

过程控制时间序列中异常值的动态检测

刘芳¹, 毛志忠^{1,2}

(1. 东北大学 信息科学与工程学院, 辽宁 沈阳 110819; 2. 东北大学 流程工业综合自动化教育部重点实验室, 辽宁 沈阳 110819)

摘要: 针对传统小波异常值检测方法的不足以及控制调节系统在调节阶段采集的震荡数据所具有的特点, 提出了适用于调节系统震荡数据异常检测的自回归模型(auto-regression, AR)与小波相结合的在线异常值检测方法. 该方法通过引入改进的鲁棒AR模型, 克服了传统小波分析方法检测控制过程数据异常值时存在的不足; 为了避免传统异常值检测方法需要事先设定检测阈值的问题, 算法引入隐马尔科夫模型(hidden Markov model, HMM)来分析小波系数, 并在线更新HMM参数, 提高了算法的检测精度. 通过实验与应用证明了本文提出的异常数据检测方法更适合震荡的控制过程数据, 具有一定的实用性.

关键词: 异常数据检测; 自回归模型; 小波; 隐马尔科夫模型; 时间序列

中图分类号: TP273 **文献标识码:** A

Dynamic outlier detection for process control time series

LIU Fang¹, MAO Zhi-zhong^{1,2}

(1. School of Information Science and Engineering, Northeastern University, Shenyang Liaoning 110819, China;

2. Key Laboratory of Integrated Automation of Process Industry, Ministry of Education, Northeastern University, Shenyang Liaoning 110819, China)

Abstract: To improve the traditional outlier-detection by using wavelet analysis method and to deal with the instability characteristic of data from regulatory control process, we propose an improved outlier-detection method. This method combines an improved robust auto-regression (AR) model with the wavelet analysis method to eliminate the deficiency of the wavelet method in outlier-detection. To avoid the requirement of a pre-selected threshold value in the traditional method, we introduce the hidden Markov model (HMM) which analyzes the wavelet coefficients and updates online the coefficient values to improve the detection precision. Experiments and applications show that this method is especially suitable to oscillatory data in control processes.

Key words: outlier detection; auto-regression; wavelet; hidden Markov model(HMM); time series

1 引言(Introduction)

控制系统中的过程数据往往包含着许多重要的信息, 因此基于过程数据的建模、预报^[1]、监测^[2]及控制策略的制定^[3-4]等方面的研究受到学者们的广泛关注, 然而由于现场环境复杂等诸多因素的影响, 使得过程数据中难免存在着一些错误数据, 这些错误数据直接影响了上述研究结果的准确性, 因此异常值的检测工作是上述基于数据研究的前提和保障.

由于控制过程数据能够反映被控对象实时信息这一特征, 因此其异常定义不能简单的等同于传统的异常定义, 所以在控制过程数据中, 异常数据应该是一些不能反映被控对象实际结构的数据.

然而由于控制系统多种多样, 其数据的特点也存在很大的差异. 本文主要针对被控对象结构不变、参数慢时变的一类调节系统所产生的过程数据进行检

测. 这类数据有其自身的特点, 例如, 控制过程中大多有震荡调节过程, 即波动性大, 较不稳定, 这些都要检测算法具有较高的动态特性. 而且过程控制中, 一般控制周期较短, 数据时间性较强, 数据量较大, 因此要求检测算法能够在线进行, 且检测过程能够在控制周期内完成. 这些要求使得检测算法面临很高的挑战.

对于异常值的检测方法的研究, 前人已经提出了很好的算法, 如V. Barnett和T. Lewis^[5]提出的最早的统计学思想的异常值检测方法. 但是, 由于工业过程控制系统中, 对于异常值定义有其独特之处, 使得仅仅从数据间的一些统计量(均值、方差、距离、密度等)对数据进行异常判断缺乏可信度. 随着科学技术的不断发展和深入, 许多新的理念和算法被引入进来, 如聚类分析^[6-7]、神经网络^[8]等. 但是聚类分析的步骤大致为, 首先对数据进行聚类处理, 从聚类

结果来看, 样本少的类被认为是异常类, 因此无法实现在线检测的要求; 神经网络算法需要干净数据离线对网络进行训练, 而且计算较为复杂, 同样无法实现在线检测、快速计算的要求; 综上所述, 传统的方法都无法满足工业中调节系统产生的时间序列的异常值在线检测的要求。

在数学上, 对于异常数据的定义用Lipschitz指数描述: 即Lipschitz指数越小(表示其函数幅值或导数发生突变的可能性越大), 数据异常的可能性也就越大^[9]。Mallat^[10]在1992年指出了Lipschitz指数与小波系数之间的关系, 并据此提出了小波变换模极大值异常检测思想, 从而给小波异常检测奠定了坚实的数学基础。小波可以对信号中的短时高频成分进行分析, 对低频缓变趋势进行估计, 这对调节系统中的非平稳信号的特征信息提取提供了有效的方法^[11]。1998年迭代小波分析方法被提出后, 使得小波分析方法可以在线进行, 且计算更简单。但是由于小波方法是一种在时间和频率之间相权衡的分析办法, 即不能保证时间和频率都有很好的分辨率。此外, 小波检测是基于异常在数学上的定义, 与过程数据的异常定义有所差别, 因此单纯采用小波来检测控制过程时间序列也不太合适。

考虑传统小波异常数据检测方法的不足以及过程控制时间序列数据的特点, 本文在小波异常数据检测基础上, 提出一种改进的鲁棒自回归模型(auto-regression, AR)与小波相结合的时间序列异常值检测方法。该方法考虑控制过程数据异常值定义的特殊性, 依据1995年Agrawal和Ragaran提出“序列异常”的概念^[12], 首先采用本文提出的加权鲁棒AR模型对待检测时间序列进行拟合; 然后利用小波对拟合残差进行小波分解; 最后, 为了避免事先设定检测阈值以及更准确的对异常数据进行检测, 采用隐马尔科夫模型(hidden Markov model, HMM)分析小波系数的差异。通过与传统小波检测方法比较可以证明, 对于控制过程时间序列, 本文提出的方法检测更准确。对生产现场实际数据的检测结果也进一步证明了基于AR模型与小波分析的异常值检测方法的实用性。

2 传统小波检测存在的问题(The problem of conventional wavelet-based detection method)

根据Mallat的模极大值原理认为, 当信号或其导数发生突变时, 其Lipschitz指数 β 小于零, 此时某一尺度 $s(s = 1/f)$ 下的小波系数与Lipschitz指数 β 的关系为^[10]

$$|W_f(s, t)| \leq |Ks^\beta|, \quad (1)$$

式中: K 为常数, $W_f(s, t)$ 表示尺度 s 下的小波分解系数。

通过式(1)可以看出当 $\beta < 0$ 且 $s \Rightarrow 0$ 时,

$|W_f(s, t)|$ 渐进衰减, 即 $|W_f(s, t)|$ 比尺度 s 衰减的快。因此 $\beta < 0$ 处小波变换值形成模极大值。传统小波检测方法即通过寻找模极大值的方式检测异常数据。

然而很多控制过程(如电弧炉炼钢过程中的起弧阶段)极不稳定, 非常容易出现信号震荡的情况, 然而震荡情况不同于异常情况, 其两者不同之处主要表现为: 震荡属于正常调节过程, 被控对象输出依然跟随输入的变化而变化; 而异常情况则不然, 被控对象本身出现意外导致输出不跟随输入的变化而变化。但由于两者表现相似(在小尺度下表现为突变), 因此采用传统的小波方法很容易将这些正常的震荡调节当成异常值检测。

3 AR-Wavelet检测算法(The detection method by AR-Wavelet)

鉴于传统小波检测方法存在的不足, 本文提出AR模型与小波分析相结合的异常值检测方法, 对这一不足进行弥补, 使得小波分析方法能够适合过程控制时间序列异常值检测。引入HMM对小波系数进行分析, 提高算法检测精度的同时, 避免传统小波方法需要事先设定检测阈值的问题。算法具体流程如图1所示。

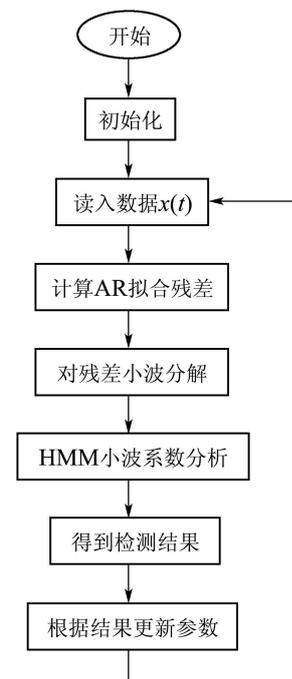


图1 检测流程图

Fig. 1 The flow of detection method

3.1 AR模型(AR model)

3.1.1 AR模型结构(The structure of AR model)

Jun-ichi Takeuchi^[13]在2006年曾采用AR模型作为时间序列异常值检测的拟合工具, 并根据AR模型拟合残差的高斯概率以及事先设定的检测阈值来决

定数据异常的情况. 由于AR模型结构简单, 且为标准的白噪声激励模型, 因此本文将系统的输入输出数据统一看作白噪声驱动的系统输出信号进行辨识.

设待检测数据 $x_t = [y_t \ u_t]^T$, $x_t \in \mathbb{R}^{d \times 1}$, $y_t \in \mathbb{R}$, $u_t \in \mathbb{R}^{(d-1) \times 1}$, $t = 1, 2, \dots$, 其中: y_t 为系统 t 时刻输出, u_t 为系统 t 时刻输入, 其AR模型为

$$x_t = \sum_{i=1}^m w_i x_{t-i} + e(t), \quad (2)$$

其中: $w_i \in \mathbb{R}^{d \times d}$ ($i = 1, 2, \dots, m$) 为AR模型系数矩阵, m 为模型阶数, $e(t)$ 为白噪声信号.

因此利用式(2)得到 t 时刻系统采样数据的估计值为 $\hat{x}_t = \sum_{i=1}^m w_i x_{t-i}$, 其中 $\hat{x}_t = [\hat{y}_t \ \hat{u}_t]^T$ 为 x_t 的拟合值.

从式(2)可知, t 时刻的系统采样值与 t 时刻之前的系统采样值有关, 符合过程控制系统的实际情况. 因此通过式(2)的线性结构可以近似地建立被控系统的模型.

对于控制过程而言, 被控对象在 t 时刻的输入值 u_t , 即是控制器的输出, 由计算机计算得到, 一般不会出现异常, 因此本文仅仅检测数据 $x_t = [y_t \ u_t]^T$ 中的 y_t 值是否异常. 即在随后的小波分析中, 也仅仅分析值的拟合残差.

由AR模型得到的 y_t 的拟合残差 $\varepsilon(t)$ 为

$$\varepsilon(t) = y_t - \hat{y}_t. \quad (3)$$

由式(3)可知, 如果待检测数据 y_t 为正常数据, $\varepsilon(t)$ 为白噪声信号, 如果 y_t 为异常数据, $\varepsilon(t)$ 则应为白噪声信号和异常残差之和(当被控对象受到白噪声以外的其他扰动干扰时, 所产生的数据均不能表征被控对象的实际结构, 因此这里均视为异常数据). 因此残差序列 $\varepsilon(t)$ ($t = 1, 2, \dots$) 有两种情况分别为: 白噪声或者白噪声和异常偏差之和. 由AR模型得到的残差信号 $\varepsilon(t)$ 不再有原始信号中的正常震荡调节信号. 因此也不会出现2.2节中检测不准确的情况, 从而弥补的单纯采用小波检测控制过程数据存在的不足.

3.1.2 AR模型的鲁棒训练方法(The robust training method for AR model)

由于被控对象参数慢时变的特点, 算法采用带有遗忘因子 r , $r \in (0, 1)$ 的在线更新方式训练AR模型, 以保证较好的动态特性.

值得注意的是, 在线动态更新AR模型的方式虽然提高了模型的动态特性, 但当异常值出现时, 如果利用异常值更新参数容易造成AR模型针对异常值的拟合, 这样直接影响异常值检测的准确性, 进而造

成漏检现象. 为了避免这一情况的出现, 本文提出了在目标函数中增加权重项的鲁棒训练方法, 以降低异常值对于模型参数的影响, 提高算法的鲁棒性.

具体训练方法根据最大后验的思想, 以式(4)为目标函数:

$$\begin{cases} \max \sum_{i=1}^t r^{t-i} \cdot b_t \cdot \log p(\hat{y}_i | x^{i-1}, w_i), \\ b_t = \begin{cases} 1, & y_t \text{ 为正常数据时,} \\ b_{t1}, & y_t \text{ 为异常数据时,} \end{cases} \end{cases} \quad (4)$$

其中: b_t 为权重, 在数据正常时等于1; 数据异常时取概率 b_{t1} (由式(16)计算得到), b_{t1} 表示 t 时刻数据为正常的高斯概率.

可以看出, 如果数据异常, 则 b_{t1} 会很小, 将其引入目标函数, 使得异常值对于参数更新的影响也会随之降低, 从而达到鲁棒的效果.

具体更新方法以Jun-ichi Takeuchi论文中的AR模型更新方法(SDAR算法)^[13]为基础, 在此基础上加入 b_t 权重. 即, 当无异常时, 保证算法的收敛性; 当存在异常时, 由于权重 b_t 的引入, 使得本文中的AR模型系数更新算法的准确性高于传统的SDAR算法的准确性. 计算步骤如下:

1) 初始化参数 $w_1, \dots, w_m, \lambda_j^0, \delta_j^0$; 读入待检测数据 x_1, \dots, x_m ;

2) 每读入一个检测后的数据(采用先检测后更新的方式) $x_t = [y_t \ u_t]^T$, $t = m + 1, m + 2, \dots$, 计算:

$$\begin{cases} \lambda_j^t = (1-r)\lambda_j^{t-1} + r \cdot b_t \cdot y_t x_{t-j}^T, \\ \delta_j^t = (1-r)\delta_j^{t-1} + r \cdot b_t \cdot x_{t-1} x_{t-j}^T, \\ j = 1, \dots, m, \end{cases} \quad (5)$$

其中: r 为遗忘因子, λ_j^t 为 d 维行向量, δ_j^t 为 $d \times d$ 维方阵.

3) 解方程组, 得到AR模型系数矩阵 w_i :

$$\lambda_j^t = \sum_{i=1}^m w_i \delta_{j-i}^t, \quad j = 1, \dots, m, \quad (6)$$

其中 w_i 为 d 维行向量, 当 δ_{j-i}^t 中下脚标 $j-i$ 小于零时, $\delta_{-k}^t = (\delta_k^t)^T$, $k = |j-i|$.

由于异常值检测算法在这里只检测系统输出值 y_t , 因此在求解AR模型系数时, 为了计算简单、快速, 也仅仅求出了拟合 y_t 值时需要的AR模型系数.

分析上述更新步骤可以看出, 当数据异常时(步骤2)中, 异常值会影响 λ_j^t 和 δ_j^t 值的准确性. 而本文提出的鲁棒训练方法通过引入权重 b_t (数据异常概率越大, b_t 值越小) 降低了异常值对于 λ_j^t 和 δ_j^t 值的影响. 值得注意的是, 如果 b_t 取一个固定不变的很小值, 即变成传统的加入惩罚因子的思想. 但是本文的鲁棒训练算法中, b_t 值会根据数据的异常程度取不同的

值, 带有自适应特点, 较传统的引入惩罚因子的方法更加合理, 且并不增加计算复杂度。

对于AR模型中的模型阶数 m , 被控对象一定时, 其AR模型阶数也为定值, 因此本文根据传统的模型阶数选取方法^[14]采用离线的方式确定AR模型阶数。

3.2 改进递推小波算法(The improved recursive wavelet transform method)

为了保证算法的在线应用, 本文采用Zhang Chuanli^[15]提出的能够实现在线小波分解的改进递推小波算法(improved recursive wavelet transform, IRWT)对AR模型的拟合残差进行小波分解。

定义函数

$$F_1(t) = (\alpha^3 t^3 / 3 - \alpha^4 t^4 / 6 + \alpha^5 t^5 / 15) \cdot e^{(-\sigma + i\omega_0)t} u_0(t). \quad (7)$$

令 $\Psi(t) = F_1^*(-t)$ 为母小波, 则母小波为

$$\Psi(t) = \left(-\frac{\alpha^3 t^3}{3} - \frac{\alpha^4 t^4}{6} - \frac{\alpha^5 t^5}{15}\right) e^{(\sigma + i\omega_0)t} u_0(-t), \quad (8)$$

其中: 上角标*表示共轭, $u_0(t) = \begin{cases} 0, & t < 0 \\ 1, & t \geq 0 \end{cases}$; 本文选取 $\alpha = 2\sqrt{3}\pi/3$; $\omega_0 = 2\pi$, 以保证母小波满足容许性条件。

根据式(8)的小波将拟合残差信号 $\varepsilon(t)$ 分解并离散化后为

$$W(f, kT_s) = \sqrt{fT_s} \sum_{n=1}^{\infty} \varepsilon(nT_s) \Psi^*(f(nT_s - kT_s)) = \sqrt{fT_s} \sum_{n=1}^{\infty} \varepsilon(nT_s) F_1(f(kT_s - nT_s)). \quad (9)$$

式(9)可变成卷积形式:

$$W(f, kT_s) = T_s \sqrt{f} (\varepsilon(nT_s) * F_1(fnT_s)), \quad (10)$$

其中: T_s 为采样周期; k, n 表示整数; f 为尺度 s 的倒数。

为了将式(10)的卷积形式变成乘积形式, 求其 z 变换为

$$W(z) = T_s \sqrt{f} (\varepsilon(z) \cdot F_1(z)), \quad (11)$$

其中 $F_1(Z)$ 可以表示为

$$F_1(z) = (k_1 z^{-1} + k_2 z^{-2} + k_3 z^{-3} + k_4 z^{-4} + k_5 z^{-5}) / (o_1 z^{-1} + o_2 z^{-2} + o_3 z^{-3} + o_4 z^{-4} + o_5 z^{-5} + o_6 z^{-6}), \quad (12)$$

其中各个参数取值如下:

$$c = e^{-fT_s(\sigma - i\omega_0)}, \\ k_1 = c \left[\frac{(\alpha f T_s)^3}{3} - \frac{(\alpha f T_s)^4}{6} + \frac{(\alpha f T_s)^5}{15} \right],$$

$$k_2 = c^2 \left[\frac{2(\alpha f T_s)^3}{3} - \frac{5(\alpha f T_s)^4}{3} + \frac{26(\alpha f T_s)^5}{15} \right],$$

$$k_3 = c^3 \left[-\frac{6(\alpha f T_s)^3}{3} + \frac{22(\alpha f T_s)^5}{5} \right],$$

$$k_4 = c^4 \left[\frac{2(\alpha f T_s)^3}{3} + \frac{5(\alpha f T_s)^4}{3} + \frac{26(\alpha f T_s)^5}{15} \right],$$

$$k_5 = c^5 \left[\frac{(\alpha f T_s)^3}{3} + \frac{(\alpha f T_s)^4}{6} + \frac{(\alpha f T_s)^5}{15} \right],$$

$$o_1 = -6c, o_2 = 15c^2, o_3 = -20c^3,$$

$$o_4 = 15c^4, o_5 = -6c^5, o_6 = c^6.$$

将式(12)代入式(11)可以得

$$W(z)(1 + o_1 z^{-1} + o_2 z^{-2} + o_3 z^{-3} + o_4 z^{-4} + o_5 z^{-5} + o_6 z^{-6}) = \sqrt{fT_s} \varepsilon(z) \cdot (k_1 z^{-1} + k_2 z^{-2} + k_3 z^{-3} + k_4 z^{-4} + k_5 z^{-5}). \quad (13)$$

将式(13)转换成差分形式即为IRWT算法的公式为

$$W(kT_s, f) = \sqrt{fT_s} \{k_1 \varepsilon[(k-1)T_s, f] + k_2 \varepsilon[(k-2)T_s, f] + k_3 \varepsilon[(k-3)T_s, f] + k_4 \varepsilon[(k-4)T_s, f] + k_5 \varepsilon[(k-5)T_s, f]\} - o_1 W[(k-1)T_s, f] - o_2 W[(k-2)T_s, f] - o_3 W[(k-3)T_s, f] - o_4 W[(k-4)T_s, f] - o_5 W[(k-5)T_s, f] - o_6 W[(k-6)T_s, f]. \quad (14)$$

从式(14)可知, 首先利用式(9)得到的6个小波系数, 而后就可以只根据式(14)以及前5个时刻的拟合残差信号, 前6个时刻的小波系数计算出当前的小波系数, 实现在线小波递推分解公式。

3.3 HMM分析算法(The analysis method by hidden Markov model)

传统的异常值检测方法一般都需要事先设定检测阈值, 即当检测指标高于检测阈值时认为异常。但在实际应用中, 检测阈值需要根据实际计算的检测指标取值范围而定。如果事先设定的检测阈值不准确, 将会严重影响检测的准确性。据此本文引入HMM分析小波系数, 避免设定检测阈值的同时一定程度的提高了检测的准确性。

HMM是一个一阶的双重随机过程, 主要由两部分组成^[16]: 一是马尔可夫链, 它描述了各个状态之间的转移情况, 由初始状态概率 a_0 和状态转移矩阵 $A = (a_{ij})_{N \times N}$ 组成, 其中: $a_{ij} = P(s_t = j | s_{t-1} = i)$, $i, j \in S$, 式中: S 表示所有状态组成的集合, s_t 表示 t 时刻状态; N 表示模型的状态总个数;

这里初始状态转移概率 a_0 实际为状态转移矩阵 A 的初始值, 需要事先设定(这里取0.5), 随着HMM在线的不断更新, a_0 的取值对数据检测准确性的影

响将会不断减小直至消失. 而状态转移矩阵 A 中的各个元素采用在线的更新方式:

$$\begin{aligned} a_{01} &= \frac{n(a_{01})}{n(a_{01}) + n(a_{00})}, a_{00} = 1 - a_{01}, \\ a_{11} &= \frac{n(a_{11})}{n(a_{11}) + n(a_{10})}, a_{10} = 1 - a_{11}. \end{aligned} \quad (15)$$

其中: a_{01} 的下脚标“1”表示数据正常;“0”表示数据异常,即 $S = \{0, 1\}$;因此 a_{01} 表示前一时刻数据异常,而后一时刻数据正常的概率,而 $n(a_{01})$ 表示这种情况出现的次数. 由于 A 在线更新,因此在更新 t 时刻 A 时,只统计 t 时刻之前这种情况出现的次数. A 的不断更新也使其能够更准确的反映被检测时间序列异常值分布的情况.

HMM的另一随机过程描述了观测值和状态情况之间的关系,由观测值概率矩阵 $P = (p_{tk})_{1 \times 2}$, $k = 0, 1$ 描述,表示在某一状态 s_t 下,观测值取某一数值的概率.

本文所提算法中,观测值概率矩阵 P 中的 p_{t1} 表示 t 时刻小波系数 $W(t, f)$ 与正常数据($k = 1$)小波系数平均值 W_a 之间的相似度;即

$$\begin{aligned} p_{t1} &= P(W_a, W(t, f) | s_t = 1) = \\ &N(W(t, f) | W_a, W_v) = \\ &\exp\left(-\frac{1}{2}(W(t, f) - W_a)^T W_v^{-1}(W(t, f) - W_a)\right), \end{aligned} \quad (16)$$

其中: $N(\cdot)$ 表示高斯分布函数,由于小波分析的时间序列正常时残差信号为白噪声,因此 W_a 取白噪声均值0.

为了求取HMM的最优状态序列 s_t , $t = 1, 2, \dots$,即数据的检测结果,本文采用文献[17]给出Viterbi算法的实时计算办法:

$$\begin{aligned} \phi_t(1) &= a_{i1} \cdot p_{t1}, \\ \phi_t(0) &= a_{i0} \cdot p_{t0} = a_{i0} \cdot (1 - p_{t1}), \end{aligned} \quad (17)$$

其中: $\phi_t(1), \phi_t(0)$ 分别为 $s_t = 1$ (数据正常)和 $s_t = 0$ (异常数据)的判断指标. a_{i1} 表示前一时刻状态为 i ,当前状态为1的状态转移概率.

可以看出,只需在每一时刻比较 $\phi_t(1), \phi_t(0)$ 的大小即可判断当前时刻的HMM的状态链值(即数据的异常情况):

$$\begin{aligned} \phi_t(1) &\geq \phi_t(0), s_t = 1, \\ \phi_t(1) &< \phi_t(0), s_t = 0. \end{aligned} \quad (18)$$

从判断指标 $\phi_t(1), \phi_t(0)$ 的计算式(17)可以看出:在起始阶段,若状态转移矩阵 A 较不准确时,可以用观测值概率 b_{t1} 进行制衡;而随着检测的进行, A 的不断更新,逐渐准确时,又能够对观测值概率 b_{t1} 的准确性进行制衡. 两者的相互作用提高了检测的准确性.

4 实验与应用(Experimentation and application)

4.1 实验比较(Experimentation and comparison)

为了验证算法的检测性能,这里分别利用两个模型生成两组数据作为检测目标:

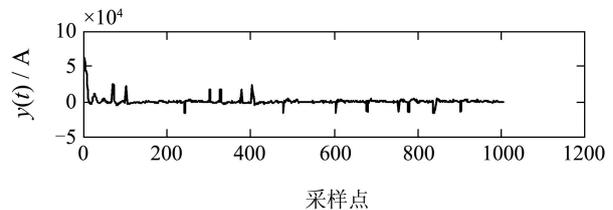
1) 第1组数据代表实际的闭环过程控制系统中的过程数据;通过针对第1组数据的仿真实验说明本文提出的异常数据检测方法较传统的Wavelet方法更适合闭环过程控制系统中的过程数据的异常检测.

2) 在第1组闭环控制系统仿真的基础上,为了突出本文提出的方法较传统Wavelet方法更适合数据波动性大且系统参数慢时变等特点的过程数据,第2组数据采用波动性更大的开环系统模型进行仿真,从另一个角度说明了本文提出的检测算法同样适用于开环系统的异常数据检测任务.

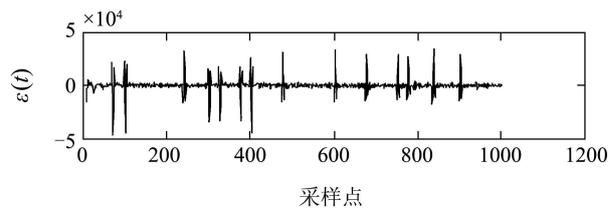
两组数据均与Jun-ichi Takeuchi^[13]提出的AR模型检测方法作比较. 以证明该方法的更适合控制过程的异常检测.

1) 第1组数据.

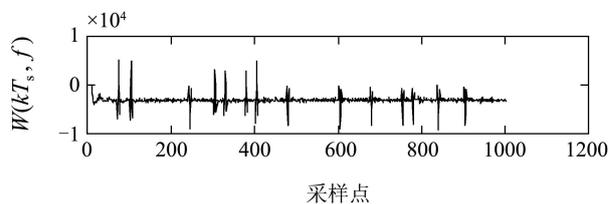
选取钢铁企业中电弧炉炼钢过程为应用背景,利用电弧炉三相交流电极调节系统的机理模型(其中电弧放大系数时变)产生一组电极调节系统的输出信号(电流信号),并在其中加入10%白噪声和14个异常点以模拟工况噪声和实际冶炼过程中的塌料、断弧等异常现象;待检测信号以及检测结果如图2所示.



(a) 待检测数据点



(b) 拟合残差



(c) $f = 80$ 下的小波分解系数

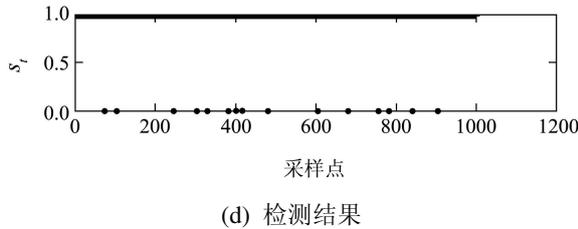


图 2 电极调节系统信号及检测结果
Fig. 2 The signal of electrode and detection results

传统小波分析方法在大尺度下容易将正常的震荡调节信号误检为异常信号,而在小尺度下又难于确定准确的异常位置.而图2中由于采用本文提出的方法首先对待检测信号进行拟合处理(由于机理模型模拟慢时变过程,因此拟合过程遗忘因子取值较小为 $r = 0.002$),即可以避免上述问题的发生,然后再在高频下($f = 80$)进行小波分解并准确定位异常值的位置.图2(d)为采用HMM模型分析小波系数后确定的最终检测结果,其中:“1”表示数据正常;“0”表示数据异常.从图2(d)中可以看出本文提出的检测算法准确的检测出所有异常值,没有漏检和误检现象.

为了说明本文提出的方法的优越性,这里与Jun-ichi Takeuchi^[13]提出的AR模型检测方法作比较.采用AR模型检测方法对第1组数据检测得到的结果如图3所示.

图3中,纵坐标表示数据通过AR模型拟合后得到残差的高斯概率负对数,即负对数值越高,说明数据异常的可能性越大.从图3中可以看出,AR模型方法同样将开始阶段的震荡过程信号误检测成异常值.且第2个异常点(椭圆标记)几乎检测不出.说明了对于控制过程数据,AR模型检测效果较本文提出的检测效果要差.

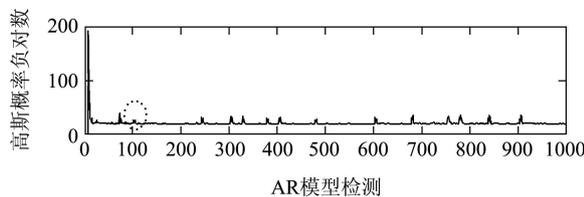


图 3 AR模型检测结果
Fig. 3 The detection results by AR model

2) 第2组数据.

在第1组数据的基础上,采用第2组开环系统的过程数据来说明,本文提出的异常数据检测算法同样适用于开环系统.在Alex Alexandridis^[18]文中提到的开环模型的基础上进行修改,得到第2组数据.修改后的模型如下:

$$y(k) = \{y(k-1)y(k-2)y(k-3) \cdot u(k-2)(y(k-3)-1) +$$

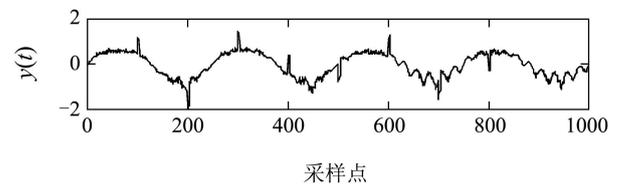
$$u(k-1)\} / \{1 + 0.2 \sin(2\pi k/25) + y(k-2)^2 + y(k-3)^2\}, \quad (19)$$

其中

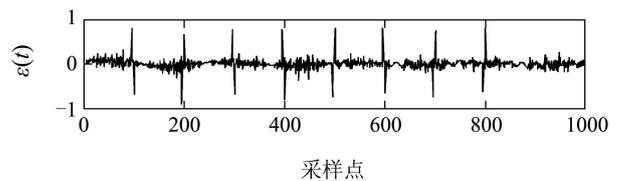
$$u(k) = \begin{cases} \sin \frac{2\pi k}{250}, & k \leq 500, \\ 0.8 \sin \frac{2\pi k}{250} + 0.2 \sin \frac{2\pi k}{25}, & k > 500. \end{cases} \quad (20)$$

从式(19)可以看出,分母有时变参数项 $0.2 \sin(2\pi k/25)$.为了验证算法的鲁棒性,在其中加入10%的白噪声和8个异常点.其数据及检测结果如图4所示.

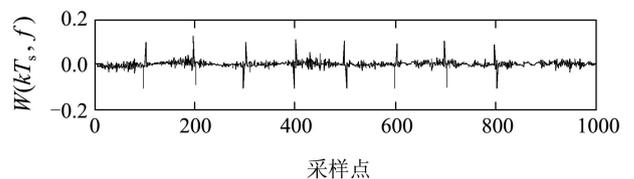
从图4(a)的待检测信号可以看出,其波动性较大,且具有时变特性.从图4(b)可以看出由于信号(图4(a)所示)经过AR模型拟合处理(拟合过程遗忘因子取值为 $r = 0.02$),因此信号的残差几乎为白噪声信号或者为白噪声信号与异常信号叠加的信号.经过小波分析(图4(c)所示)以及HMM最终的寻优过程得到最终的检测结果(图4(d)):所有异常值全部准确检出,没有误检和漏检现象.



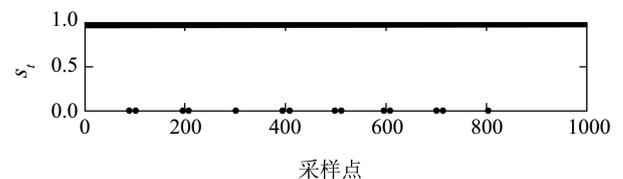
(a) 待检测数据点



(b) 拟合残差



(c) $f = 80$ 下的小波分解系数



(d) 检测结果

图 4 Alex模型信号及检测结果

Fig. 4 The signal from Alex's model and the detection results

图5为第2组数据没有经过AR模型拟合处理而直接采用小波分析方法得到的小波分解系数. 图5(b)为小尺度($f = 20$)下的小波分解系数, 可以看出异常点周围存在很多的波动, 即难以准确定位异常值位置; 而图5(c)适当增大了尺度值($f = 40$), 可以看出图中出现了与原始信号类似的波动, 因此难于再确定异常值的位置. 图5(d)为采用与图4中小波分解相同的尺度($f = 80$)下的小波分解系数, 对比图5(d)与图4(c)可以看出两者在相同尺度下分解的不同.

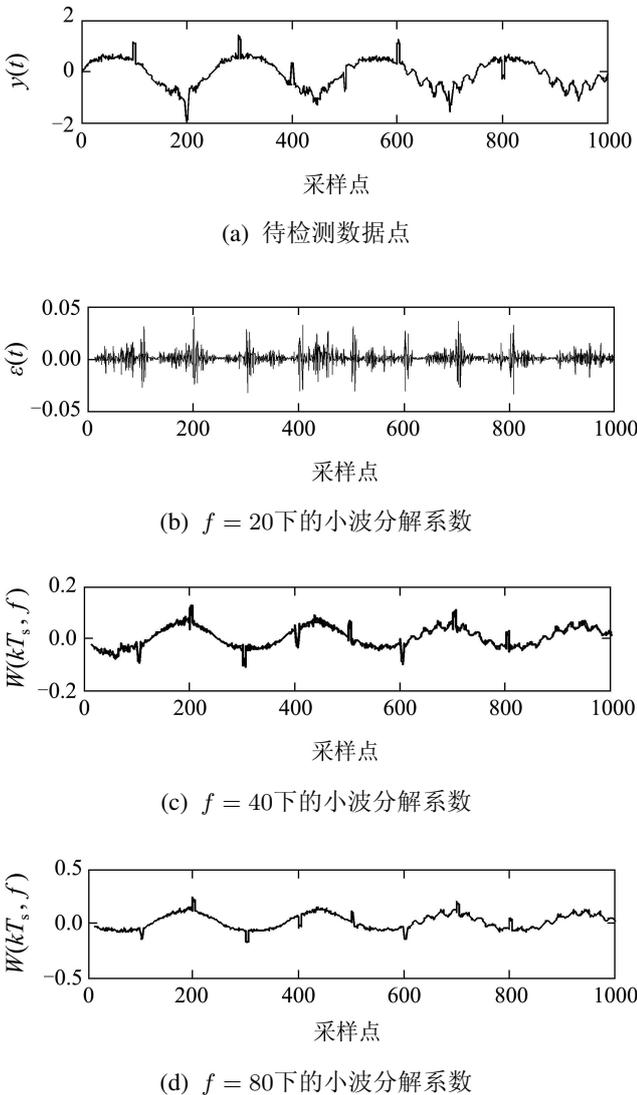


图5 Alex模型信号及传统小波分析结果

Fig. 5 The signal from Alex's model and the analysis results based on traditional wavelet

图6为采用Jun-ichi Takeuchi^[13]提出的AR模型检测方法对第2组数据进行检测的结果, 从图中可以看出, 在异常点周围有许多误检点, 而且Jun-ichi Takeuchi的检测方法, 需要实现设定检测阈值, 而对于未知的数据而言, 很难事先设定准确的检测阈值. 从而也说明了其没有本文提出的方法方便可行.

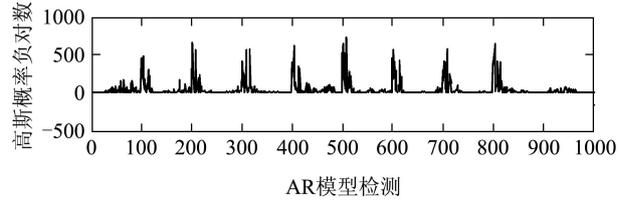


图6 AR模型检测结果

Fig. 6 The detection results by AR model

为验证算法的计算量和复杂度能否满足在线检测的要求, 参照实际工况(上钢五厂冶炼车间) 控制系统设备参数搭建检测平台. 平台主要硬件参数如表1所示.

表1 平台参数

Table 1 The parameters of platform

硬件名称	具体参数
CPU	Core 2, 1.86GHz
存储器	1G
磁盘	160G

在检测平台下, 对上述两组数据各进行10次检验, 所得结果如表2所示.

表2 检测结果

Table 2 The detection results

数据	个数/个	最高用时/s	平均用时/ ($\text{ms} \cdot \text{个}^{-1}$)	采样周期/ms
第1组	1000	4.59	4.15	50
第2组	1000	4.87	4.37	50

表2中可以看出, 两组数据在检测时, 单个数据平均检测用时均远小于采样周期, 基本满足工业在线检测的要求.

基于以上验证分析, 本文提出的结合AR模型与小波分析的时间序列异常值检测方法能够弥补传统小波分析方法的不足, 较单纯小波分析方法以及传统AR模型检测方法更加于适合过程控制这种波动数据的异常值检测任务, 算法的实际检测性能和实时性能能够满足工业实际的要求.

4.2 应用(Application)

为了进一步验证该算法的实用性, 本文以上海宝钢30吨电弧炉电极调节系统2008年4月的一炉钢所产生的部分数据(1000组)作为验证数据, 并在其中加入10个幅值较小的异常点. 检测结果如图7所示(由于实际过程为慢时变过程, 因此拟合过程遗忘因子取值较小为 $r = 0.001$):

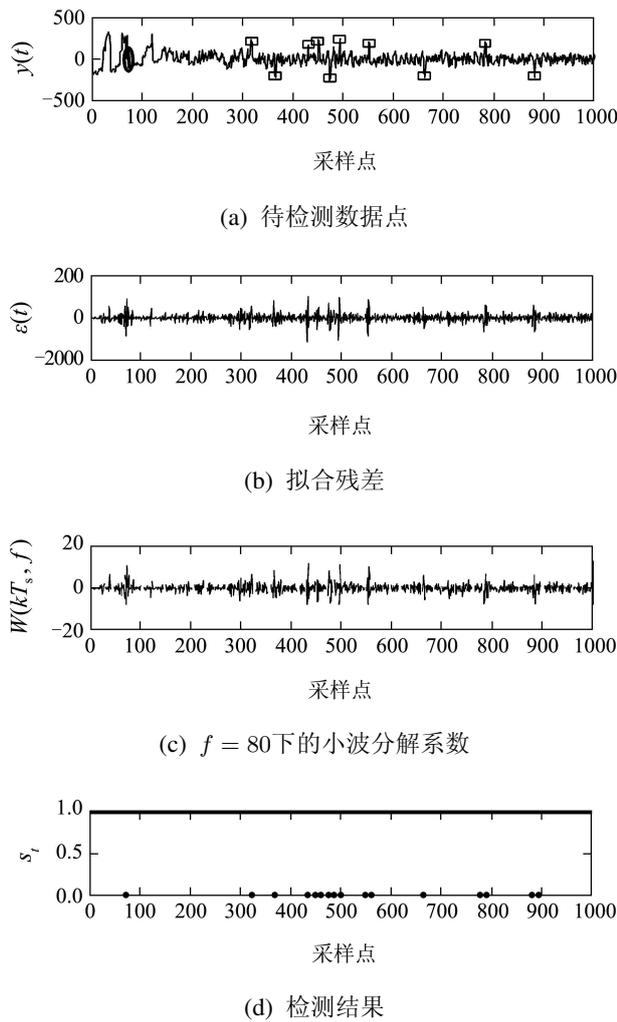


图7 真实数据及检测结果

Fig. 7 The real signal and detection results

鉴于10个异常点幅值较小,因此在图7(a)中用黑色方框标记其位置.从图7(a)可以看出,实际采集的数据中同样有一段震荡调节过程(1~100步左右),而且较模型生成的信号噪声要大很多,但是从检测结果来看,所有10个异常点均被准确检测出,没有漏检.

表3 待检测数据

Table 3 The data waiting for detecting

序号	数据值	序号	数据值	序号	数据值
51	-64.6788	61	313.4494	71	75.6488
52	-73.1093	62	275.5426	72	-104.4900
53	-70.6764	63	277.3945	73	137.5450
54	-46.4575	64	234.8348	74	-0.0526
55	-9.5037	65	199.2413	75	-91.7447
56	49.3292	66	226.5152	76	-89.7186
57	69.1959	67	279.1071	77	-101.9224
58	97.4359	68	230.0441	78	-81.3203
59	109.6340	69	7.8289	79	-76.3869
60	206.1242	70	289.1346	80	-76.8439

值得注意的是,从拟合残差图像(图7(b))或者小波分析图像(图7(c))都能发现在开始的震荡调节阶段有一处偏差很大,算法检测此处为异常(图7(a)中用黑色椭圆标出),而此处并非人为加入的异常点.为了分析其原因,这里列出部分数据来分析此处异常原因,如表3所示.从表3中可以看出,正常数据51~68步都是相对连续的变化,而在69~74步处出现剧烈波动,分析此处数据波动剧烈,上下起伏范围过大,应为异常情况,因此算法将此处检测为异常属于正确检测.这也证明了本文提出的算法对于波动数据(相对于后面的平稳数据)异常检测的有效性.

同样在4.1小节中的检测平台上对实际数据进行检测时间分析得到数据如表4所示.

表4 检测结果

Table 4 The detection results

数据	个数/个	最高用时/s	平均用时/(ms·个 ⁻¹)	采样周期/ms
实际数据	1000	4.81	4.39	50

分析表4,平均检测时间依然远远小于采样周期,说明算法能够满足工业在线应用的要求.

5 结论(Conclusion)

本文针对传统小波检测震荡的控制过程时间序列时存在的不足,提出了一种AR模型和小波相结合动态检测算法.该方法首先本文提出的鲁棒AR模型对数据进行线性拟合,有效弥补了直接用小波分析信号容易造成误检的不足,而后对拟合残差进行一定尺度下的小波分解,最后利用HMM描述小波系数与数据异常情况的关系,并利用Viterbi算法确定最终的检测结果,从而避免了检测阈值的设定,保证了该检测算法的准确性和鲁棒性.通过实验和应用验证,该方法在动态控制过程时间序列异常值检测方面较传统小波检测方法具有更好的检测准确度,精度和鲁棒性,同时完全能够满足工业在线检测的需要,具有很好的的实用价值.

参考文献(References):

- [1] SAMANTARAY D, MANDAL S, BHADURI A K. Constitutive analysis to predict high-temperature flow stress in modified 9Cr-1Mo(P91) steel[J]. *Materials and Design*, 2010, 32(2): 981 - 984.
- [2] SMITH B, KNORR W, WIDLowski J L. Combining remote sensing data with process modeling to monitor boreal conifer forest carbon balances[J]. *Forest Ecology and Management*, 2008, 255(12): 3985 - 3994.
- [3] ZHANG H, ALBIN S L, WAGNER S R. Determining statistical process control baseline periods in long historical data streams[J]. *Journal of Quality Technology*, 2010, 42(1): 21 - 35.

- [4] MILLER G B, PANKOV A R. Determining statistical process control baseline periods in long historical data streams[J]. *Automation and Remote Control*, 2007, 68(11): 2042 – 2055.
- [5] BARNET V, LEWIS T. *Outlier in Statistical Data*[M]. Chichester: John Wiley and Sons, 1994.
- [6] WANG J S, CHIANG J C. A cluster validity measure with Outlier detection for support vector clustering[J]. *IEEE Transactions on Systems Man and Cybernetics, Part B—Cybernetics*, 2008, 38(1): 78 – 89.
- [7] ALMEIDA J A S, BARBOSA L M S, PAIS A A C C. Improving hierarchical cluster analysis: a new method with outlier detection and automatic clustering[J]. *Chemometrics and Intelligent Laboratory Systems*, 2007, 87(2): 208 – 217.
- [8] PRAKOBPHOL K, ZHAN J T. A novel outlier detection scheme for network intrusion detection systems[C] // *Proceedings of the 2nd International Conference on Information Security and Assurance*. Busan, Southkorea: IEEE Computer Society, 2008: 555 – 560.
- [9] PITTNER S, KAMARTHI S V. Feature extraction from wavelet coefficients for pattern recognition tasks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1999, 21(1): 83 – 88.
- [10] STEPHANE M, WEN L H. Singularity detection and processing with wavelets[J]. *IEEE Transactions on Information Theory*, 1992, 38(2): 617 – 642.
- [11] RADU R, VALERIE L D, CHRISTIAN H, et al. Iterative wavelet-based denoising methods and robust outlier detection[J]. *IEEE Signal Processing Letters*, 2005, 12(8): 557 – 560.
- [12] JIAWEI H, MICHELINE K. 数据挖掘概念与技术[M]. 北京: 机械工业出版社, 2001.
- (JIAWEI H, MICHELINE K. *Data Mining Concepts and Techniques*[M]. Beijing: Mechanical Industry Press, 2001.)
- [13] JUN-ICHI T, KENJI Y. A unifying framework for detecting outliers and change points from time series[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2006, 18(4): 482 – 492.
- [14] PETRE S, RINGVE S. Model-order selection: a review of information criterion rules[J]. *IEEE Signal Processing Magazine*, 2004, 21(4): 36 – 47.
- [15] ZHANG C L, HUANG Y Z, MA X X, et al. A new approach to detect transformer inrush current by applying wavelet transform[C] // *Proceedings of International Conference on Power System Thchnology*. New York: IEEE, 1998: 1040 – 1044.
- [16] JEFF A, BILMES. What HMMs can do[J]. *IEICE—Transactions on Information and Systems*, 2006, E89-D(3): 869 – 891.
- [17] LOU H L. Implementing the viterbi algorithm—fundamentals and real-time issues for processor designers[J]. *IEEE Signal Processing Magazine*, 1995, 12(5): 42 – 52.
- [18] ALEX A, HARALAMBOS S, GEORGE B. A new algorithm for on-line structure and parameter adaptation of RBF networks[J]. *Neural Networks*, 2003, 16(7): 1003 – 1017.

作者简介:

刘芳 (1983—), 女, 博士研究生, 主要研究方向为工业控制过程异常数据检测, E-mail: liufang19830311@163.com;

毛志忠 (1961—), 男, 教授, 博士生导师, 东北大学信息学院自动化所副所长, 主要研究方向为复杂工业系统建模、控制与优化, E-mail: maozhizhong@ise.neu.edu.cn.