口的增大而降低,当学习窗口为 12 h 时,与前瞻窗口为 1 h 相比,前瞻窗口为 12 h 的 AUC 下降了 0.108,在所有学习窗口中差异最大。这种变化规律符合预期结果。随着学习窗口的增大,训练集包含信息越多,模型训练的效果越好;而随着前瞻窗口的增大,模型预测的时间越晚,患者病情变化越复杂,预测的效果越差。

2.3 特征排序

为了反映每个无创生理参数在死亡事件动态预测中的贡献,本文固定学习窗口和前瞻窗口均为 1 h,统计了预测模型的特征权重,如表 2 所示。

表 2 死亡事件动态预警模型的特征权重值

Tab.2 Values of feature weights for a dynamic early warning model for fatal events

特征名称	特征权重	累计权重
吸入氧气浓度	0.177	0.177
心率	0.112	0.289
无创收缩压	0.079	0.368
格拉斯哥评分	0.063	0.431
无创平均压	0.063	0.493
无创舒张压	0.061	0.554
动脉氧饱和度	0.057	0.611
进行机械通气	0.055	0.666
呼气末正压	0.045	0.711
呼吸率(患者)	0.045	0.756
平台压	0.045	0.800
液体排除量	0.033	0.833
不进行机械通气	0.024	0.857
排尿量	0.022	0.879
氧气流速	0.018	0.897
身体质量指数	0.015	0.912
每千克潮气量	0.015	0.927
男	0.015	0.942
平均气道压	0.013	0.955
吸气峰压	0.010	0.966
分钟通气量	0.009	0.975
氧流量	0.006	0.981
年龄	0.003	0.984
女	0.003	0.987
压力支持	0.003	0.990
高峰流速	0.003	0.993

续表 2

特征名称	特征权重	累计权重
潮气量(患者)	0.003	0.996
疼痛分数	0.001	0.997
呼气末二氧化碳	0.001	0.999
潮气量(实际)	0.001	1.000

由表 2 可以看出,吸入氧气浓度、心率和无创收缩压权重占比最高,这类参数反应了患者氧合情况、循环状态和神经系统功能,与患者生命体征密切相关。另一方面,年龄、性别、疼痛分数等参数权重占比较低,这类参数易受患者个体差异影响。因此,基于无创参数的患者死亡事件实时动态预警模型主要关注患者的生理功能和器官衰竭程度,而不是患者的一般特征或主观感受。

3 结 论

为了实现基于连续无创参数的死亡事件动态预警,降低患者死亡风险,本文从 eICU 合作研究数据库中提取了 4 738 名成年患者的 30 个参数,经过独热编码、采样率一致性处理和数据插补等预处理后,作为 LighGBM 模型输入并训练模型;在学习窗口与预测窗口之间加入前瞻窗口,为医生决策提供宝贵时间,并采用 10 折交叉验证方法优化模型参数,以构建最佳死亡事件动态预警模型。研究结果表明:

(1) 该模型可实现前瞻窗口后 4 h 内患者死亡事件的准确预测,模型最大 AUC 值为 0.875。

(2) 本文证明了仅使用无创参数来实现死亡事件动态预测的可行性,避免了传统方法对实验室参数的依赖,可为医生提供有价值的决策支持。

(3) 该模型预测性能与学习窗口呈正相关,与前瞻窗口呈负相关。学习窗口越大,预测效果越好;前瞻窗口越大,预测准确性越低。

基于上述结果,提出了进一步的研究方向:

(1) 作为一项回顾性研究,本文无法模拟医疗环境。未来可根据不同的医疗环境,开发特定的死亡事件实时动态预测模型,并通过不同机器学习算法进行验证,以确定最优算法模型。

(2) 本文所使用的数据经过筛选和清洗,减少了噪声的影响。为了使本方法更具有普适性和鲁棒性,适合更多的临床环境,未来应该开发新的多模态方法,提高模型的抗干扰能力。

(3) 考虑算法的复杂性及未来嵌入式系统集成应用的可能性,本文采用统一的时间间隔来提取各种无创生理参数,以简化算法的复杂度。未来可以根据各

个生理参数的特点,采用自适应的时间间隔来进一步提升模型的准确性。

(4) 未来可以通过优化机器学习算法,实现在较短的学习窗口和较长的前瞻窗口下,获得稳定和准确的预测结果。

参考文献:

- [1] NEMATI S, HOLDER A, RAZMI F, et al. An interpretable machine learning model for accurate prediction of sepsis in the ICU[J]. *Critical Care Medicine*, 2018, 46(4): 547-553.
- [2] SAMAD M D, ULLOA A, WEHNER G J, et al. Predicting survival from large echocardiography and electronic health record datasets optimization with machine learning[J]. *JACC: Cardiovascular Imaging*, 2019, 12(4): 681-689.
- [3] FORREST I S, PETRAZZINI B O, DUFFY Á, et al. Machine learning-based marker for coronary artery disease: Derivation and validation in two longitudinal cohorts[J]. *The Lancet*, 2023, 401(10372): 215-225.
- [4] FREUND Y, LEMACHATTI N, KRASTINOVA E, et al. Prognostic accuracy of sepsis-3 criteria for in-hospital mortality among patients with suspected infection presenting to the emergency department[J]. *JAMA*, 2017, 317(3): 301-308.
- [5] HOPKINS R O, SUCHYTA M R, KAMDAR B B, et al. Instrumental activities of daily living after critical illness: A systematic review[J]. *Annals of the American Thoracic Society*, 2017, 14(8): 1332-1343.
- [6] SHROPE-MOK S R, PROPST K A, IYENGAR R. APACHE IV versus PPI for predicting community hospital ICU mortality[J]. *The American Journal of Hospice & Palliative Care*, 2010, 27(4): 243-247.
- [7] BRESLOW M J, BADAWI O. Severity scoring in the critically ill part 2: Maximizing value from outcome prediction scoring systems[J]. *Chest*, 2012, 141(2): 518-527.
- [8] BENEDETTO U, DIMAGLI A, SINHA S, et al. Machine learning improves mortality risk prediction after cardiac surgery: Systematic review and meta-analysis[J]. *The Journal of Thoracic and Cardiovascular Surgery*, 2022, 163(6): 2075-2087.
- [9] MEYER A, ZVERINSKI D, PFAHRINGER B, et al. Machine learning for real-time prediction of complications in critical care: A retrospective study[J]. *The Lancet Respiratory Medicine*, 2018, 6(12): 905-914.
- [10] TSAI P J, CHEN P C, CHEN Y Y, et al. Length of hospital stay prediction at the admission stage for cardiology patients using artificial neural network[J]. *Journal of Healthcare Engineering*, 2016, 2016: 7035463.
- [11] YANG J, LI Y J, LIU Q Q, et al. Brief introduction of medical database and data mining technology in big data era[J]. *Journal of Evidence-Based Medicine*, 2020, 13(1): 57-69.
- [12] HULSEN T, JAMUAR S S, MOODY A R, et al. From big data to precision medicine[J]. *Frontiers in Medicine*, 2019, 6: 34.
- [13] MAHMUD M, SHAMIM KAISER M, MARTIN MCGINNITY T, et al. Deep learning in mining biological data[J]. *Cognitive Computation*, 2021, 13(1): 1-33.
- [14] YANG P C, WU T H, YU M, et al. A new method for identifying the acute respiratory distress syndrome disease based on noninvasive physiological parameters[J]. *PLoS One*, 2020, 15(2): e0226962.
- [15] 陶祥兴, 杨峥, 季彦颢. 基于机器学习的 Lee-Carter 模型死亡率预测方法研究[J]. *人口与经济*, 2022(6): 47-57.
- TAO X X, YANG Z, JI Y T. Research on the prediction method of death rate of Lee-Carter model based on machine learning[J]. *Population & Economics*, 2022(6): 47-57 (in Chinese).
- [16] WEISSMAN G E, HUBBARD R A, UNGAR L H, et al. Inclusion of unstructured clinical text improves early prediction of death or prolonged ICU stay[J]. *Critical Care Medicine*, 2018, 46(7): 1125-1132.
- [17] RONGALI S, ROSE A J, MCMANUS D D, et al. Learning latent space representations to predict patient outcomes: Model development and validation[J]. *Journal of Medical Internet Research*, 2020, 22(3): e16374.
- [18] POLLARD T J, JOHNSON A E W, RAFFA J D, et al. The e-ICU collaborative research database, a freely available multi-center database for critical care research[J]. *Scientific Data*, 2018, 5: 180178.
- [19] GU B, SUNG Y. Enhanced reinforcement learning method combining one-hot encoding-based vectors for CNN-based alternative high-level decisions[J]. *Applied Sciences*, 2021, 11(3): 1291.
- [20] JANJÍČ T, BORMANN N, BOCQUET M, et al. On the representation error in data assimilation[J]. *Quarterly Journal of the Royal Meteorological Society*, 2018, 144(713): 1257-1278.
- [21] HAJIHOSEINLOU M, MAGHSOUDI A, GHEZELBASH R. A novel scheme for mapping of MVT-type Pb-Zn prospectivity: LightGBM, a highly efficient gradient boosting decision tree machine learning algorithm[J]. *Natural Resources Research*, 2023, 32(6): 2417-2438.
- [22] ZHANG G, XU J M, WANG H Q, et al. An interpretable deep learning algorithm for dynamic early warning of posttraumatic hemorrhagic shock based on noninvasive parameter[J]. *Biomedical Signal Processing and Control*, 2022, 77: 103779.

本文引文格式:

赵喆, 赵鑫浩, 郭宇, 等. 基于连续无创生理参数驱动的死亡事件动态预警[J]. *天津工业大学学报*, 2025, 44(4): 13-18.

ZHAO Z, ZHAO X H, GUO Y, et al. Dynamic warning of mortality events based on continuous noninvasive physiological parameters[J]. *Journal of Tiangong University*, 2025, 44(4): 13-18 (in Chinese).