

中文引用格式:刘洋. 炼化企业工艺安全管理指标数据预测方法[J]. 中国安全科学学报, 2025, 35(8): 54-60.

英文引用格式:LIU Yang. Prediction method for process safety management indicator data of refining and chemical enterprises[J]. China Safety Science Journal, 2025, 35(8): 54-60.

炼化企业工艺安全管理指标数据预测方法^{*}

刘洋^{1,2,3} 工程师

(1 化学品安全全国重点实验室, 山东 青岛 266104; 2 中石化安全工程研究院有限公司, 山东 青岛 266104; 3 中石化管理体系认证(青岛)有限公司, 山东 青岛 266104)

中图分类号:X937 文献标志码:A DOI: 10.16265/j.cnki.issn1003-3033.2025.08.1054

资助项目:中国工程院重点战略咨询项目(2023-XZ-17)。

【摘要】 为提升炼化企业过程安全管理水平,增强对关键安全指标的动态监控与趋势预警能力,提出一种融合多预测模型的工艺报警数据预测方法。该方法结合差分移动平均自回归(ARIMA)、二次指数平滑以及基于粒子群优化(PSO)的支持向量回归(SVR)3种时间序列预测模型,针对不同指标的趋势性、自相关性与非线性特征,实现对多样化安全指标的有效建模与预测。首先,处理原始指标数据的异常值;分别构建3类预测模型并计算预测结果;然后,通过比较各模型误差自动选取最优模型用于指标趋势预测;最后,实证分析某炼化企业一年内的时平均报警数指标。结果表明:该方法能够动态适配不同数据特征,所选模型预测误差稳定低于0.1,明显优于现有报警数量级精度要求。该方法可有效提升炼化企业过程安全指标预测的准确性与灵活性,及时识别潜在风险指标。

【关键词】 炼化企业; 工艺安全; 安全管理; 指标数据; 时间序列; 支持向量回归(SVR); 指数平滑法

Prediction method for process safety management indicator data of refining and chemical enterprises

LIU Yang^{1,2,3}

(1 State Key Laboratory of Chemical Safety, Qingdao Shandong 266104, China;

2 SINOPEC Research Institute of Safety Engineering Co., Ltd., Qingdao Shandong 266104, China;

3 SINOPEC Management System Certification (Qingdao) Co., Ltd., Qingdao Shandong 266104, China)

Abstract: To improve the level of process safety management in refining and chemical enterprises and enhance dynamic monitoring and trend warning capabilities for key safety indicators, a multi-model fusion method for process alarm data prediction was proposed. This approach integrated three time series forecasting models: Autoregressive Integrated Moving Average (ARIMA), double exponential smoothing, and particle swarm optimization (PSO)-based support vector regression (SVR). The method effectively modeled and predicted diverse safety indicators by addressing their trend, autocorrelation, and nonlinear characteristics. Initially, outliers in the raw indicator data were processed. Three types of forecasting models were then constructed and their prediction results were computed. The optimal model for trend prediction was automatically selected based on error comparison. Finally, an empirical analysis was

conducted using the time-averaged alarm count indicators from a refinery enterprise over one year. The results show that the proposed method dynamically adapts to varying data characteristics, with selected model prediction errors consistently remaining below 0.1, significantly outperforming the existing requirements for alarm magnitude accuracy. This method effectively enhances the accuracy and flexibility of safety indicator prediction in refining and chemical enterprises and enables the timely identification of potential risk indicators.

Keywords: refining and chemical enterprises; process safety; safety management; indicator data; time series; support vector regression (SVR); exponential smoothing method

0 引言

随着我国炼油与化工行业的发展,炼化装置的运行工况日益复杂,装置规模日趋扩大,传统依赖人工经验和常规巡检的方式已难以满足现代大型炼化装置的过程安全管控需求,易引发人为失误,增加事故风险。在此背景下,提升过程安全管理的智能化水平,构建数据驱动为核心的风险监测与预警体系,已成为行业发展的必然趋势。通过智能监测关键设备与工艺参数,并结合历史运行数据挖掘潜在规律,可实现对过程安全绩效指标的趋势研判与风险预警,从而有效提升企业本质安全水平^[1]。

目前,国内外学者已在工业过程建模与过程安全管理方面开展了广泛研究,提出了多种基于时间序列的数据预测方法。常见的模型包括指数平滑模型^[2]、差分移动平均自回归 (Autoregressive Integrated Moving Average, ARIMA) 模型^[3]、支持向量回归 (Support Vector Regression, SVR) 模型^[4]等。这些方法在电力负荷预测^[5]、金融风险评估^[6]、设备故障检测^[7]等领域已取得良好应用效果。然而,炼化过程安全指标具有数据维度多、波动性强、周期变化显著等特点,导致传统单一模型在预测准确性与适应性方面仍存在不足,难以全面捕捉不同指标间的非线性、多尺度特征^[8]。此外,模型参数依赖人工设定、泛化能力有限等问题,也制约了其在复杂工业场景中的推广应用。

鉴于此,笔者拟建立一种融合多模型的工艺安全指标数据预测方法。通过融合指数平滑、ARIMA 以及基于粒子群优化 (Particle Swarm Optimization, PSO) 的 SVR 等模型,计算并预测炼化企业过程安全指标运行趋势,以期提高企业过程安全管理水平,及时预测较差指标,减少事故发生。

1 工艺安全指标分析

国内外各大传统炼化企业偏重于考核结果性指

标,但是,自 2005 年德克萨斯炼油厂事故以来,过程性安全指标日益受到重视。国内相关炼化企业也逐渐设置了相关绩效指标体系,其中,管理性指标偏多,如依法依规、隐患排查治理、人员培训等相关指标均偏向定性描述,无法实现炼化企业过程安全管理指标的报警与缺陷量化分析。随着数据分析、人工智能等方法的发展,应建立一套适用于量化表征炼化企业过程安全管理情况的指标体系,包含结果性安全指标、过程性安全指标 2 个层次。结果性安全指标通常包括事故事件率、记录伤害率、事故数、死亡人数等表征企业发生事故情况的指标;过程性安全指标主要从各专业安全出发,包括设备安全、工艺安全、作业安全、风险与隐患管理水平、体系运行水平等指标族。各指标族下分别设置一级、二级指标,结合企业实际运行情况及相关国家标准,列举工艺安全的过程安全指标,见表 1。

表 1 工艺安全指标示例

Table 1 Examples of process safety indicators

一级指标	二级指标
工艺参数报警率	时平均报警数
	24 h 持续报警数
	10 min 峰值报警数
工艺参数波动率	平稳率
流程自动化率	自控率
	先进过程控制有效投用率
	联锁投用率
	人均控制回路数

推行相关指标有助于实时、动态掌握炼化企业工艺、设备过程安全管理绩效。通过数据驱动,并结合各专业安全过程安全绩效评价模型及指标数据预测模型,可实现相关专业安全指标的预测及预警,促进基层人员有效落实工艺、设备等关键专业安全管理要求。以时平均报警数为例,该指标表述的是企业每小时报警的数量,相关报警范围包括工艺相关的温度、流量、压力、液位等,设备相关的位移、振动、电流等报警信息,有效预测相关工艺指标数据,有助

于企业及时改进并完善其工艺安全管理水平。

2 工艺安全指标数据清洗与预处理

在数据采集时,可能存在设备故障、人为操作错误、临时停车但依然记录数据、数据记录单位转换错误等因素,导致指标时间序列数据中出现异常值,又称为离群值。在进行多模型预测前,应预处理离群值,避免其对模型计算结果造成影响,因此,先进行异常值检测及处理。

2.1 异常值检测

异常值检测方法较多,可直接利用散点图、箱线图等进行数据可视化直接观测,同时,也可采用统计方法进行检测^[9]。文中采用格鲁布斯检验法检测时间序列中的异常值,具体步骤如下。

- 1) 给定原假设 H_0 : 数据集中无异常值。
- 2) 将统计值 G_c 定义为:

$$G_c = \frac{\max |X_i - \bar{X}|}{SD} \tag{1}$$

式中: $\bar{X}$ 为样本均值; X_i 为每个样本数据; SD 为样本标准差。

其临界值 G_r 定义为:

$$G_r = \frac{(N-1)}{\sqrt{N}} \sqrt{\frac{(t_{\beta/(2N), N-2})^2}{N-2 + (t_{\beta/(2N), N-2})^2}} \tag{2}$$

式中: N 为样本量; β 为显著性水平,表示愿意接受的错误概率。

- 3) 若统计值 G_c 大于临界值 G_r ,即拒绝原假设,可作出数据集中有异常值的判断。

以某炼化企业 1 年 320 多天的时平均报警数据为例,经过计算,得到 G_c 与 G_r 分别为 14.19、3.74,显然统计值大于临界值,因此,存在异常值,应当及时处理。

2.2 异常值处理

Hampel 滤波器^[10]基于中值和中值绝对偏差 (Median Absolute Deviation, MAD) 对异常值更具鲁棒性,其核心在于中值的计算和 MAD 的求解,中值代表数据中间值, MAD 则度量数据与中值中间的离散程度^[11]。故采用此方法处理时间序列中的异常值。

MAD 是每个数据点与中值之间绝对差的中值,其计算公式如下:

$$MAD = \text{median}(|X_i - m|) \tag{3}$$

式中: m 为数据中值; median 为取中间值。

Hampel 滤波器异常值的判定标准是:若数据点 X_i 的绝对偏差除以 MAD 超过阈值,则将其替换为数据中值,否则保持原始值。将滤波器窗口大小设置为 6,阈值设置为 5.5,检测出异常值,并进一步处理后,结果如图 1 所示。




图 1 Hampel 滤波后时间序列
Fig. 1 Hampel filtered time series

3 融合多预测模型的预测方法

因工艺安全指标较多,选取工艺安全中相对比较重要的时平均报警数指标为例进行举例说明,将预处理后的时间序列数据作为输入样本,分别采用指数平滑法、ARIMA 以及 PSO-SVR 方法进行分析计算,得到预测数据,并分析对比采用不同方法计算得到的预测数据误差。

3.1 基于 ARIMA 方法的指标数据预测

采用 ARIMA 方法进行时间序列预测时,应检验时间序列的平稳性。常用的方法为单位根检验法 (Augmented Dickey-Fuller, ADF)。该方法利用 ADF 值判断时间序列在置信区间上是否显著,若具有显著性,则确定该时间序列是平稳的,反之,则是非平稳时间序列。若时间序列呈现非平稳趋势,需进行差分运算,直至时间序列达到平稳。

使用 Python 对时平均报警数指标数据进行 ADF 检验,结果见表 2。

表 2 ADF 检验结果
Table 2 ADF test results

指标名称	差分阶数	t	P
每小时平均报警数	0	-1.77	0.39>0.05
	1	-6.63	0.00<0.05
	2	-8.25	0.00<0.05

注: t 表示单位根假设下的检验统计量; P 表示原假设 (存在单位根) 成立的概率。

由表 2 可知:对于时平均报警数,其在 1 阶差分后, p 才趋近 0,且随差分阶数增大, t 逐渐变小,表明时平均报警数在 1 阶差分时时间序列数据是平稳的。

基于 ARIMA 方法预测指标时间序列数据时,需确定 3 个重要参数,分别为 p 、 q 、 d 。其中, d 为阶数,通过 ADF 检验确定。 p 为自回归方法的阶数值, q 为移动平均方法的阶数值。采用赤池信息量 (Akaike Information Criterion, AIC) 准则确定 p 和 q 的阶数。AIC 准则的计算公式如下:

$$AIC = -2\ln L + 2 \times (p + q + 1)$$

(4)

式中 L 为 ARIMA 模型的极大似然函数值。

AIC 准则的目标是寻找不同 p 和 q 的组合,并选择最小 AIC 值组合作为最佳阶数。将 p 和 q 的边界条件设为 $[0, 4]$,时平均报警数指标数据在不同阶数的 AIC 计算结果见表 3。

表 3 不同阶数的 AIC 计算值

Table 3 AIC calculated values of different orders

p	d	q	AIC
0	1	0	282.523
0	1	1	217.463
0	1	2	210.667
1	1	0	246.559
1	1	1	210.145
1	1	2	212.131
2	1	0	233.537
2	1	1	212.126
2	1	2	212.172
2	1	3	213.998
2	1	4	212.799
3	1	0	228.785
3	1	1	213.539
3	1	2	213.701
3	1	3	216.073
3	1	4	213.670
4	1	0	211.678
4	1	1	210.222
4	1	2	210.697
4	1	3	207.048
4	1	4	207.825

由表 3 可知:当 ARIMA 模型参数为 (4, 1, 3) 时,AIC 最小,故计算 ARIMA(4, 1, 3) 的趋势预测结果,并对比趋势预测结果与原始数据,如图 2 所示。

从图 2 可以看出,使用 ARIMA 模型进行时间序列预测,得到的趋势与原始值基本保持一致,但在最大值与最小值的预测上,数值差距较大。




图 2 ARIMA 预测值与原始值对比

Fig. 2 Comparison of ARIMA predicted values with original values

3.2 基于指数平滑法的指标数据预测

由于不同指标呈现出不同的趋势,因此,对于周期性趋势较强的指标,采用指数平滑法预测指标时间序列数据。通过对过去观察到的数据赋予不同的权重,以便更好地捕捉数据的趋势变化。采用二次指数平滑模型分别计算时平均报警数的时间序列数据。

二次指数平滑的计算公式如下:

$$\begin{cases} S_t^{(1)} = \alpha y_t + (1 - \alpha) S_{t-1}^{(1)} \\ S_t^{(2)} = \alpha S_t^{(1)} + (1 - \alpha) S_{t-1}^{(2)} \end{cases}$$

(5)

预测模型如下:

$$\hat{y}_{t+m} = a_t + b_t m, m = 1, 2, \dots$$

(6)

$$\begin{cases} a_t = 2S_t^{(1)} - S_t^{(2)} \\ b_t = \frac{\alpha}{1 - \alpha} (S_t^{(1)} - S_t^{(2)}) \end{cases}$$

(7)

式中: α 为平滑系数,取值区间为 $[0, 1]$; $S_t^{(1)}$ 为一次指数的平滑值; $S_t^{(2)}$ 为二次指数的平滑值。取 $\alpha = 0.5$, 计算得到时平均报警数指标的结果,如图 3 所示。

从图 3 可以看出,预测值趋势基本与实际值趋势一致,且计算的极大、极小值相比,ARIMA 模型更加接近原始值。

3.3 基于 PSO-SVR 的时间序列预测

1) SVR 建模。随着系统的持续运行,指标数据不断积累,为机器学习建模提供有利的数据基础。采用 SVR 方法,建模预测关键指标。

SVR 旨在寻找一个在允许误差范围内最平滑的回归函数,具备较强的泛化能力。为解决实际中非线性的时间序列问题,引入惩罚系数 C 与松弛变




图3 指数平滑法预测值与原始值对比
Fig.3 Comparison between predicted values and original values of exponential smoothing method

量,通过构造带约束的损失函数实现对误差的控制。其中,惩罚系数 C 用于平衡模型复杂度与预测精度, C 值越大,对预测误差的惩罚越强,模型拟合能力越强,但过大可能导致过拟合。

为增强对非线性特征的拟合能力,采用核函数方法将输入空间映射至高维特征空间。选用径向基函数核(Radial Basis Function, RBF),其通用性强,适用于复杂边界条件。RBF 核函数定义为:

$$K(x_i, x_j) = \exp(\gamma \|x_i - x_j\|) \quad (8)$$

式中 γ 为控制高斯函数的模糊程度,即核函数的响应范围。 γ 值较小时,核函数作用范围大,模型较平滑; γ 值较大时,模型更关注局部特征。

2) 参数优化。惩罚参数 C 决定分类错误的惩罚程度,径向基核函数中参数 γ 控制了数据映射到特征空间后的模糊程度。这 2 个参数的值设置过大或过小都可能导致模型过拟合或欠拟合。因此,要获得优秀的 SVR 的分类性能,需要选取合适的值。通过调整参数取值,获取最优参数组合,并使模型性能最佳,该过程即为参数优化过程。

参数优化一般是通过合适的搜索策略,在大规模、高纬度的复杂问题中找到全局最优解。传统的参数选择方法往往难以获得最优的参数组合,从而限制了其在实际应用中的效果。因此,采用 PSO 优化 SVR 模型参数^[12]。

PSO 是一种基于群体智能的优化算法,其灵感来源于鸟群觅食的行为。PSO 通过个体之间的信息共享和协同搜索,能够有效探索和开发解空间,寻找全局最优解。由于其简单易实现、收敛速度快等优点,PSO 在参数优化、功能优化等方面显示出强大的能力^[13]。整体计算流程如图 4 所示。

3) 指标数据预测。以时平均报警数指标数据




图4 基于 PSO-SVR 的计算流程
Fig.4 Flow chart of calculation based on PSO-SVR

为例,利用该方法实现数据预测。

该算法设置时间窗口为 30,按照 8 : 2 的比例将数据划分为训练集和测试集。学习因子 l_1 和 l_2 分别为 0.5 和 0.3,惯性因子 w 设置为 0.9。设定 SVR 惩罚参数 C 和高斯核函数参数 γ 的边界条件: $C \in [10, 20]$, $\gamma \in [0.001, 10]$ 。

经过计算,得到时平均报警数的计算结果如图 5 所示。




图5 PSO-SVR 预测值与原始值对比
Fig.5 Comparison of PSO-SVR predicted values with original values

从图 5 可以看出,前期数据预测值与原始值差距较大,但整体可预测趋势走向,而随着机器学习的输入数据不断增多,预测值与原始值逐渐接近。

4 不同预测方法误差分析

在评估预测模型时,常用的指标有均方根误差(Root Mean Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)。

1) RMSE 的计算公式如下:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

(9)

式中: y_i 为实际值; $\hat{y}_i$ 为对应的预测值; n 为样本数量。RMSE 通常用于评估模型整体预测的准确性,对异常值与大误差较为敏感,可反映出预测值与实际值之间的离散程度。

2) MAE 的计算公式如下:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

(10)

相较于 RMSE,其计算的是预测误差的绝对值的平均,更加偏向于反映出预测数据中小误差的情况,若预测数据中异常值较少,则更加适用。

为准确评估不同模型对不同指标时间序列数据的适用性,采用加权组合方式计算时间序列预测结果误差,并以此为基准选择合适的模型。将该指标定义为 E ,其计算公式如下:

$$E = k_1 \times \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} + k_2 \times \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

(11)

式中 k_1 和 k_2 分别为均方根误差和平均绝对误差的权重。鉴于不同指标的差异性,且数据计算前经过异常值处理,更为关注平均绝对误差,因此,以 $k_1 = 0.4, k_2 = 0.6$ 计算最终误差 E 。

对于时平均报警数指标,不同方法计算得到的误差见表 4。

表 4 时平均报警数误差计算

Table 4 Error calculation of time-averaged alarm count

计算模型	RMSE	MAE	E
ARIMA	0.325	0.195	0.247
指数平滑	0.094	0.052	0.069
SVR	0.177	0.115	0.140

从表 4 可以看出,对于时平均报警数,使用 ARIMA 方法计算得到的预测数据误差最大,误差最小的是二次指数平滑法,使用基于 PSO-SVR 算法得到的预测数据误差则比指数平滑法略大。因此,对于目前的数据量,采用二次指数平滑法效果最好,但随着数据量的增加,采用监督式机器学习方式的 SVR 误差当量会进一步减少,效果可能会超过其他方法。

为进一步分析不同方法对不同指标的预测效果,比较不同算法的残差结果,即预测值与原始值之差,如图 6 所示,不同算法的最大与最小误差占比见表 5。




图 6 不同方法计算残差对比

Fig. 6 Comparison of residuals calculated by different methods

表 5 不同方法残差占比对比

Table 5 Comparison of residual proportion between different methods

计算模型	最大残差占比	最小残差占比
ARIMA	2.79	0.000 8
指数平滑	0.72	0
SVR	2.12	0.000 9

从图 6 可以看出,在大概 170 天前,时平均报警数整体呈现先增加后下降的趋势,但报警数整体偏低,波动不大。3 种方法均可较好地预测这种趋势,但指数平滑法在前期数据表现出的残差结果最好,ARIMA 方法次之,SVR 方法在前期计算经常出现残差较大的值。随着时间的推进,在 170 天左右,报警数呈现突增的趋势,这可能是因为装置出现工艺调整、检修或非计划停工等原因。指数平滑法与 SVR 方法计算得到的预测值显然与突变后的区间范围更贴近,而 ARIMA 法的曲线拟合程度较差。ARIMA 方法在中后期得到的残差曲线波动最大,远高于其他 2 种方法。指数平滑法整体残差曲线较低,结合表 5 看出,残差占比表现最好,这可能是因为该指标数据量较少,且呈现的趋势性较为明显,对于该方法较为适用。而基于 PSO-SVR 预测在前期残差较大,随机器学习的数据量增多,残差显著降低,可以预见,随指标数据量的不断增加,基于 PSO-SVR 预测结果准确性不断提升,残差也将不断减少。最终,基于模型性能评估指标,构建基于动态权重分配的融合框架,根据不同指标在不同方法的预测性能指标,动态分配不同方法权重。

5 结 论

1) 围绕炼化企业工艺安全管理中关键指标的

趋势预测问题,构建一种融合多模型的时间序列预测方法。该方法通过集成 ARIMA、二次指数平滑与 PSO-SVR 模型,并基于误差动态分配模型权重,可有效提升不同特征安全指标的预测精度与适应性。

2) 实证研究结果表明:该方法在预测时平均报警数等关键指标方面表现出良好的准确性与鲁棒性,可为炼化企业构建以数据驱动的智能化预警机制提供方法支撑,有助于企业实现过程安全绩效的

动态评估与风险源头管控,从而提升本质安全水平。

3) 文中仍存在一定局限性。一方面,模型训练样本数量有限,可能影响部分模型在大数据条件下的泛化能力;另一方面,当前预测方法主要针对单变量指标,对于多变量间的协同演化规律尚缺乏系统研究。未来可进一步拓展为多指标协同预测模型,并结合深度学习方法增强模型的特征提取能力与长期预测能力,以适应更加复杂多变的工业应用场景。

参考文献

- [1] 李传坤. 炼化过程工艺报警管理研究[J]. 安全、健康和环境, 2021, 21(1): 74-78.
LI Chuankun. Research on process alarm management of refining and chemical process[J]. Safety Health & Environment, 2021, 21(1): 74-78.
- [2] 林锦全. 基于模糊指数平滑法的工程造价估算方法[J]. 建筑与预算, 2023(8): 19-21.
LIN Jinquan. A method for estimating engineering construction costs based on fuzzy exponential smoothing[J]. Construction and Budget, 2023(8): 19-21.
- [3] 孙建波. 基于 ARIMA 线性时间序列的埋地输油管道剩余寿命预测[J]. 辽宁化工, 2024, 53(3): 471-475.
SUN Jianbo. Residual life prediction of buried oil pipeline based on ARIMA linear time series[J]. Liaoning Chemical Industry, 2024, 53(3): 471-475.
- [4] 王军武,何娟娟,宋盈辉,等. 基于 RF-SFLA-SVR 的装配式建筑高空作业工人不安全行为预警[J]. 中国安全科学学报, 2024, 34(3): 1-8.
WANG Junwu, HE Juanjuan, SONG Yinghui, et al. Research on early warning for prefabricated building workers' unsafe behaviors of working at height based on RF-SFLA-SVR[J]. China Safety Science Journal, 2024, 34(3): 1-8.
- [5] 马国石. 基于 ARIMA 的短期电力负荷预测方法[J]. 电力设备管理, 2025(2): 195-197.
MA Guoshi. Short-Term power load forecasting method based on ARIMA[J]. Electric Power Equipment Management, 2025(2): 195-197.
- [6] 陈满丽,张慧娟,焦楠楠,等. 基于 MATLAB 的 ARIMA 模型对我国 GDP 预测的研究[J]. 中国市场, 2024(12): 1-4.
CHEN Manli, ZHANG Huijuan, JIAO Nannan, et al. A study on forecasting China's GDP Using ARIMA model based on MATLAB[J]. China Market, 2024(12): 1-4.
- [7] 牛鲁娜,兰正贵,胡海军. 常压塔塔顶腐蚀关键参量相关性分析与预测[J]. 安全、健康和环境, 2020, 20(3): 21-26.
NIU Lu'na, LAN Zhenggui, HU Haijun. Correlation analysis and prediction of key parameters of corrosion in an atmosphere tower overhead system[J]. Safety Health & Environment, 2020, 20(3): 21-26.
- [8] 马晨哲,王霄,杨波,等. 基于 ARIMA 与 NNAR 模型的甘肃省胰腺癌发病趋势预测[J]. 现代肿瘤医学, 2024, 32(11): 2 080-2 084.
MA Chenzhe, WANG Xiao, YANG Bo, et al. Prediction of pancreatic cancer incidence trend in Gansu province based on ARIMA and NNAR model[J]. Journal of Modern Oncology, 2024, 32(11): 2 080-2 084.
- [9] 褚建平,孙艳琳,薛茜. 中国科创板股票价格变动预测模型研究[J]. 武汉理工大学学报: 信息与管理工程版, 2024, 46(2): 343-348.
CHU Jianping, SUN Yanlin, XUE Qian. Research on the prediction model of stock price changes of China's science and technology innovation board[J]. Journal of Wuhan University of Technology: Information & Management Engineering, 2024, 46(2): 343-348.
- [10] ALLEN D P. A frequency domain Hampel filter for blind rejection of sinusoidal interference from electromyograms[J]. Journal of Neuroscience Methods, 2009, 177: 303-310.
- [11] 廖栋森,祝长鸿,余琪琦,等. 基于分层的体域网异常数据检测方法[J]. 计算机工程与设计, 2024, 45(1): 197-203.
LIAO Dongsan, ZHU Changhong, YU Qiqi, et al. Hierarchical anomaly data detection method for body area networks[J]. Computer Engineering and Design, 2024, 45(1): 197-203.
- [12] 吴红,王晓明,王斌,等. PSO-SVR 模型在化工事故风险预测中的应用研究[J]. 工业安全与环保, 2022, 48(4): 70-73.
WU Hong, WANG Xiaoming, WANG Bin, et al. Research on the application of PSO-SVR model in the risk prediction of chemical industry accidents[J]. Industrial Safety and Environmental Protection, 2022, 48(4): 70-73.
- [13] 石博文,尹燕燕,刘飞. 基于 PSO-控制变量参数化混合策略的间歇化工过程优化控制[J]. 化工学报, 2019, 70(3): 979-986.
SHI Bowen, YIN Yanyan, LIU Fei. Optimal control strategies combined with PSO and control vector parameterization for batchwise chemical process[J]. CIESC Journal, 2019, 70(3): 979-986.

作者简介: 刘洋 (1995—),男,山东烟台人,硕士,工程师,主要从事化工安全智能化技术方面的工作。
E-mail:liuyang.qday@sinopec.com。