

# 一种无创预测血压的改进 LightGBM 学习方法

陈勤达, 陈小惠

(南京邮电大学 自动化学院、人工智能学院, 江苏 南京 210023)

**摘要:** 为提高无创血压预测模型的准确率, 减小个人身体差异对准确率的影响, 提出一种基于鲸鱼优化算法 (WOA) 与轻量级梯度提升机 (LightGBM) 的无创血压检测模型 WOA-LightGBM。该模型首先提取预处理后的光电容积脉搏波、心电信号特征, 并结合人体特征组成输入特征矩阵; 然后通过核主成分分析法对输入特征矩阵进行降维, 减少冗余; 最后运用 WOA 优化 LightGBM 模型参数。实验结果表明, WOA-LightGBM 模型预测的收缩压和舒张压的平均绝对误差均满足美国医疗仪器促进协会制定的标准 ( $\pm 5\text{mmHg}$ ), 与传统模型相比具有一定优势, 且与传统水银血压计测量结果有高度一致性。

**关键词:** 无创血压检测; 人体特征; 核主成分分析法; 鲸鱼优化算法; 轻量级梯度提升机

DOI: 10.11907/rjdk.231246

开放科学 (资源服务) 标识码 (OSID):



中图分类号: TP212.6

文献标识码: A

文章编号: 1672-7800(2024)003-0041-06

## An Improved LightGBM Learning Method for Non-invasive Blood Pressure Prediction

CHEN Qinda, CHEN Xiaohui

(School of Automation and Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

**Abstract:** To improve the accuracy of non-invasive blood pressure prediction models and reduce the impact of individual body differences on accuracy, a non-invasive blood pressure detection model WOA LightGBM based on Whale Optimization Algorithm (WOA) and Lightweight Gradient Booster (LightGBM) is proposed. The model first extracts the preprocessed features of the photocopacitive product pulse wave and electrocardiogram signal, and combines them with human body features to form an input feature matrix; Then, the input feature matrix is dimensionally reduced using kernel principal component analysis to reduce redundancy; Finally, WOA is used to optimize the parameters of the LightGBM model. The experimental results show that the average absolute error of the WOA LightGBM model in predicting systolic and diastolic blood pressure meets the standard set by the American Association for the Advancement of Medical Devices ( $\pm 5\text{mmHg}$ ), which has certain advantages compared to traditional models and high consistency with traditional mercury meters for measuring blood pressure.

**Key Words:** non-invasive blood pressure detection; human characteristic; KPCA; WOA; LightGBM

### 0 引言

血压是衡量人体健康程度的关键指标之一, 心脑血管疾病的发生与血压异常密切相关<sup>[1-2]</sup>。医学领域评估心脑血管疾病风险、评价降压疗效、指导个性化用药时常需动态监测血压<sup>[3]</sup>。因此, 实现高精度的血压测量具有重要意义。

血压测量方式分为有创和无创两种。其中有创测量

是通过侵入人体的方式, 如使用动脉导管获取准确的实时血压值<sup>[4]</sup>, 但存在出血、伤口感染、体感不适等多种问题, 因此无创测量方式成为日常监测血压的首要选择<sup>[5]</sup>。为提高血压测量精度, 国内外学者进行了广泛研究。例如, 凌振宝等<sup>[6]</sup>、Ghosh 等<sup>[7]</sup>利用光电容积脉搏波和心电信号求取脉搏波传导时间, 并根据传导时间与血压的关系建立血压预测模型。然而血压受性别、年龄、心率、体重指数等多种因素影响, 该模型不具备良好的泛化能力。

随着人工智能算法的广泛使用, BP (Back Propaga-

收稿日期: 2023-04-03

作者简介: 陈勤达 (1997-), 男, 南京邮电大学自动化学院、人工智能学院硕士研究生, 研究方向为网络化测控技术; 陈小惠 (1961-), 男, 博士, 南京邮电大学自动化学院、人工智能学院教授、硕士生导师, 研究方向为网络化测控系统、嵌入式系统与智能仪器。本文通讯作者: 陈勤达。

tion)神经网络、支持向量机、长短期记忆神经网络(Long Short Term Memory, LSTM)、极限梯度提升(XGboost)、轻量级梯度提升机(LightGBM)等算法被用于建立无创血压预测模型,然而神经网络算法均易陷入局部极值而导致训练失败<sup>[8]</sup>。例如,李帆等<sup>[9]</sup>根据脉搏波信号与动脉血压值均与时间有关联性的特点,通过LSTM网络提取脉搏波信号时序序列参数,进而构建血压预测模型。该模型虽充分利用生理信号时间特征,但未加入人体特征,且LSTM网络易出现梯度消失现象,收敛速度亦较慢,导致其难以运用于实际;赵谓博等<sup>[10]</sup>利用高斯核函数将数据特征映射到高维空间,并基于支持向量机建立血压预测模型,高斯核函数参数少,模型复杂度低,且支持向量机泛化能力较好,但不适用于大规模样本;孙斌等<sup>[11]</sup>采用XGboost算法构建血压预测模型,将人体特征与生理信号作为输入,采用贝叶斯优化算法优化模型参数,降低了人体差异对预测结果的影响。然而XGboost算法在分裂节点的过程中需要遍历数据集,因此模型空间复杂度较高。

针对以上问题,本文提出一种基于核主成分分析法和鲸鱼优化算法(Whale Optimization Algorithm, WOA)优化LightGBM模型预测血压的方法WOA-LightGBM。其通过结合预处理后的生理信号特征与人体特征构建输入数据集,包括年龄、身高、体重、性别、体脂、脉搏波传导时间、脉搏波波形特征等,最大程度地降低了人体特征差异对血压模型的影响。同时通过WOA自动搜寻模型最优超参数,避免其陷入过拟合或欠拟合状态,有效提高了血压预测模型的精度。此外,该方法还通过核主成分分析方法降低输入数据维度,减少冗余,提高了模型的训练速度。

## 1 相关算法

### 1.1 LightGBM

LightGBM具有高效、快速、准确度高的特点。其在梯度提升决策树(Gradient Boosting Decision Tree, GBDT)的基础上采用基于直方图的算法构建决策树以实现数据快速分割;采用Leaf-wise生长策略快速减小损失函数并提高准确率<sup>[12]</sup>;采用稀疏存储技术构建直方图以减小内存使用;采用GOSS(Gradient-based One-Side Sampling)优化策略降低样本数量。

算法决策树根据特征值进行分裂,首先将待预测样本的特征值按照训练时的方式排序。设第*i*个样本的第*j*个特征值为 $x_{ij}$ , $N_j$ 表示特征*j*在训练集中的样本总数, $R(x_{ij})$ 表示在特征*j*上的排名,则 $x_{ij}$ 在特征*j*上的排序值表示为:

$$s_{ij} = \frac{R(x_{ij})}{N_j} \quad (1)$$

在遍历过程中,将特征向量输入到构建好的决策树中。从根节点开始遍历,对于非叶节点,根据节点对应的特征值和特征阈值判断样本应该走左子树还是右子树;对

于叶节点,直接返回该节点的预测值。

然后将多个决策树的预测值进行加权平均,得到最终结果。LightGBM通常使用梯度提升算法构建多个决策树,因此每个决策树的预测值都对应一个权重,预测结果的加权平均即为决策树预测值的加权平均。表示为:

$$y = \frac{\sum_{k=1}^w w_k f_k(x)}{\sum_{k=1}^w w_k} \quad (2)$$

式中: $f_k(x)$ 为第*k*个决策树对样本*x*的预测值, $w$ 为决策树的总数, $w_k$ 为第*k*个决策树的权重。

### 1.2 WOA

WOA通过模拟鲸鱼群体的行为来寻找最优解<sup>[13]</sup>。该算法首先随机生成一组鲸鱼的位置和速度;然后每个鲸鱼会根据当前位置和速度进行迁徙、狩猎与社交。迁徙是指鲸鱼向目标方向移动,以便更好地搜索空间;狩猎是指鲸鱼根据其适应度值选择目标位置,并向该位置移动,以便更快接近最优解;社交是指鲸鱼根据自身适应度值与邻居鲸鱼进行交流,然后调整自己的位置和速度,以便在搜索过程中更好地学习。每次迭代,鲸鱼都会进行这3种行为,并根据自身适应度值与搜索空间中的最优解进行比较,最终返回搜索到的最优解。

## 2 血压预测模型构建

### 2.1 核主成分分析法优化输入

#### 2.1.1 输入数据预处理

为降低人体差异对血压预测的影响,并充分利用生理信号波形特征与血压的关联性,本文结合人体特征参数和生理信号特征参数构建数据集。人体特征参数包括年龄、身高、体重、性别、心率、体重指数;生理信号特征参数包括脉搏波传导时间、大动脉硬度指数、反射波增强指数、拐点面积比<sup>[14]</sup>。其中脉搏波信号波形特征、大动脉硬度指数与舒张期峰值与收缩期峰值的时间间隔有关;反射波增强指数是舒张期与收缩期两个峰值之比;拐点面积比与血管阻力密切相关,是脉搏波波形曲线的拐点面积比。

设特征个数为*n*,随机抽取*m*人的特征构建输入矩阵 $X_{n \times m}$ 。表示为:

$$X_{n \times m} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mn} \end{bmatrix} \quad (3)$$

为避免数据量纲对预测结果产生影响,对数据集进行标准化处理。首先剔除缺失、异常值;然后分别采用0和1表示女性和男性;最后对特征数据归一化。归一化公式为:

$$x'_{mn} = \frac{x_{mn} - x_{mn}(\min)}{x_{mn}(\max) - x_{mn}(\min)} \quad (4)$$

图1为标准化后的脉搏波信号曲线。




Fig. 1 Standardized pulse wave signal curve

图1 标准化脉搏波信号曲线

2.1.2 特征降维

本文输入数据为非线性。核主成分分析法为非线性降维方法, 通过将数据投影到一个高维特征空间, 采用核函数计算特征空间中的内积<sup>[15]</sup>, 从而在非线性问题中提取主成分。

采用高斯径向基函数作为核函数。表示为:

$$k(x_i, x_j) = e^{-\gamma(x_i - x_j)^2} \quad (5)$$

式中:  $x_i$  和  $x_j$  分别为输入矩阵  $X_{n \times m}$  的第  $i$  和第  $j$  列向量;  $\gamma$  为控制映射的超参数, 本文  $\gamma$  值取 0.176。

构建核矩阵  $K$ 。表示为:

$$K = \begin{bmatrix} k(x_1, x_1) & k(x_1, x_2) & \cdots & k(x_1, x_n) \\ k(x_2, x_1) & k(x_2, x_2) & \cdots & k(x_2, x_n) \\ \vdots & \vdots & \ddots & \vdots \\ k(x_n, x_1) & k(x_n, x_2) & \cdots & k(x_n, x_n) \end{bmatrix} \quad (6)$$

对核矩阵进行中心化后求取特征值的特征向量, 保留累计可解释方差比大于设定阈值的特征向量, 合并被保留特征向量构成投影矩阵  $P$ , 降维后得到输入矩阵  $Q$ 。表示为:

$$Q = XP \quad (7)$$

2.2 WOA 优化 LightGBM 参数

将预处理后的矩阵  $Q$  输入 WOA 优化的 LightGBM 算法中。该算法参数主要包括核心参数、学习控制参数、IO 参数等<sup>[16]</sup>。采用 WOA 优化 LightGBM 参数的具体步骤为:

(1) 首先定义一个目标函数, 用于评估模型在当前参数下的性能。本文选择的目标函数为均方误差 (Mean Square Error, MSE)。

(2) 确定每个参数的范围和初始值。LightGBM 主要参数信息见表 1。

(3) WOA 算法需要初始化一个鲸鱼群, 鲸鱼群中每只

Table 1 Main parameters of LightGBM

表 1 LightGBM 主要参数信息

LightGBM 参数	含义	初始范围	结果
learning_rate	学习率	(0.001, 0.1)	0.01
num_leaves	决策树的叶子节点数量	(20, 100)	36
Max_depth	决策树的最大深度	(3, 10)	6
bagging_fraction	迭代时随机选择的样本比例	(0.5, 1]	0.69
feature_fraction	迭代时随机选择的特征比例	(0.5, 1]	0.71

鲸鱼代表一个参数组合。初始化时随机生成鲸鱼, 并通过当前目标函数评估每只鲸鱼的适应度。

(4) 每次迭代时, 鲸鱼群会根据其适应度和搜索策略进行移动。通过移动, 鲸鱼群中的参数组合不断优化, 直至满足终止条件。

(5) 每次迭代时需记录当前最优解, 即具有最小目标函数值的参数组合。若出现更好的参数组合, 则需要更新最优解。

(6) 当满足终止条件时, 即寻找到模型参数最优解, 输出当前解作为最终参数。

WOA 优化改进的 LightGBM 血压预测模型采用核主成分分析法对特征融合降维, 降低了人体差异对血压预测结果的影响, 提高了泛化能力和准确度。模型预测流程图 2。

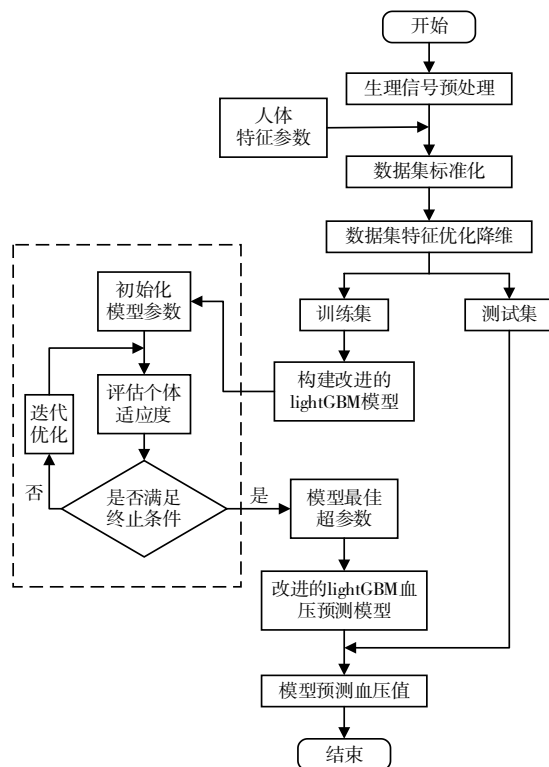


Fig. 2 Blood pressure prediction process of WOA-LightGBM

图 2 WOA-LightGBM 模型血压预测流程

3 实验方法与结果分析

3.1 数据集

本文数据集来源于课题团队自主采集建立的数据库 (<http://dataset.kangdollar.com>), 包括被测人员的血压标准值、身体参数以及经过预处理后的生理信号特征。从数据库中随机选取 1 000 组数据, 分为训练集 872 组和测试集 128 组。为保证预测模型有较强的泛化能力, 以舒张压 44~100 mmHg、收缩压 80~185 mmHg 为范围进行数据选取, 其中男性占比 55%, 女性占比 45%, 覆盖青年、中年、老

年3个年龄段。数据集年龄分布见图3。




Fig. 3 Age distribution of data set

图3 数据集年龄分布

### 3.2 评价指标

采用平均绝对误差 (Mean Absolute Error, MAE)、准确率 (Accuracy, AR)、决定系数 ( $R^2$ ) 评估模型性能。计算公式分别为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (8)$$

$$AR = \frac{\text{符合误差允许的样本个数}}{\text{测试样本总数}} \times 100\% \quad (9)$$

$$R^2 = \frac{\sum_{i=1}^n (\hat{x}_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (10)$$

式中:  $x_i$  为样本真实值,  $\hat{x}_i$  为样本预测值,  $\bar{x}$  为  $n$  个样本真实值的均值。AR 值越大, MAE 值越小表示模型预测准确度越高;  $R^2$  用于评估模型的拟合程度, 其值越接近于 1, 模型的拟合程度越好<sup>[17]</sup>。

### 3.3 比较实验

将 128 组测试集数据作为输入, 比较支持向量机、GS-LightGBM<sup>[18]</sup> 和本文 WOA-LightGBM 模型的血压预测性能, 其中 GS-LightGBM 为网格搜索算法优化的 LightGBM 模型。以水银血压计的测量值作为标准参考值, 记为 True。各模型收缩压与舒张压预测结果如图 4、图 5 所示 (彩图扫 OSID 码可见, 下同)。可以看出, 本文模型具有更好的拟合效果, 更接近收缩压和舒张压的真实值。支持向量机、GS-LightGBM 和 WOA-LightGBM 模型各评价指标比较见表 2。可以看出, WOA-LightGBM 模型的 MAE 均满足小于 5mmHg 的要求, 且  $R^2$  值较其他两个模型更接近于 1。

Table 2 Model performance comparison

表2 各模型评价指标比较

血压	模型	MAE	AR/%	$R^2$
舒张压	支持向量机	5.88	66	0.825 9
	GS-LightGBM	3.92	72	0.821 4
收缩压	WOA-LightGBM	2.62	92	0.935 6
	支持向量机	5.01	65	0.812 8
	GS-LightGBM	4.16	76	0.827 8
	WOA-LightGBM	2.39	95	0.968 9




Fig. 4 Comparison of systolic blood pressure prediction results

图4 收缩压预测结果比较




Fig. 5 Comparison of diastolic blood pressure prediction results

图5 舒张压预测结果比较

为评估 WOA 算法对 LightGBM 模型参数优化的适用性及优越性, 随机选择 55 组测试集数据作为输入, 分别使用 WOA-LightGBM 模型和 GA-LightGBM 模型在测试集数据上进行实验比较, 并绘制误差图, 结果见图 6、图 7。其中, GA 为传统的遗传算法。




Fig. 6 Systolic blood pressure error comparison

图 6 收缩压误差比较




Fig. 7 Diastolic blood pressure error comparison

图 7 舒张压误差比较

可以看出, GA-LightGBM 模型预测的收缩压和舒张压最大绝对误差分别为 9.28 mmHg 和 7.08 mmHg, 而 WOA-LightGBM 模型预测的收缩压和舒张压最大绝对误差分别为 8.06 mmHg 和 5.69 mmHg。此外, WOA 优化的模型平均运行时间为 3.16 s, 少于 GA 优化的 4.37 s, 说明 WOA 优化 LightGBM 超参数能使模型误差更小, 性能更优。

### 3.4 验证试验

为评估本文模型的实际可行性, 采用 Bland-Altman 分析法<sup>[1]</sup>对水银血压计测量结果和本文模型预测结果进行一致性分析<sup>[19]</sup>。结果如图 8、图 9 所示, 其中 Mean 为两种方法测量值差值的均值<sup>[20]</sup>; 1.96SD 为 1.96 倍标准偏差, 也称为一致限。散点分布在一致限内越多, 差值平均数 Mean 的线越接近代表差值平均数为 0 的线, 表明两个模型的一致性越好。可以看出, 两种方法收缩压和舒张压的 Mean 值接近差值平均数为 0 的线, 且 95% 的差值落于一致限内, 说明两种测量方法具有高度一致性, 本文方法具有实际可行性。

## 4 结语

本文提出的无创血压检测模型 WOA-LightGBM 通过 WOA 寻找 LightGBM 的最优参数, 避免过拟合现象和陷入局部最优解; 同时采用核主成分分析法对输入数据降维, 以减少冗余, 降低人体差异对血压预测精度的影响。与传




Fig. 8 Bland-Altman analysis result of systolic blood pressure

图 8 收缩压 Bland-Altman 分析结果




Fig. 9 Bland-Altman analysis result of diastolic blood pressure

图 9 舒张压 Bland-Altman 分析结果

统预测模型相比, 本文模型具有更强的泛化能力, 且与水银血压计测量结果具有高度一致性, 具有应用于实际场景的潜力。

基于人工智能算法的血压测量模型依赖高质量、大样本的数据信息, 后续将考虑引入更多影响因素, 如家族遗传、生活习惯等, 并进一步提高生理信号的采集质量, 深度挖掘生理信号多域特征, 对时域、频域、小波域等进行融合, 以实现高精度的血压测量。

### 参考文献:

- [1] JUNIOR A D, MURALI S, RINCON F, et al. Estimation of blood pressure and pulse transit time using your smartphone [C]//Madeira: Euromicro Conference on Digital System Design, 2015.
- [2] YUSUF S, BOSCH J, DAGENAIS G, et al. Cholesterol lowering in intermediate-risk persons without cardiovascular disease [J]. Journal of Vascular Surgery, 2016, 64(3): 827-827.
- [3] China Hypertension Alliance Committee. 2020 China ambulatory blood pressure monitoring guidelines [J]. Chinese Journal of Circulation, 2021, 36(4): 313-328.  
中国高血压联盟委员会. 2020 中国动态血压监测指南 [J]. 中国循环杂

- 志, 2021, 36(4): 313-328.
- [4] REBESCO M R, PINKSTON M C, SMYRNIOS N A, et al. A comparison of non-invasive blood pressure measurement strategies with intra-arterial measurement [J]. *Prehospital and Disaster Medicine*, 2020, 35(5): 516-523.
- [5] XI Z B, CHEN X H, ZHANG Y F, et al. A new network non-invasive real-time blood pressure monitoring system [J]. *Computer Technology and Development*, 2020, 30(1): 155-159.  
席锡宾, 陈小惠, 张永芳, 等. 一种新的网络化无创血压实时监测系统 [J]. *计算机技术与发展*, 2020, 30(1): 155-159.
- [6] LING Z B, ZHANG M, XIONG W J, et al. Design of cuff less blood pressure measuring instrument based on pulse wave conduction time [J]. *Journal of Electronic Measurement and Instrumentation*, 2012, 26(12): 1080-1085.  
凌振宝, 张铭, 熊文激, 等. 基于脉搏波传导时间的无袖带血压测量仪设计 [J]. *电子测量与仪器学报*, 2012, 26(12): 1080-1085.
- [7] GHOSH S, BANERJEE A, RAY N, et al. Continuous blood pressure prediction from pulse transit time using ECG and PPG signals [C]// *Cancun: Healthcare Innovation Point-of-care Technologies Conference*, 2016.
- [8] WU T H, PANG K H, KWONG W Y. Predicting systolic blood pressure using machine learning [C]// *Colombo: International Conference on Information & Automation for Sustainability*, 2015.
- [9] LI F, CHENG Y Z, BIAN J J, et al. LSTM network synchronous arterial blood pressure prediction based on PPG signals [J]. *Software Guide*, 2020, 19(8): 44-48.  
李帆, 程云章, 边俊杰, 等. 基于PPG信号的LSTM网络同步动脉血压预测 [J]. *软件导刊*, 2020, 19(8): 44-48.
- [10] ZHAO X B, HE Y D, LI X Z, et al. Human blood pressure prediction method based on support vector regression [J]. *Journal of Yanshan University*, 2017, 41(5): 438-443.  
赵谓博, 赫英迪, 李信政, 等. 基于支持向量回归的人体血压预测方法 [J]. *燕山大学学报*, 2017, 41(5): 438-443.
- [11] SUN B, CHU F F, CHEN X H. Noninvasive blood pressure prediction method based on Bayesian optimized XGBoost [J]. *Electronic Measurement Technology*, 2022, 45(7): 68-74.  
孙斌, 储芳芳, 陈小惠. 基于贝叶斯优化XGBoost的无创血压预测方法 [J]. *电子测量技术*, 2022, 45(7): 68-74.
- [12] XIAO Q, MU Y F, JIAO Z P, et al. Online prediction of the remaining service life of electric vehicle battery based on improved LightGBM [J]. *Journal of Electrical Technology*, 2022, 37(17): 4517-4527.  
肖迁, 穆云飞, 焦志鹏, 等. 基于改进LightGBM的电动汽车电池剩余使用寿命在线预测 [J]. *电工技术学报*, 2022, 37(17): 4517-4527.
- [13] HU W, XIAO P, ZHAI R, et al. Research on energy-regenerative suspension based on WOA-PID algorithm [J]. *Journal of Intelligent Material Systems and Structures*, 2023, 34(5): 536-550.
- [14] JI L, LIU C, LI P, et al. Increased pulse wave transit time after percutaneous coronary intervention procedure in CAD patients [J]. *Scientific Reports*, 2018, 8(1): 452-457.
- [15] WU J N, LIN Q T, WU B. A new model of human motion classification based on correlation vector machine based on kernel principal component analysis [J]. *Chinese Journal of Biomedical Engineering*, 2022, 41(6): 641-649.  
吴建宁, 林秋婷, 伍滨. 基于核主成分分析的相关向量机人体动作分类新型模型 [J]. *中国生物医学工程学报*, 2022, 41(6): 641-649.
- [16] YE F, FENG H L, LIANG X, et al. Prediction of shield cutting bolt parameters based on WOA-LightGBM [J]. *Journal of Tongji University (Natural Science Edition)*, 2022, 50(12): 1761-1769.  
叶飞, 冯浩岚, 梁兴, 等. 基于WOA-LightGBM的盾构切削锚杆参数预测 [J]. *同济大学学报(自然科学版)*, 2022, 50(12): 1761-1769.
- [17] FAN H X, CHEN X H. An improved vector machine learning method for continuous non-invasive blood pressure prediction [J]. *Journal of System Simulation*, 2020, 32(9): 1686-1692.  
樊海霞, 陈小惠. 一种连续无创血压预测的改进向量机器学习方法 [J]. *系统仿真学报*, 2020, 32(9): 1686-1692.
- [18] LI C Z, LIU D D, WANG M, et al. Detection of outliers in time series power data based on prediction errors [J]. *Energies*, 2023, 16(2): 582.
- [19] LI Z K, PAN Y, ZHAO M, et al. Research and analysis on the current situation of non-invasive automatic sphygmomanometer replacing mercury sphygmomanometer [J]. *China Metrology*, 2022(7): 16-17.  
李宗奎, 潘杨, 赵明, 等. 无创自动测量血压计替代水银血压计的现状研究和分析 [J]. *中国计量*, 2022(7): 16-17.
- [20] DU Y, ZHANG C, HAN Z, et al. Use the Bland-Altman method to evaluate the consistency of the measurement results of two filter efficiency detectors [J]. *China Metrology*, 2021(6): 95-97.  
杜玉, 张璨, 韩争, 等. 利用Bland-Altman法对两种过滤效率检测仪测量结果进行一致性评价 [J]. *中国计量*, 2021(6): 95-97.

(责任编辑:尹晨茹)