

DOI:10.3969/j.issn.1001-4551.2024.04.011

基于大流量止回阀实验系统的快速预测模型*

王江坤¹, 赵晶^{1,3*}, 查洒洒¹, 王剑², 曲洺剑^{1,3}, 张俊飞²

(1. 沈阳工业大学机械工程学院, 辽宁 沈阳 110870; 2. 沈阳盛世五寰科技有限公司, 辽宁 抚顺 110172;
3. 辽宁五寰特种材料与智能装备产业技术研究院, 辽宁 沈阳 118015)

摘要:针对传感器在数据获取中的局限性和无法用于对实验系统进行全面的数据收集问题, 对大流量止回阀实验系统的快速预测模型技术进行了研究, 建立了实验系统的快速预测模型, 进行了快速预测模型的结果分析。首先, 搭建了实体模型, 根据大流量止回阀实验系统的结构, 结合实验系统的工作原理对其进行了简化, 并进行了有限元分析; 然后, 利用快速预测模型的关键技术构建了实验系统数据库, 进行了实验系统的样本采集; 通过比对不同机器学习算法的预测准确率, 选择了随机森林算法, 并建立了实验系统内压与应力应变的关系; 最后, 进行了快速预测模型的结果分析, 并完成了实验系统整体预测实验和实验系统部件单独预测实验。研究表明: 采用随机森林(RF)算法建立的快速预测模型, 拟合优度(R^2)达到了0.99, 相较于深度神经网络(DNN)算法和梯度提升树(GBDT)算法, 拟合优度(R^2)提高了68.97%和51.47%。实验系统整体预测与实验系统部件单独预测的对比试验结果表明: 整体预测模型的预测速度更快, 且精度可以达到97.43%。

关键词:大流量旋启式止回阀; 单向阀; 随机森林算法; 响应时间; 深度神经网络; 梯度提升树; 决定系数

中图分类号: TH137.52

文献标识码: A

文章编号: 1001-4551(2024)04-0659-07

Fast prediction model based on high flow check valve experimental system

WANG Jiangkun¹, ZHAO Jing^{1,3*}, ZHA Sasa¹, WANG Jian², QU Mingjian^{1,3}, ZHANG Junfei²

(1. School of Mechanical Engineering, Shenyang University of Technology, Shenyang 110870, China; 2. Shenyang Shengshi Wuhuan Technology Co., Ltd., Fushun 110172, China; 3. Liaoning Wuhuan Special Materials and Intelligent Equipment Industrial Technology Research Institute, Shenyang 118015, China)

Abstract: Aiming at the limitations of sensors for data acquisition and the inability to collect comprehensive data for the experimental system, the fast prediction modeling technology of the high flow check valve experimental system was studied. The rapid prediction model of the experimental system was established, and the results of the rapid prediction model were analyzed. First of all, the solid model was constructed and based on the structure of the experimental system of high flow check valve. At the same time, the working principle of the experimental system was combined to simplify it and carry out finite element analysis. Then, the key technology of fast prediction model was used to construct the experimental system database and realize the sample collection of the experimental system. By comparing the prediction accuracy of different machine learning algorithms, the random forest (RF) algorithm was selected to establish the relationship between the internal pressure and stress-strain of the experimental system. Finally, the results of the fast prediction model were analyzed, and the overall prediction experiment of the experimental system and the individual prediction experiment of the experimental system components were done. The results show that the fast prediction model established by the random forest algorithm has a goodness of fit (R^2) of 0.99, which is 68.97% and 51.47% higher compared to the deep neural network (DNN) algorithm and gradient boosted tree (GBDT) algorithm. Comparison tests between the overall prediction of the experimental system and the individual prediction of the experimental system components show that the overall prediction model has a faster prediction speed and an accuracy of 97.43%.

Key words: large flow swing check valve; non-return valve; random forest(RF) algorithm; response time; deep neural network(DNN); gradient boosting tree(GBDT); coefficient of determination(R^2)

收稿日期: 2023-09-05

基金项目: 辽宁省海洋经济发展项目(2022-47-1-09)

作者简介: 王江坤(1999-), 男, 河南周口人, 硕士研究生, 主要从事流体机械和机器学习方面的研究。E-mail: 1056988089@qq.com

通信联系人: 赵晶, 女, 教授, 博士生导师。E-mail: zhaojing@sut.edu.cn

0 引 言

大流量旋启式止回阀是阀瓣绕固定轴做旋转运动的单向阀。由于具备结构简单、压降低、经济性好、密封可靠、维护维修相对方便、适用范围广等优点,大流量旋启式止回阀被广泛应用于工业生产中。

施熠徽等人^[1]采用了有限元分析软件对阀门的内流场进行了分析,通过引入场协同原理,提出了2种阀结构优化设计思路,并发现了在引入协同原理对阀结构进行优化后,减小了流体的有效黏性系数平均值,增大了有效黏性系数梯度。但阀门的内流场是变化的,怎样对瞬态的流场进行优化是其需要改进的问题。

刘梦遥等人^[2]采用有限元分析软件,分析了高压止回阀的应力分布及变形情况;采用流固耦合方法对止回阀进行了模拟,提出了阀口开度与止回阀变形量关联模型,发现了止回阀变形量与阀口开度呈波动趋势。但该模型只用于对阀门入口进行分析,缺失了对阀门整体的应力分布分析。余航等人^[3]采用流固热耦合仿真方法,研究了温度快速变化对止回阀的影响;采用流体力学计算技术,对工况变换时止回阀的内部流场进行了仿真,提出了基于止回阀对温度场的建模方法,发现了止回阀的等效应力和变形量随温度的降低而降低;但其没有分析外界条件对止回阀的影响。竺盛才等人^[4]采用有限元仿真软件,研究了接触面在工作中所受的冲击效应,采用有限元分析方法,建立了各个部件之间的接触关系和有限元分析模型,发现了切换阀速度与应力峰值产生部位分别为阀板、阀体挡台距离转轴最远处;但其对于快速响应预测没有进行研究。

大多数研究是对止回阀进行单独分析,很少有研究人员对止回阀实验平台进行系统分析。所以需要建立实验系统快速预测模型,从而快速预测整个实验系统的状态信息。

笔者利用机器学习算法建立阀门实验系统快速预测模型。首先,利用有限元软件对大流量止回阀实验系统进行建模分析,并通过比对实验数据和仿真数据,确保仿真数据的可靠性;然后,针对实验系统,利用多种机器学习算法建立快速预测模型。

1 快速预测模型技术路线

快速预测模型的技术路线分三部分:1)数据准备阶段;2)模型训练阶段;3)结果分析阶段。

快速预测模型技术路线如图1所示。




图1 快速预测模型技术路线

Fig. 1 Rapid prediction model technical route

1)数据准备阶段。搭建实验台架,并进行实验,将实验数据与有限元仿真数据进行对比,验证数据的可靠性。通过对数据的归一化处理,消除量纲影响,形成训练数据集;

2)模型训练阶段。使用均方误差指标(mean squared error, MSE)、平均绝对误差指标(mean absolute error, MAE)、R2 指标对 DNN、RF、GBDT^[5-7] 三种算法进行机器学习,选择表现最好的随机森林算法训练数据,并采用粒子群算法^[8]对快速预测模型的参数进行寻优;

3)结果分析阶段。随机选择一组初始值,用训练完成的快速预测模型进行预测,观察预测的响应速度、预测准确率和误差值并进行分析优化。

2 实体模型搭建

2.1 实验台架结构

大流量止回阀实验系统由阀门、管道、流量计、压力表、循环水泵共同组成。

实验系统示意图如图2所示。

由图2可知:实验系统由4条回路组成,第1条回路为主工作回路,主要测试实验阀门的应力、应变和流量。因为不同流量对应的流量计不同,2、3和4这3条流量回路用于测试不同流量下实验阀门的应力、应变。

在进行有限元分析时,3条流量回路可以通过有限元软件参数设置进行代替,不需要3条流量回路的辅助,所以可以将3条流量回路进行简化,只留下主回路部分并进行有限元分析。同时,对于储水罐和循




图2 实验系统示意图

Fig. 2 Schematic diagram of the experimental system

环水泵的泵机部分一并进行简化,用参数代替。

2.2 有限元参数设置

实验台架以 AISI 321 不锈钢为材料,其弹性模量为 193 GPa,泊松比为 0.28,密度为 7 900 kg/m³,屈服极限为 205 MPa。

笔者选择通用性较强的四面体网格,网格最小尺寸单元尺寸 100 mm,节点数为 663 693。

2.3 数据验证

为了验证仿真数据的可靠性,笔者选取实验系统的关键点位与仿真数据进行对比,选取容易发生应力集中的点位作为实验系统的关键点位。

实验阀门应力如图 3 所示。




图3 实验阀门应力

Fig. 3 Experimental valve stress diagram

由图 3 可知:应力较大的点主要在阀门颈部、阀门管道连接处。因此,笔者选择这些点位作为关键点位。由于实验数据会受到噪声的影响,所以在进行数据验证之前,需要先对实验数据进行异常值清洗。笔者采用 3sigma 原则将实验数据进行处理,然后将其与仿真数据进行对比分析。

应变数据对比如表 1 所示。

表 1 应变数据对比

Table 1 Comparison of strain data

实验数据/mm	仿真数据/mm	准确率/%
2.72×10^{-5}	2.82×10^{-5}	96.44
5.34×10^{-5}	5.53×10^{-5}	96.42
3.41×10^{-5}	3.49×10^{-5}	97.42
6.58×10^{-5}	6.71×10^{-5}	98.12
2.91×10^{-4}	2.96×10^{-4}	98.22
7.48×10^{-5}	7.63×10^{-5}	97.97
4.65×10^{-4}	4.73×10^{-4}	98.33
1.72×10^{-4}	1.74×10^{-4}	98.70
2.76×10^{-4}	2.81×10^{-4}	98.37

由表 1 可知:仿真数据的准确率最小值为 96.42%,说明仿真数据满足误差要求,可以代替实验数据构建训练集。

2.4 数据处理

由于大流量止回阀实验系统应变数据区间为 $10^{-4} \sim 10^{-5}$,而应力的数据区间为 0 ~ 100,因此笔者采用最大最小值归一化法,消除应力应变的量纲差异。

对于应力应变的原始值 y_1, y_2 ,具体表示如下:

$$y_{1_scaled} = (y_1 - \min) / (\max - \min) \tag{1}$$

$$y_{2_scaled} = (y_2 - \min) / (\max - \min) \tag{2}$$

式中: y_{1_scaled} 为归一化后的输出应力; y_{2_scaled} 为归一化后的输出。

笔者通过将原始值与最小值的差异除以最大值和最小值之间的范围来进行归一化,最小值会被映射到 0,最大值会被映射到 1,对于其他值,则在这个范围内线性地进行缩放。

关键点位归一化数据如表 2 所示。

表 2 关键点位归一化数据

Table 2 Normalized data table for key points

应变/mm	应力/MPa
3.77×10^{-3}	3.45×10^{-3}
7.39×10^{-3}	6.97×10^{-3}
4.67×10^{-3}	3.72×10^{-3}
8.97×10^{-3}	4.66×10^{-3}
3.96×10^{-2}	1.35×10^{-2}
1.02×10^{-2}	8.09×10^{-3}
6.32×10^{-2}	4.94×10^{-2}
2.33×10^{-2}	1.48×10^{-2}
3.77×10^{-3}	3.45×10^{-3}

由表 2 可知:归一化后的数据消除了量纲的影响,应力、应变的数值范围相近,解决了因数值差距过大而导致某些特征对模型训练贡献值小的问题。

3 快速预测模型关键技术

快速预测模型是指用机器学习的方法进行大量数据训练,训练出响应速度快、预测准确率高的模型。快速预测模型技术针对给定的任意初始条件,能够快速预测整个实验系统的应力、应变变化。

3.1 算法选择

DNN^[9-12]在大数据机器学习中具有高度可扩展性和强大的表征学习能力,能够处理大规模数据集和模型参数,通常具有较高的准确性。然而,训练和调整 DNN 模型复杂且耗时,对小数据集容易过拟合,且对特征工程依赖较高。

随机森林能够并行处理大规模数据,具有良好的鲁棒性,能够处理异常值和噪声,可以进行特征选择,降低计算和存储成本。但随机森林可能占用较大内存空间。

GBDT^[13]具有高准确性和可解释性等特点,适用于高维稀疏数据,能够处理大量特征变量。然而,GBDT 训练和预测速度较慢,对噪声和异常值敏感,处理大数据集和高维数据时需要更多计算资源。

随机森林算法^[14-15]构建的预测模型在实验系统的样本训练数据下,其均方误差指标 (root MSE)、平均绝对误差指标 (root MAE)、 R^2 都明显优于 DNN 模型以及 GBDT 模型。

应变损失值如表 3 所示。

表 3 应变损失值			
Table 3 Strain loss function			
	DNN	GBDT	随机森林
MSE	2.00×10^{-8}	2.07×10^{-8}	7.27×10^{-10}
MAE	6.765×10^{-5}	6.22×10^{-5}	9.37×10^{-6}
R^2	0.58	0.63	0.99

由表 3 可知,采用 DNN 和 GBDT 算法构建的模型有较低的均方误差和平均相对误差,结合归一化后的数据值,这两种算法应该有较好的拟合曲线^[16-17]。但通过 R^2 值可以发现,两种算法的拟合效果并不好,说明这两种算法构建的模型发生了过拟合。

因此,在对比了 RMSE、RMAE、 R^2 三种指标后,笔者选择使用随机森林算法构建快速预测模型。

随机森林的构建预测模型过程可以简述为:对整个训练集进行 Bootstrap 重采样,生成新的训练集。

抽取 n 个样本形成子集,每个子集对应一棵决策树,重复 m 次,就构建了具有 m 棵决策树的随机森林快速预测模型。

随机森林构建预测模型原理如图 4 所示。




图 4 随机森林构建预测模型原理图
Fig. 4 Schematic diagram of random forest construction prediction model

随机森林算法的计算过程如下:

- 1) 通过 bootstrap 重采样,将样本打乱,从抽取的样本集中选择合适的样本,组成 n 个子集,每个子集对应一个决策树训练集;
- 2) 子集中包含 M 个特征,随机抽取 m 个特征的子集 K_i 。根据信息增益最大化的规则选择决策树分支结点,具体表示如下:

$$Gain(K_i,a) = Ent(K_i) - \sum_{j=1}^m \frac{K_i^j}{K_i} Ent(K_i^j) \quad (3)$$

式中: $Gain(K_i,a)$ 为特征 a 对子集 K_i 属性划分获得的信息增益; $Ent(K_i)$ 为子集 K_i 信息熵。

- 3) 遍历子集 K_i 各项特征数据,将找到的信息增益最大化的特征 a 作为决策树分支结点,并将节点分裂为两个分支,通过决策树持续分支生长而不进行剪枝,使所有特征都完成分裂过程;

- 4) 利用决策树对特征集实施类别投票,根据投票结果,将得票数较多的类别作为诊断类型。

3.2 随机森林参数确定

粒子群算法^[18-21]是一种兼顾全局和局部最优的随机搜索算法。所以,需要利用粒子群算法寻找随机森林模型的最优参数。

笔者以群体最优值为基准,对每个粒子的位置 x 与速度 v 进行更新,更新公式为:

位置 x 更新公式为:

$$x_i(k+1)=x_i(k)+v_i(k+1) \tag{4}$$

式中: x_i, v_i 为粒子的位置与速度。

速度 v 更新公式为:

$$v_i(k+1)=wv_i(k)+a_1r_1(p_{bi}(k)-x_i(k))+a_2r_2(g_{bi}(k)-x_i(k)) \tag{5}$$

式中: w 为惯性因子; a_1, a_2 为学习因子; r_1, r_2 为(0,1)之间的随机数。

笔者以损失函数为目标函数进行寻优,最终的搜索结果表明,决策树的最优棵数为 50 棵,对应的预测准确率达到 97.56%。

4 快速预测模型结果分析

笔者利用随机森林算法建立大流量止回阀实验系统快速预测模型,并对所得实验系统应力应变预测数据进行反归一化;同时,将样本节点映射至原始实验系统节点中,得到实验系统对应的预测数据。

4.1 响应速度与预测准确率分析

快速预测模型的响应速度是一个很重要的评价指标。模型的响应速度与模型的复杂程度成反比,而模型的复杂程度又与模型的预测准确率成正比。因此,模型的响应速度与模型的预测准确率成反比,所以,笔者针对两者相互影响情况进行实验验证。

实验系统响应时间如表 4 所示。

表 4 实验系统响应时间表

Table 4 Response schedule of experimental system		
决策树数量	响应时间/s	预测准确率/%
5	0.25	96.78
10	0.34	97.05
15	0.45	97.24
20	0.49	97.35
25	0.53	97.43
30	1.64	97.46

由表 4 可知:随着决策树数量增加,预测模型响应时间和预测准确率都在增大;当决策树数量从 25 增长到 30 时,预测模型响应时间提高 2 倍,预测准确率只增加了 0.03%。

由此可知:当决策树数量到达 25 棵以后,预测准确率提升所需要的成本太高。所以,笔者选取决策树数量为 25 棵为预测模型的最优参数。

4.2 误差分析

笔者随机选取一组有限元分析结果进行预测,采用实验系统快速预测模型所得应力应变预测结果和有限元分析结果吻合。结合评价模型和预测曲线得出结论:在大流量止回阀实验系统的应用场景下,采用随机森林算法能够实现多目标同时准确输出目的,适合实验系统运行状态下的快速预测。

应变和应力预测结果如图 5 所示。




图 5 应变应力预测图

Fig.5 Strain stress prediction diagram

由图 5 可知:误差值在前后两部分发生跳动,这是因为阀门数据与管道数据一起训练,阀门应力应变的变化比管道复杂,所以会导致阀门部分误差比管道部分大。阀门部分单独建模,可以减小误差曲线的跳动。实验阀门响应时间如表 5 所示。

表 5 实验阀门响应时间		
Table 5 Experimental valve response schedule		
决策树数量	响应时间/s	预测准确率/%
5	0.09	97.53
10	0.10	97.87
15	0.16	98.00
20	0.25	98.00
25	0.32	98.08
30	0.41	98.13

由表 5 可得到在决策树数量为 25 时,实验阀门快速预测模型的响应速度。

结果表明:模型的响应时间为 0.32 s,实验系统整体快速预测模型的响应时间为 0.53 s。实验阀门的数据量只有实验系统数据量的 1/6,说明采用阀门部件单独构建快速预测模型,将大幅增加预测模型的响应时间。同时,实验系统整体快速预测模型的误差满足预期误差。

因此,笔者采用实验系统整体快速预测模型。

4.3 实验验证

实验数据与预测模型之间存在双向反馈机制。实验系统在前文提到的关键点位放置应力和应变传感器,采集实验数据对预测模型的预测值进行实时验证。采用预测模型能发现实验系统的应力和应变异常点,并发出警告。

实验系统实验与仿真数据对比如表 6 所示。

表 6 实验系统实验与仿真数据对比		
Table 6 Comparison of experimental and simulation data of the experimental system		
应力/MPa(实验)	应力/MPa(预测)	准确率/%
6.34 × 10	6.78 × 10	96.33
1.08 × 10 ²	1.10 × 10 ²	98.07
1.10 × 10 ²	1.13 × 10 ²	97.48
1.02 × 10 ²	1.07 × 10 ²	95.84
1.16 × 10 ²	1.18 × 10 ²	98.36
8.91 × 10	8.82 × 10	98.91
4.11 × 10	4.14 × 10	99.18
5.81 × 10	5.59 × 10	96.23
3.73 × 10	4.31 × 10	95.56
应变/mm(实验)	应变/mm(预测)	准确率/%
3.31 × 10 ⁻⁴	3.54 × 10 ⁻⁴	95.59
5.60 × 10 ⁻⁴	5.71 × 10 ⁻⁴	98.04
5.71 × 10 ⁻⁴	5.85 × 10 ⁻⁴	97.49

续表		
应变/mm(实验)	应变/mm(预测)	准确率/%
5.29 × 10 ⁻⁴	5.57 × 10 ⁻⁴	96.75
6.04 × 10 ⁻⁴	6.14 × 10 ⁻⁴	98.37
4.62 × 10 ⁻⁴	4.59 × 10 ⁻⁴	99.25
2.26 × 10 ⁻⁴	2.30 × 10 ⁻⁴	98.07
3.03 × 10 ⁻⁴	2.93 × 10 ⁻⁴	97.83
2.02 × 10 ⁻⁴	2.30 × 10 ⁻⁴	96.18

由表 6 可知,在内压为 1.9 MPa 时,实验数据与预测数据对比的准确率均在 95% 以上,可以满足预期误差要求。

5 结束语

针对传感器对于数据获取的局限性,笔者对大流量止回阀实验系统的快速预测模型技术进行了研究。笔者通过搭建实体模型,并利用快速预测模型的关键技术,构建了实验系统数据库,完成了实验系统的样本采集;然后,通过比对不同机器学习算法的预测准确率,选择利用随机森林算法,建立了实验系统的快速预测模型;最后,进行了快速预测模型的结果分析。

研究结论如下:

- 1) 基于应力应变样本数据库中的数据,利用随机森林算法建立大流量止回阀快速预测模型,拟合优度 R^2 达到 0.99;
- 2) 随机抽取一组样本作为测试集,预测准确率达到 97.43%,同时模型响应时间为 0.53 s,验证了快速预测模型的可靠性,这对于大流量止回阀实验系统分析具有重要参考价值;
- 3) 对比了整体预测模型和部件单独预测模型的预测速度和精度。部件单独预测模型的预测精度比整体预测模型高 1%,但预测速度是整体预测模型的 30%。

模型的预测精度还有提升空间,如何在不影响预测模型响应速度的前提下提升模型的预测精度,这是笔者接下来的研究重点。

参考文献(References):

[1] 施熠徽,罗 坤,樊建人. 轴流式止回阀的流动场协同分析与减阻设计[J]. 浙江大学学报:工学版,2018,52(1): 29-35,159.
SHI Yi-hui, LUO Kun, FAN Jian-ren. Flow field synergy analysis and drag reduction design of axial flow check valves [J]. Journal of Zhejiang University: Engineering Edition, 2018, 52(1): 29-35, 159.

[2] 刘梦瑶,康 灿,丁可金,等. 某核电止回阀开启过程中的瞬态流动与结构特征[J]. 核动力工程,2020,41(3): 45-51.

- LIU Meng-yao, KANG Can, DING Ke-jin, et al. Transient flow and structural characteristics during the opening process of a nuclear power check valve [J]. Nuclear Power Engineering, 2020, 41(3): 45-51.
- [3] 余航, 赵新文, 傅晟威. 船用核动力装置止回阀的流固热耦合研究[J]. 核动力工程, 2019, 40(4): 25-28.
- YU Hang, ZHAO Xin-wen, FU Sheng-wei. Research on fluid-solid-thermal coupling of check valves for marine nuclear power plants [J]. Nuclear Power Engineering, 2019, 40(4): 25-28.
- [4] 竺盛才, 贾建利, 钟毅, 等. 顺序增压切换阀冲击过程仿真分析[J]. 车用发动机, 2022(2): 67-72.
- ZHU Sheng-cai, JIA Jian-li, ZHONG Yi, et al. Simulation analysis of impact process of sequential boost switching valve [J]. Vehicle Engine, 2022(2): 67-72.
- [5] LIANG W, LUO S, ZHAO G, et al. Predicting hard rock pillar stability using GBDT, XGBoost, and Light GB Algorithms [J]. Mathematics, 2020, 8(5): 765.
- [6] 朱锡山, 罗贞, 易灿灿, 等. 基于 POA-CNN-REGST 的电梯钢丝绳滑移量预测方法[J]. 机电工程, 2023, 40(6): 928-935.
- ZHU Xi-shan, LUO Zhen, YI Can-can, et al. Prediction method of elevator wire rope slip based on POA-CNN-REGST [J]. Journal of Mechanical & Electrical Engineering, 2023, 40(6): 928-935.
- [7] 张丽秀, 李爽, 魏晓奕, 等. 石墨烯润滑油润滑下摩擦副摩擦因数预测模型[J]. 机电工程, 2023, 40(3): 415-421.
- ZHANG Li-xiu, LI Shuang, WEI Xiao-yi, et al. Prediction model of friction factor of friction pair under graphene lubricant lubrication [J]. Electromechanical Engineering, 2023, 40(3): 415-421.
- [8] PANDEY R, UZIEL S, HUTSCHENREUTHER T, et al. Towards deploying DNN models on edge for predictive maintenance applications [J]. Electronics, 2023, 12(3): 639.
- [9] 陈向俊, 傅军平, 陈栋栋, 等. 基于极端梯度提升回归模型的电梯钢丝绳磨损预测方法[J]. 机电工程, 2022, 39(4): 554-560.
- CHEN Xiang-jun, FU Jun-ping, CHEN Dong-dong, et al. An elevator wire rope wear prediction method based on extreme gradient lifting regression model [J]. Electromechanical Engineering, 2022, 39(4): 554-560.
- [10] 曹斐, 周彧, 王春晓, 等. 一种改进的支持向量回归的混凝土强度预测方法[J]. 硅酸盐通报, 2021, 40(1): 90-97.
- CAO Fei, ZHOU Yu, WANG Chun-xiao, et al. An improved support vector regression method for concrete strength prediction [J]. Silicate Bulletin, 2021, 40(1): 90-97.
- [11] ZHANG C, YU J, WANG S. Fault detection and recognition of multivariate process based on feature learning of one-dimensional convolutional neural network and stacked denoised autoencoder [J]. International Journal of Production Research, 2021, 59(8): 2426-2449.
- [12] 邱振波, 李子正, 尹宝良, 等. 基于随机森林算法的热轧精轧带钢宽展量预测[J]. 塑性工程学报, 2023, 30(8): 107-114.
- QIU Zhen-bo, LI Zi-zheng, YIN Bao-liang, et al. Prediction of hot rolled strip width spread based on random forest algorithm [J]. Plastic Engineering Journal, 2023, 30(8): 107-114.
- [13] LUO S, ZHAO W, PAN L. Online GBDT with chunk dynamic weighted majority learners for noisy and drifting data streams [J]. Neural Processing Letters, 2021, 53(5): 3783-3799.
- [14] 李铁军, 胡毅, 刘茜, 等. 基于随机森林的支持向量机混凝土抗渗性预测模型研究[J]. 水电能源科学, 2021, 39(2): 119-122, 118.
- LI Tie-jun, HU Yi, LIU Xi, et al. Support vector machine concrete permeability prediction model based on random forest [J]. Hydropower Energy Science, 2021, 39(2): 119-122, 118.
- [15] 王雪, 韩韬. 基于贝叶斯优化随机森林的变压器故障诊断[J]. 电测与仪表, 2021, 58(6): 167-173.
- WANG Xue, HAN Tao. Transformer fault diagnosis based on Bayesian optimization random forest [J]. Electrical Measurement and Instrumentation, 2021, 58(6): 167-173.
- [16] HIMMY O, RHINANE H. Landslide susceptibility mapping using machine learning algorithms study case AL hoceima region, northern Morocco [J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2023, 48(4): 153-158.
- [17] 陈冠宇, 杨鹏, 陈宁. 基于随机森林算法的船舶电站故障诊断[J]. 船舶工程, 2023, 45(1): 116-119.
- CHEN Guan-yu, YANG Peng, CHEN Ning. Fault diagnosis of ship power station based on random forest algorithm [J]. Ship Engineering, 2023, 45(1): 116-119.
- [18] 武鑫, 吴万哲, 白浩, 等. 基于深度神经网络的 SOFC 电堆温度场建模[J]. 太阳能学报, 2023, 44(7): 55-60.
- WU Xin, WU Wan-zhe, BAI Hao, et al. Deep neural network-based temperature field modeling of SOFC power stack [J]. Journal of Solar Energy, 2023, 44(7): 55-60.
- [19] 蒋文强, 胡绍林, 郭其亮, 等. 基于 PSO-RF 的气动调节阀故障诊断[J]. 流体机械, 2022, 50(12): 79-85.
- JIANG Wen-qiang, HU Shao-lin, GUO Qi-liang, et al. Fault diagnosis of pneumatic control valves based on PSO-RF [J]. Fluid Machinery, 2022, 50(12): 79-85.
- [20] 黎梓昕, 林海军, 徐雄, 等. 基于 KPCA-PSO-SVM 的水轮机故障检测方法[J]. 排灌机械工程学报, 2023, 41(5): 467-474.
- LI Zi-xin, LIN Hai-jun, XU Xiong, et al. Fault detection method for water turbine units based on KPCA-PSO-SVM [J]. Journal of Drainage and Irrigation Machinery Engineering, 2023, 41(5): 467-474.
- [21] 李良, 李晓俊, 杨顺银, 等. 基于 PSO-LSSVR 代理模型的石化多级离心泵叶轮优化设计[J]. 流体机械, 2023, 51(9): 42-50.
- LI Liang, LI Xiao-jun, YANG Shun-yin, et al. Optimization design of petrochemical multi-stage centrifugal pump impeller based on PSO-LSSVR surrogate model [J]. Fluid Machinery, 2023, 51(9): 42-50.

本文引用格式:

王江坤, 赵晶, 查洒洒, 等. 基于大流量止回阀实验系统的快速预测模型[J]. 机电工程, 2024, 41(4): 659-665.

WANG Jiangkun, ZHAO Jing, ZHA Sasa, et al. Fast prediction model based on high flow check valve experimental system [J]. Journal of Mechanical & Electrical Engineering, 2024, 41(4): 659-665.

《机电工程》杂志: <http://www.meem.com.cn>