

自适应综合指标的化工过程参数报警阈值优化方法研究

罗静, 胡瑾秋*

中国石油大学(北京)机械与储运工程学院, 北京 102249

* 通信作者, hujq@cup.edu.cn

收稿日期: 2016-11-15

摘要 面临日益复杂的化工过程生产装置, 提高化工过程报警系统的性能有着重要的指导意义。传统的化工过程参数报警阈值设置方法一般只考虑误报警, 并没有同时考虑误报警和漏报警, 导致报警系统产生大量的错误报警。针对上述问题, 提出自适应综合指标的报警阈值优化方法。采用核密度估计方法、基于历史数据对过程报警状态进行估计, 综合考虑误报警率和漏报警率, 从而建立优化报警阈值的目标函数, 将数值优化算法内嵌于粒子群算法形成新的算法进行求解。案例分析中将此方法应用于TE过程, 结果表明, 用此方法设置的报警阈值监测误报率为0, 漏报率为0.78%。与传统的 3σ 法相比, 此方法能够在保证低漏报率的条件下有效降低误报率, 提高化工过程报警系统的性能, 减轻现场操作人员的工作压力, 减少人员生命财产损失。

关键词 自适应; 综合指标; 误报警; 漏报警; 核密度估计; 粒子群算法

0 引言

化工生产过程日益复杂, 具有大量的过程数据, 及时准确地判断这些过程数据的异常状况关系到化工生产过程的安全性与可靠性, 进而关系到人员生命财产安全。因此, 提高过程参数报警系统的性能具有重大意义。当前工业过程中存在着报警数目多的问题, 根据WIT的研究^[1], 操作员有效处理的报警为每天150个(每10分钟1个报警), 一天最多处理300个报警(每5分钟1个报警), 而在实际过程中则远远超出这个数字。报警数目多的直接原因是报警阈值设置的不合理, 阈值范围设置得过小会产生过多的报警, 其中大部分为误报警^[2-4]。相反, 如果阈值范围设置得过大可能会漏掉重要报警, 报警系统将失去作用。

常见的过程参数报警阈值的设置分为3类: (1)基于模型的方法; (2)基于知识的方法; (3)基于统计的方法。文献[5]建立了在线和离线模型进行报警阈值的

优化; 文献[6]根据数据的伯努利分布特性, 在多变量统计过程中构建统计量的二级的控制限, 减少了误报警; 文献[7]将模糊神经网络和遗传算法用于阈值估计的训练; 文献[8]提出核密度估计方法得到多元统计量的概率密度函数, 之后由等概率密度曲线得到数据分布的正常区间。在实际工业过程中应用最多的是 3σ 阈值设定方法, 它是根据过程参数在正常状态的历史数据, 计算分别得到其均值 μ 和方差 σ , 将阈值范围设在区间 $[\mu - 3\sigma, \mu + 3\sigma]$ 内。根据概率论知识, 落在此区间内的概率为99.73%, 而落在此范围外的概率仅为0.27%, 属于小概率事件。然而, 以上方法在设置阈值时一般只考虑误报警, 并没有同时考虑漏报警, 导致报警系统产生大量的错误报警。

鉴于此, 提出自适应综合指标的报警阈值优化方法。采用核密度估计方法、基于历史数据对过程报警状态进行估计, 综合误报警率和漏报警率, 建立优化报警阈值的目标函数, 将数值优化算法内嵌于粒子群

引用格式: 罗静, 胡瑾秋. 自适应综合指标的化工过程参数报警阈值优化方法研究. 石油科学通报, 2016, 03: 407-416

LUO Jing, HU Jinqiu. A study of adaptive composite-indicator alarm threshold optimization of chemical process parameters. Petroleum Science Bulletin, 2016, 03: 407-416. doi: 10.3969/j.issn.2096-1693.2016.03.036

算法形成新的算法进行求解。此方法能够有效减少误报警和漏报警次数,提高化工过程报警系统的性能,在减少现场操作人员工作压力的同时又能够捕捉到重要报警信息,保证现场安全,减少人员生命财产损失。

1 自适应综合指标报警阈值优化方法的基本概念

1.1 核密度估计

为了构造报警阈值优化的目标函数,需要利用核密度估计方法来估计过程参数的报警状态,以确定误报警和漏报警。核密度估计(Kernel Density Estimation, KDE)是一类基于概率密度函数的非参数估计法,它从数据样本本身出发研究数据分布的特征。KDE基于历史数据估计未知总体的概率密度函数,使估计的密度函数与真正的密度函数间的均方积分误差最小。KDE的表达式为:

$$f(x) = \frac{1}{rh^d} \sum_{i=1}^r k\left(\frac{x-x_i}{h}\right) \quad (1)$$

式中, x_i 为归一化后的自变量; $f(x)$ 为自变量概率密度的估计值,取 $f(x)=0.99$ 时的自变量,返回一化后得到自变量阈值 δ ; r 为样本数; d 为空间的维数; $f(x)$ 为核函数,本文选用高斯核函数; h 为窗宽,一维最优窗宽的计算公式为

$$h = 1.059 \xi r^{-\frac{1}{5}} \quad (2)$$

$$\text{式中, } \xi = \left[\frac{1}{r} \sum_{i=1}^r (x_i - \bar{x})^2 \right]^{\frac{1}{2}}; r \text{ 为样本数。}$$

选定样本后,根据式(1)和(2)计算每个样本点的概率密度值,以其作为纵坐标,样本点作为横坐标,运用KDE方法得到过程参数概率密度函数曲线(如图1所示)。图中,左侧曲线为正常数据分布曲线,右侧曲线为异常数据分布曲线,竖线所对应的横坐标为参数报警阈值,异常数据分布曲线下低于报警阈值部分的区域面积是漏报率的概率,正常数据分布曲线下超出报警阈值部分的区域面积是误报率的概率。

根据最小错误率贝叶斯决策理论^[6],误报警和漏报警发生的概率可以通过式(3)、(4)计算:

$$P_1(e) = \int_t^{+\infty} f(x|\omega_1) dx \quad (3)$$

$$P_2(e) = \int_{-\infty}^t f(x|\omega_2) dx \quad (4)$$

式中, $f(x|\omega_1)$ 为正常情况下的概率密度函数;




图1 过程参数概率密度

Fig. 1 Process parameters probability density

$f(x|\omega_2)$ 为异常情况下的概率密度函数; t 为报警阈值。可见,若报警阈值设置过大,误报警的概率变小,而漏报警的概率变大;反之,误报警的概率增大,而漏报警的概率减小。

1.2 数值优化算法

本文选用最常见的数值优化算法来寻找最佳阈值^[1]。误报警和漏报警均属于错误报警,因此,将错误报警率作为数值优化算法的目标函数,建立如下报警阈值优化问题

$$\begin{aligned} \text{Min} F(x) &= P_1(e) + P_2(e) \\ &= \int_t^{+\infty} f(x|\omega_1) dx + \int_{-\infty}^t f(x|\omega_2) dx \end{aligned} \quad (5)$$

$$\text{S.t. } f(x|\omega_j) = \frac{1}{nh} \sum_{i=1}^n k\left(\frac{x-x_i}{h}\right), \quad a < t < b \quad (6)$$

式中, $f(x)$ 是错误报警率; $P_1(e)$ 是误报警率; $P_2(e)$ 是漏报警率; t 是选择的阈值; n 是样本点个数; h 是KDE的窗宽,由式(2)计算。

数值优化算法的实现步骤如下:

(1) 在区间 $[a, b]$, 构造两点 $x_1 = a + q(b-a)$, $x_2 = a + (1-q)(b-a)$, 式中, q 和 $(1-q)$ 分别是算法的两个系数, $q \in \left(0, \frac{1}{2}\right)$, 一般取 $q = 0.382$;

(2) 若 $F(x_1) < F(x_2)$, 则搜索区间缩小为 $[a, x_2]$, $b = x_2$, 判断 $|x_2 - x_1| < \varepsilon$ 是否成立, 如果成立转到步骤(4), 否则返回步骤(1);

(3)若 $F(x_1) \geq F(x_2)$, 则搜索区间缩小为 $[x_1, b]$, $a = x_1$, 判断 $|x_2 - x_1| < \varepsilon$ 是否成立, 如果成立转到步骤(4), 否则返回步骤(1);

(4)最优解为 $t = x^* = \frac{1}{2}(x_1 + x_2)$, 目标函数最小值为 $F(x^*)$ 。

然而, 数值优化算法的系数 q 和 $(1-q)$ 是人为设置的, 并不能保证算法寻优结果接近全局最优。因此, 本文采用粒子群(Particle Swarm Optimization, PSO)算法对系数 q 进行优化, 使寻优结果接近全局最优。

1.3 粒子群算法

粒子群(PSO)算法最早在 1995 年被提出, 是一种从生物活动中得到启发而模拟自然界生物集群现象的进化算法。在 PSO 算法中, 每个优化问题的潜在解都称为“粒子”, 所有的粒子都有一个由被优化的函数决定的适应值(Fitness Value), 每个粒子还有一个速度决定它们移动的方向和每一步的位移。然后粒子们就追随当前的最优粒子在解空间中搜索。PSO 算法需要初始化一群随机粒子(随机解), 然后通过迭代找到最优解, 在每一次迭代中, 粒子通过跟踪两个“极值”来更新自己。第一个就是粒子本身所找到的最优解, 这个解称为个体极值。另一个是整个种群目前找到的最优解, 这个解称为全局极值。

假设在一个 N 维的目标搜索空间中, 有 m 个粒子组成一个群落, 将第 i 个粒子的位置表示为一个 N 维的向量, 记为 $\bar{q}_i = (q_{i1}, q_{i2}, \dots, q_{iN}), i=1, 2, \dots, m$ 。每一个粒子都是潜在的解, 将 \bar{q}_i 带入一个目标函数就可以计算出其适应值, 根据适应值大小衡量 \bar{q}_i 的优劣。第 i 个粒子的移动速度也是一个 N 维的向量, 记为 $\bar{v}_i = (v_{i1}, v_{i2}, \dots, v_{iN})$, 速度决定粒子在搜索空间单位迭代次数的位移。记第 i 个粒子迄今为止搜索到的最优位置为 $\bar{p}_i = (p_{i1}, p_{i2}, \dots, p_{iN})$, 整个粒子群迄今为止搜索到的最优位置为 $\bar{p}_g = (p_{g1}, p_{g2}, \dots, p_{gN})$ 。粒子根据以下公式来更新其速度和位置

$$v_{in} = wv_{in} + c_1r_1(p_{in} - q_{in}) + c_2r_2(p_{gn} - q_{in}) \quad (7)$$

$$q_{in} = q_{in} + v_{in} \quad (8)$$

式中, $i=1, 2, \dots, m$; $n=1, 2, \dots, N$; 速度权重 w 随机取值于 $[-1, 1]$; 学习因子 c_1 和 c_2 是非负常数; r_1 和 r_2 是介于 $[0, 1]$ 之间的随机数; v_{in} 是第 i 个粒子速度向量的第 n 维, $v_{in} \in [-v_{max}, v_{max}]$, v_{max} 是常数, 根据实际情况设定。

迭代终止条件一般选为最大迭代次数或粒子群迄今为止搜索到的最优化位置满足适应阈值。因为 \bar{p}_g 是整个粒子群的最优值, 因此上述 PSO 算法也称为全局 PSO 算法。

2 自适应综合指标报警阈值优化方法步骤

针对传统阈值优化方法仅考虑误报警, 并没有综合考虑误报警和漏报警从而造成大量漏报的问题, 提出自适应综合指标报警阈值优化方法。综合考虑误报警和漏报警两个方面建立目标函数, 并用数值优化算法内嵌入 PSO 算法形成新的算法对报警阈值寻优, 力求达到降低错误报警次数的目的, 从而减轻现场操作人员的工作压力。自适应综合指标报警阈值优化方法的工作流程如图 2 所示, 具体步骤如下:

步骤 1: 选择化工过程某参数的正常样本 $X \in R_{1 \times N_s}$ 和故障样本 $Y \in R_{1 \times N_s}$ 。其中, N_s 是样本点个数, 根据实际情况选取;

步骤 2: 绘制概率密度曲线, 设置解区间。基于数据样本 X 和 Y , 利用式(1)和(2)分别估算过程参数正常条件下和故障条件下的概率密度, 以其作为纵坐标, 样本点作为横坐标, 绘制过程参数概率密度曲线, 并设置解的区间 $[a, b]$ 。若求报警阈值上限的区间, $a = \max(X) - 3\sigma$, $b = \max(X) + 3\sigma$; 若求报警阈值下限的区间, $a = \min(X) - 3\sigma$, $b = \min(X) + 3\sigma$ 。式中, σ 为正常样本 X 的标准差;

步骤 3: 建立 PSO 算法的适应度 $G(\bar{q})$ 。将数值优化算法作为 PSO 算法的内嵌算法, 设 q 和 $(1-q)$ 分别是数值优化算法的两个系数。当 q 取一定值时, PSO 算法的适应度 $G(\bar{q})$ 取数值优化算法目标函数的最小值 $F(x^*)$ 。以系数 q 对应的向量 \bar{q} 作为粒子位置, PSO 算法的目的是寻求使适应度最小的解 \bar{q}^* 。

步骤 4: 设置 PSO 算法的参数。粒子速度的惯性权重 w 随机取值于 $[-1, 1]$; 粒子速度的最大值 $v_{max} = 0.5$; 粒子个体最优的学习因子 $c_1 = c\theta_1$, 其中, $c = (2w + 2)\theta_2$, θ_1 和 θ_2 均随机取值于 $[0, 1]$; 粒子群体最优的学习因子 $c_2 = c - c_1$; 算法最大迭代次数 $M = 200$; 种群个体数目 $m = 50$; 算法精度 $e = 0.0001$ 。

步骤 5: 初始化粒子的位置和速度。用系数 q_i 对应的一维向量 \bar{q}_i 来标记第 i 个粒子在一维搜索空间中的位置。第 i 个粒子的移动速度也是一个一维的向量, 记为 \bar{v}_i 。设置第 i 个粒子的初始位置 $\bar{q}_{i0} = 0.5\theta_3$, 粒子

的初始速度 $\bar{v}_{i0} = 0.5\theta_4$, 其中, θ_3 和 θ_4 均是随机取值于 $[0,1]$ 的值。此时, 记粒子代数 $k=1$ 。

步骤 6: 设置粒子个体最优 \bar{p}_i 和群体最优 \bar{p}_{g_k} 的初始值。记第 i 个粒子迄今为止搜索到的最优位置为 \bar{p}_i , 整个粒子群迄今为止搜索到的最优位置为 \bar{p}_{g_k} 。令 $\bar{p}_i = \bar{q}_{i0}$, 并根据步骤 3 计算对应的适应度 $G(\bar{p}_i)$ 。当代最小适应度 $G(\bar{p}_{i^*}) = \min(G(\bar{p}_1), G(\bar{p}_2), \dots, G(\bar{p}_m))$, 则 $\bar{p}_{g_k} = \bar{p}_{i^*}$ 。

步骤 7: 粒子的位置和速度的更新。 $k=k+1$, 根据式(5)计算第 i 个粒子更新后的速度 \bar{v}_{ik} 。判断当代第 i 个粒子的速度 $\bar{v}_{ik} > v_{max}$ 是否成立: 1) 若成立, 令 $\bar{v}_{ik} = v_{max}$; 2) 若不成立, 判断 $\bar{v}_{ik} < -v_{max}$ 是否成立, 若成立, 令 $\bar{v}_{ik} = -v_{max}$; 若不成立, $\bar{v}_{ik} = \bar{v}_{ik}$ 。根据式(6)计算第 i 个粒子更新后的位置 \bar{q}_{ik} , 使得 $|\bar{q}_{ik}| \in (0, 0.5)$ 。

步骤 8: 寻找粒子个体最优 \bar{p}_i 和群体最优 \bar{p}_{g_k} 。根据步骤 3 计算当代第 i 个粒子的适应度 $G(\bar{q}_{ik})$, 若 $G(\bar{q}_{ik}) < G(\bar{p}_i)$, 则 $\bar{p}_i = \bar{q}_{ik}$, 否则, $\bar{p}_i = \bar{p}_i$; 当代最小适应度 $G(\bar{p}_{i^*}) = \min(G(\bar{p}_1), G(\bar{p}_2), \dots, G(\bar{p}_m))$, 且 $G(\bar{p}_{i^*}) < G(\bar{p}_{g_k})$, 则 $\bar{p}_{g_k} = \bar{p}_{i^*}$ 。

步骤 9: 判断迭代终止条件 $|\bar{p}_{g_k} - \bar{p}_{g_{k-1}}| < e$ 是否满足, 若满足, 则迭代终止, 进行步骤 10; 若不满足, 则返回步骤 7, 继续循环迭代。

步骤 10: 输出群体最小适应度 $G(\bar{p}_{g_k})$ 和对应的最佳报警阈值 x^* , 并记录最优粒子的位置 \bar{p}_{g_k} 。

3 实例分析

3.1 TE 过程

由伊斯曼公司设计的 TE(Tennessee Eastman)过程是一个基于实际工业过程的仿真平台, 共包含了反应器、冷凝器、压缩机、分离器和汽提塔等 5 个操作单元, 涉及到 12 个操作变量和 41 个测量变量。TE 过程的工艺流程图如图 3 所示, 部分测量变量如表 1 所示。

3.2 阈值监测

以反应堆温度为例, 用自适应综合指标的化工过程参数报警阈值优化方法设置变量阈值, 进行温度监测。与化工生产中常见的 3σ 法进行对比, 证明该方

法能够降低错误报警率, 优化报警系统的性能。

3.2.1 自适应综合指标报警阈值优化方法

选择 TE 过程反应堆温度测量变量作为研究对象, 运行过程 512 时刻, 在第 256 时刻加入干扰, 使反应堆冷却水阀粘滞, 前 256 时刻过程为正常状态, 后 256 时刻过程为故障状态。选取反应堆温度前 256 组数据作为正常训练样本 $X \in R_{1 \times 256}$, 后 256 组数据作为故障训练样本 $Y \in R_{1 \times 256}$ 。保持同样的操作条件, 运行过程 256 时刻, 在第 161 时刻加入同样的干扰, 获得测试样本 $Z \in R_{1 \times 256}$ (反应堆温度曲线如图 4 所示);

根据数据训练样本 X 和 Y , 采用式(2)计算得反应堆温度正常数据核密度估计的窗宽 $h_1 = 0.3828$, 反应堆温度故障数据核密度估计的窗宽 $h_2 = 0.7299$ 。根据式(2)分别估算反应堆温度正常条件下和故障条件下的概率密度, 以其作为纵坐标, 样本点作为横坐标, 绘制反应堆温度的概率密度曲线(如图 5 所示)。分别设置阈值上限的取值区间 $[120.4492, 120.4508]$ 和阈值下限的取值区间 $[120.3492, 120.3508]$;

建立 PSO 的适应度 $G(\bar{q})$ 。将数值优化算法作为 PSO 的内嵌算法, 当系数 q 取一定值时, 以数值优化算法的目标函数最小值 $F(x^*)$ 作为系数 q 对应的 PSO 适应度 $G(\bar{q})$ 。由式(5)和(6)分别建立数值优化算法的报警阈值上限优化问题(如式(9)–式(10))和报警阈值下限优化问题(如式(11)–式(12))。

$$\text{Min}F_1(x) = \int_{t_1}^{+\infty} f(x|\omega_1)dx + \int_{-\infty}^{t_1} f(x|\omega_2)dx \quad (9)$$

$$\text{S.t.} \begin{cases} f(x|\omega_1) = \frac{1}{256h_1} \sum_{i=1}^{256} k \left(\frac{x-x_i}{h_1} \right) \\ f(x|\omega_2) = \frac{1}{256h_2} \sum_{i=1}^{256} k \left(\frac{x-x_i}{h_2} \right) \end{cases}, \quad (10)$$

$$120.4492 < t_1 < 120.4508$$

$$\text{Min}F_2(x) = \int_{t_2}^{+\infty} f(x|\omega_1)dx + \int_{-\infty}^{t_2} f(x|\omega_2)dx \quad (11)$$

$$\text{S.t.} \begin{cases} f(x|\omega_1) = \frac{1}{256h_1} \sum_{i=1}^{256} k \left(\frac{x-x_i}{h_1} \right) \\ f(x|\omega_2) = \frac{1}{256h_2} \sum_{i=1}^{256} k \left(\frac{x-x_i}{h_2} \right) \end{cases}, \quad (12)$$

$$120.3492 < t_1 < 120.3508$$

其中, $F_1(x)$ 和 $F_2(x)$ 是错误报警率, t_1 和 t_2 是选择的阈值, KDE 窗宽 $h_1 = 0.3828$, $h_2 = 0.7299$ 。

运行报警阈值优化算法:

(1) 报警阈值上限优化

设置 PSO 的参数: 粒子速度的惯性权重

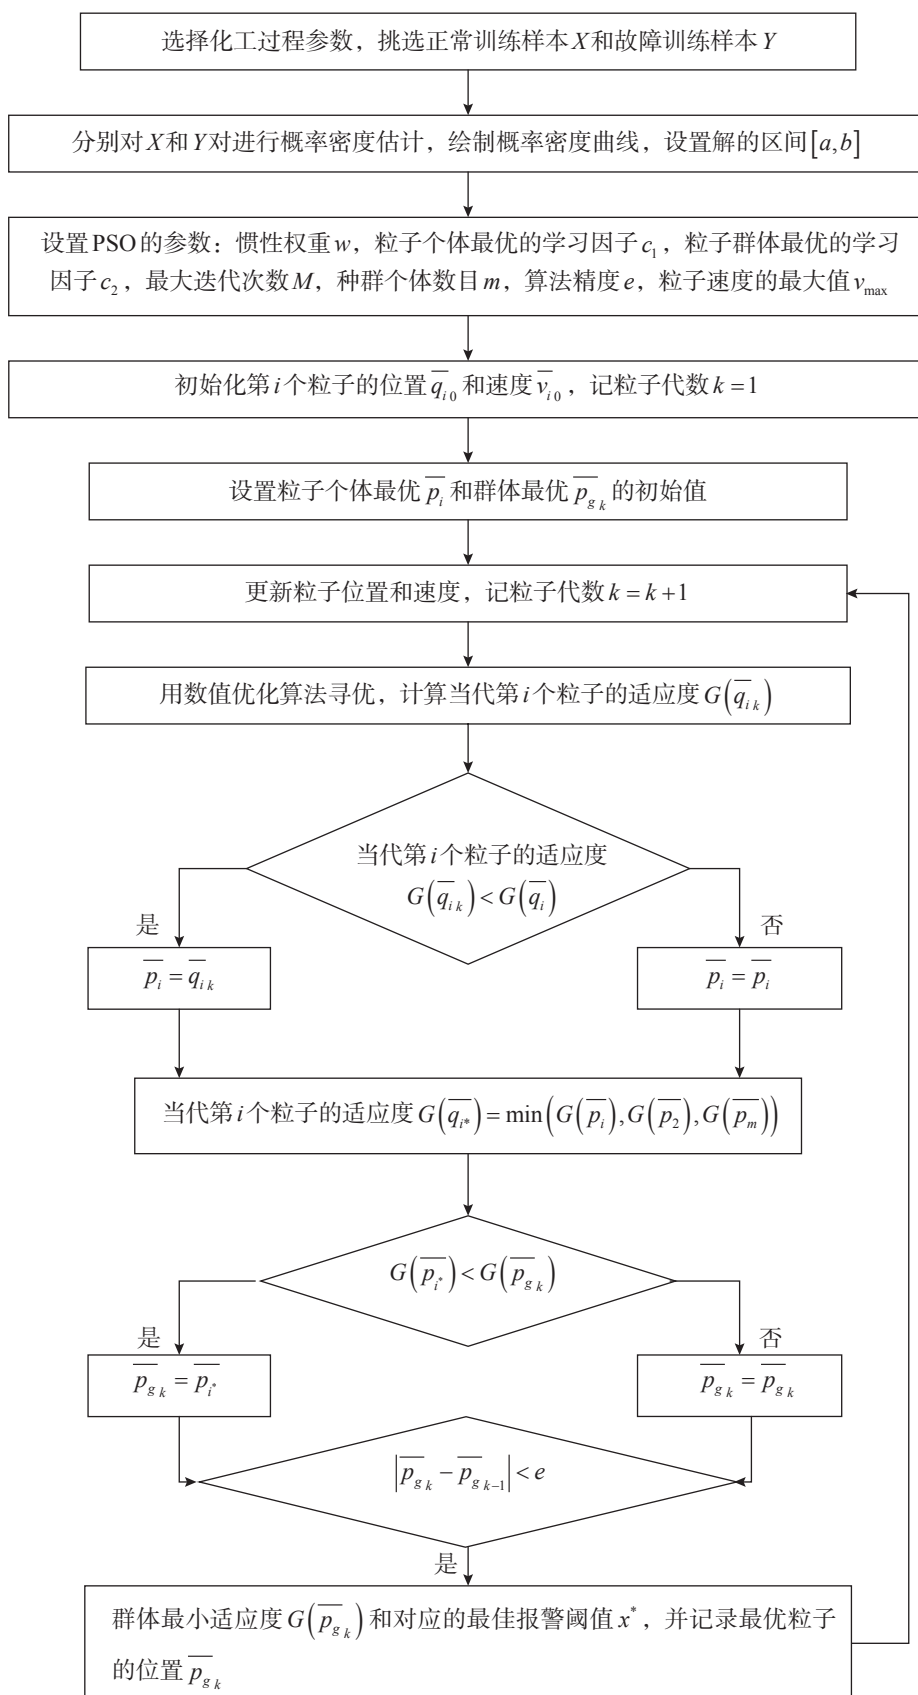


图 2 自适应综合指标报警阈值优化方法步骤

Fig. 2 Steps of the adaptive composite-indicator alarm threshold optimization method

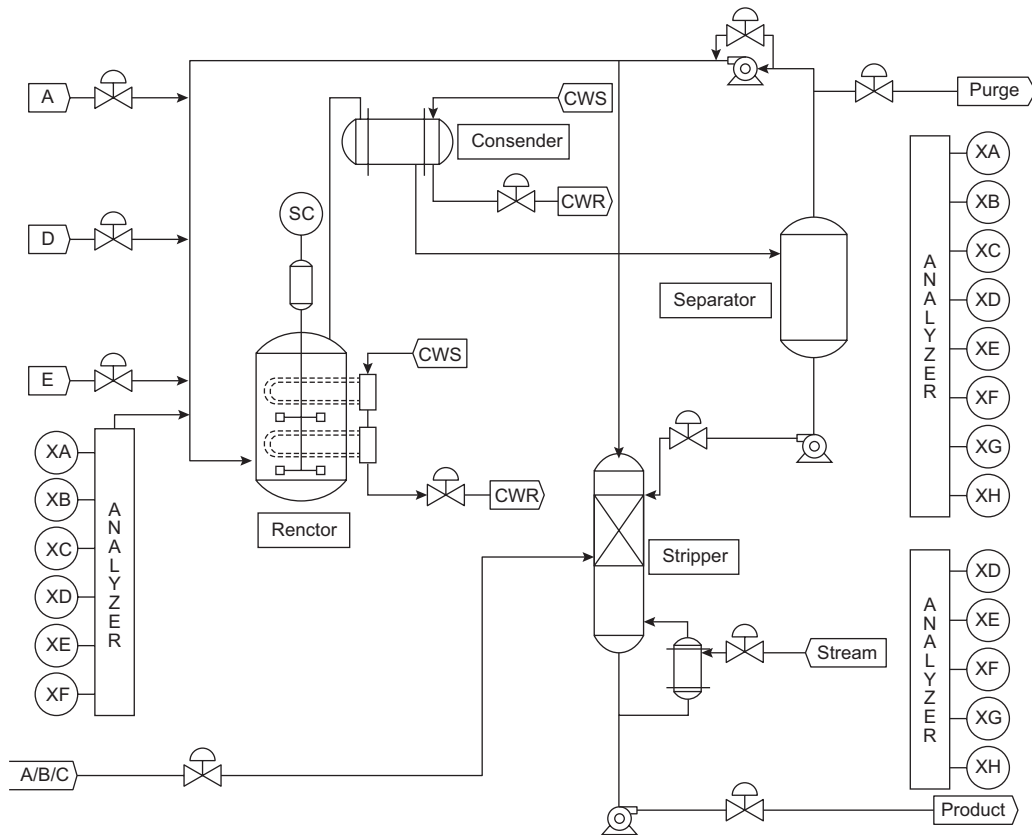


图3 TE工艺流程图

Fig. 3 Flowchart of the tennessee eastman process

表1 部分TE过程测量变量表

Table 1 Part of TE process measured variables

序号(Number)	变量(Variables)
1	A进料(流向1)/ $\text{kg}\cdot\text{h}^{-1}$
2	刺激SEP下溢(流向10)/ $\text{m}^3\cdot\text{h}^{-1}$
3	汽提塔汽流/ $\text{kg}\cdot\text{h}^{-1}$
4	反应堆冷却水出口温度/ $^{\circ}\text{C}$
5	压缩机工率/kw
6	分离器冷却水出口温度/ $^{\circ}\text{C}$
7	反应堆压力计/kPa
8	反应堆水平/%
9	反应堆温度/ $^{\circ}\text{C}$
10	循环流(流向8)/ $\text{kg}\cdot\text{h}^{-1}$

$w=0.9096$, 粒子速度的最大值 $v_{max}=0.5$, 粒子个体最优的学习因子 $c_1=0.5623$, 粒子群体最优的学习因子 $c_2=0.5619$, 算法最大迭代次数 $M=200$, 种群个体数目 $m=50$, 算法精度 $e=0.0001$ 。

调用阈值优化算法进行迭代计算, 算法共运行5次, 输出最优报警阈值上限 $t_1=120.4503$, 最优数值

优化算法参数 $q_1=0.0056$, 适应度 $G(q_1)=0.0010$ 。

(2) 报警阈值下限优化

设置PSO的参数: 粒子速度的惯性权重 $w=-0.3410$, 粒子速度的最大值 $v_{max}=0.5$, 粒子个体最优的学习因子 $c_1=0.0220$, 粒子群体最优的学习因子 $c_2=0.3805$, 算法最大迭代次数 $M=200$, 种群个

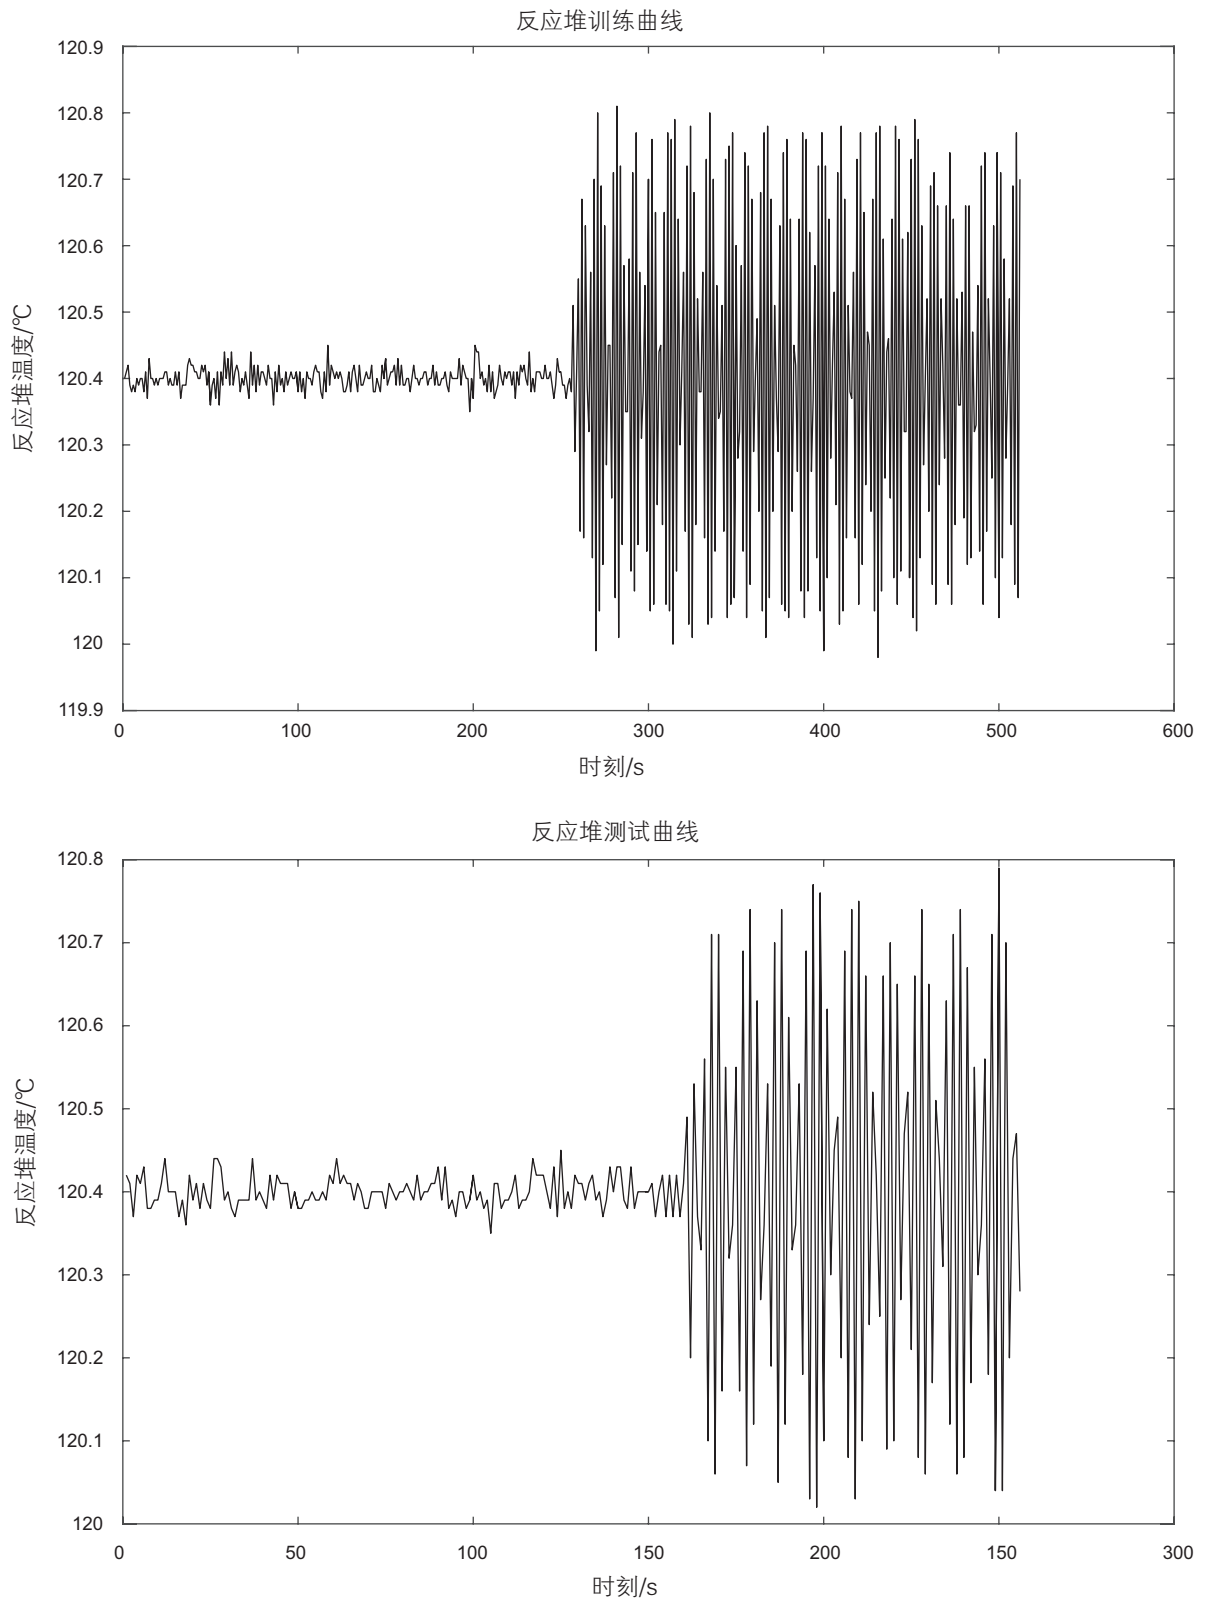


图 4 反应堆温度曲线

Fig. 4 Reactor temperature curve

体数目 $m = 50$ ，算法精度 $e = 0.0001$ 。

调用阈值优化算法进行迭代计算，算法共运行6次，输出最优报警阈值下限 $t_2 = 120.3503$ ，最优数值优化算法参数 $q_2 = 0.0101$ ，适应度 $G(q_2) = 0.0010$ 。

用最优的报警阈值 $[120.3503, 120.4503]$ 对反应堆温度测试数据 Z 进行监测，监测结果如图6所示

3.2.2 3σ 法

计算反应堆温度正常样本 X 均值 $\mu = 120.4004$ ，标准差 $\sigma = 3.5333e-3$ 。由 3σ 法求得报警阈值




图5 反应堆温度的概率密度曲线

Fig. 5 The probability density curve of reactor temperature

$[\mu - 3\sigma, \mu + 3\sigma] = [120.3900, 120.4112]$ ，并用该阈值对测试数据 Z 进行监测，监测结果如图7所示。

3.3 结果对比

自适应综合指标报警阈值优化方法与 3σ 法的误报警和漏报警情况对比如下：

由表2可知，与 3σ 法相比，自适应综合指标报警阈值优化方法所设阈值误报警率降低了51.95%，漏报警率仅为0.78%，接近于0，误报警和漏报警次数之和减少131次，证明该方法可以有效减少误报警次数，提高报警系统性能，减少操作人员工作压力。

4 结论

(1) 传统的化工过程参数报警阈值设置方法一般只考虑误报警，并没有同时考虑误报警和漏报警这两个问题，导致报警系统产生大量的错误报警。针对这个问题，提出自适应综合指标的报警阈值优化方法。该方法采用核密度估计方法、基于历史数据对过程报警状态进行估计，综合误报警率和漏报警率，从而建立优化报警阈值的目标函数，并创新地将数值优化算法内嵌于粒子群算法形成新的算法进行求解。

(2) 案例分析中，将新方法应用于TE过程的反应堆温度监测，分别优化报警阈值上下限，并进行阈值




图6 自适应综合指标法监测结果

Fig. 6 Monitoring results of the adaptive comprehensive-index method


图7 3 σ 法监测结果Fig. 7 Monitoring results of the 3 σ method

表2 TE过程反应堆温度监测的误报次数和漏报次数

Table 2 The number of false positives and false negatives of TE process reactor temperature monitoring

方法	误报警		漏报警		误报警和漏报警总次数
	次数	误报率/%	次数	漏报率/%	
自适应综合指标方法	0	0	2	0.78	2
3 σ 法	133	51.95	0	0	133

监测。

(3) 自适应综合指标报警阈值优化方法所求的报警阈值监测误报率为0, 漏报率为0.78%。与传统的3 σ

法相比, 此方法能够在保证低漏报率的条件下有效降低误报警率, 提高化工过程报警系统的性能, 减轻现场操作人员的工作压力, 减少人员生命财产损失。

参考文献

- [1] WIT J D. EEMUA recommendations for the design and construction of refrigerated liquefied gas storage tanks[J]. Cryogenics, 1998, 28(12):800-804.
- [2] FOONG O M, SUZIAH, ROHAYA D, et al. ALAP: Alarm prioritization system for oil refinery[J]. Proceedings of the World Congress on Engineering and Computer Science, 2009, (2):1012-1017.
- [3] CHAO C S, LIU A C. An alarm management framework for automated network fault identification[J]. Computer Communications, 2004, 27(13):1341-1353.
- [4] EBERHART R C, KENNEDY J. A new optimizer using particle swarm theory[C]. Sixth International Symposium on Micro and Human Science, 4-6 Oct. 1995, (2): 39-43.
- [5] JIANG R. Optimization of alarm threshold and sequential inspection scheme[J]. Reliability Engineering and System Safety, 2010, 95:208-215.

- [6] CHEN T. On reducing false alarms in multivariate statistical process control[J]. *Chemical Engineering Research and Design*, 2010, 88(4): 430-436.
- [7] MEZACHE A, SOLTANI F.A novel threshold optimization of ML-CFAR detector in Weibull clutter using fuzzy-neural networks[J]. *Signal Processing*, 2007, 87:2100-2110.
- [8] MARTIN E B, MORRIS A J. Non-parametric confidence bounds for process performance monitoring charts[J]. *Process Control*, 1996, 6(6):349-358.

A study of adaptive composite-indicator alarm threshold optimization of chemical process parameters

LUO Jing, HU Jinqiu

School of Mechanical & Storage and Transportation Engineering, China University of Petroleum-Beijing, Beijing 102249, China

Abstract Faced with increasingly complex chemical process plants, improving the performance of chemical process alarm systems is important. The traditional chemical process parameters alarm threshold setting method generally considers only false positives, but not taking both false positives and false negatives into account, leading to a lot of false alarms in alarm systems. To solve these problems, we used the alarm threshold optimization method based on an adaptive composite indicator. We used the kernel density estimation method to estimate the state of the process alarm based on historical data, integrating the false positives rate and false negatives rate to establish an objective function for optimal alarm thresholds. The numerical optimization algorithm was embedded in a particle swarm optimization algorithm, forming a new algorithm to solve the function. In case, this method was applied to the TE process. The results showed a false positive rate of 0, and a false negative rate of 0.78%. Compared with the traditional 3σ method, this method can effectively reduce the rate of false positives with a low false negative rate, and improve the performance of the chemical process alarm system. This will reduce stress on site operators, as well as the risks of loss of life and property.

Keywords adaptive; composite-indicator; false positives; false negatives; kernel density estimation; particle swarm optimization algorithm

doi: 10.3969/j.issn.2096-1693.2016.03.036

(编辑 付娟娟)