

应用阶数自学习自回归隐马尔可夫模型 对控制过程异常数据的在线检测

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 110004;

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 110004)

摘要: 针对过程工业中强噪声环境下实时采集的控制过程海量数据难以在线精确检测的问题, 提出了基于阶数自学习自回归隐马尔可夫模型(ARHMM)的工业控制过程异常数据在线检测方法. 该算法采用自回归(AR)模型对时间序列进行拟合, 利用隐马尔可夫模型(HMM)作为数据检测的工具, 避免了传统检测方法中需要预先设定检测阈值的问题, 并将传统的BDT(Brockwell-Dahlhaus-Trindade)算法改进成为对于时间和阶数均实施迭代的双重迭代结构, 以实现ARHMM参数在线更新. 为了减小异常数据对ARHMM参数更新的影响, 本文采用先检测后更新的方式, 根据检测结果采取不同的更新方法, 提高了该算法的鲁棒性. 模型数据仿真与应用试验结果证明, 该算法具有较高的检测精度和抗干扰能力, 同时具备在线检测的能力. 通过与传统基于AR模型的异常数据检测方法比较, 证明了该方法更适合作为过程工业控制过程数据的异常检测工具.

关键词: 自回归隐马尔可夫模型; BDT; 异常数据检测; 在线检测

中图分类号: TP273 **文献标识码:** A

On-line detection of outliers in control process data based on autoregressive hidden Markov model with order self-learning

LIU Fang¹, MAO Zhi-zhong^{1,2}

(1. School of Information Science and Engineering, Northeastern University, Shenyang Liaoning 110004, China;

2. Key Laboratory of Integrated Automation of Process Industry, Ministry of Education, Northeastern University, Shenyang Liaoning 110004, China)

Abstract: For the accurate online detection and collection of massive real-time data of a control process in strong noise environment, we propose an autoregressive hidden Markov model (ARHMM) algorithm with order self-learning. This algorithm employs an AR model to fit the time series and makes use of the hidden Markov model as the basic detection tool for avoiding the deficiency in presetting the threshold in traditional detection methods. In order to update the parameters of ARHMM online, we adopt the improved traditional BDT(Brockwell-Dahlhaus-Trindade) algorithm with double iterative structures, in which the iterative calculations are performed respectively for both time and order. To reduce the influence of outlier on parameter updating in ARHMM, we adopt the strategy of detection-before-update, and select the method for updating based on the detection results. This strategy improves the robustness of the algorithm. Simulation with emulation data and practical application verify the accuracy, the robustness and the property of online detection of this algorithm. Comparison between the traditional AR-model-based algorithm and the proposed algorithm shows the superiority of the proposed algorithm in outlier detection in industrial control processes.

Key words: ARHMM model; BDT; outlier detection; online detection

1 引言(Introduction)

工业过程控制系统由于被控对象结构复杂、参数时变, 很多数据难于直接测得等原因, 基于过程数据的软测量^[1]、参数辨识^[2]、系统建模^[3]以及控制决策^[4]等相关技术研究得到广泛关注, 但由于实际控制过程受随机干扰、环境噪声、传感器故障等因素的影响, 使得现场采集的数据中存在许多不能反映

被控对象实际结构的异常数据, 从而导致上述基于过程数据的相关技术方法难以直接应用, 因此, 对这些异常数据的检测和剔除是保证上述研究实际应用的前提和关键.

对于异常数据检测方法的研究, 前人提出了许多好的想法和建议, 如Barnett和Lewis在他们的著作《Outlier in Statistical Data》中提出了基于统计的

异常数据检测方法^[5]; Knorr和Ng提出了基于距离的异常数据检测方法^[6,7]; Rastogi和Ramaswamy提出一种新的基于距离的方法——密度检测方法^[8]. 然而, 由于工业控制过程异常数据的特殊性, 使得仅仅从数据间的距离、密度或者均值、方差等统计量对数据进行异常判断缺乏可信度. 随着异常数据检测技术研究的不断深入, 许多新的思想和方法被引入进来, 如聚类分析^[9,10]、神经网络^[11,12]等, 但是聚类分析的思想为以样本少的类为异常类, 需要将所有数据归类后才能做出异常判断, 而神经网络算法则需要干净数据离线训练网络, 所以这两种方法都无法满足工业异常数据在线检测的要求. 1995年 Argrawal 和 Ragaran 提出“序列异常”的概念^[13], 并据此提出基于偏差的检测方法^[14,15], 该方法的思想是: 首先利用数据通过鲁棒的方法建立回归模型, 然后依据模型产生的数据预测值与实际值之间的偏差判断数据的异常情况. 自回归(auto regression)方法因其较神经网络等其他模型相比具有更简单结构、更明确物理意义, 且由于其计算量少而更适合用于时间序列的在线分析. 考虑以上优点, 因此自回归模型被广泛应用于各个领域, 然而该方法需要事先了解回归模型的阶数, 而工业控制系统中的被控对象大都模型复杂、阶数未知, 因此直接利用该方法检测控制工业异常数据存在一定的困难.

针对工业异常数据的特殊性和被控对象模型未知且需要在线检测的局限性, 本文提出基于阶数自学习ARHMM异常数据检测算法, 该算法与传统异常数据检测算法相比具有以下几点创新:

1) 针对传统异常数据检测方法(AR模型检测方法)中检测阈值需要事先确定的问题, 提出无须设定检测阈值的ARHMM检测算法, 该算法具有双重保障的检测结构: 首先利用AR模型拟合值与实际值的残差概率作为初步检测结果, 并作为HMM结构的观测链值; 其次通过求取HMM最优状态链的Viterbi算法得到最终的检测结果.

2) 考虑控制过程阶数未知, 并难于在线确定的问题提出双重迭代结构的在线确定模型阶数的方法, 该算法将从阶数角度迭代计算AR模型系数的BDT算法改进成为以阶数迭代为内环, 时间迭代为外环的双重迭代结构, 并在每次内环迭代结束时利用KICvc(kullback information criterion vector correction)准则在线确定最优模型阶数, 在检测异常数据的同时得到被控对象最优的模型阶数, 以及最优模型阶数下的模型系数.

3) 为了避免异常数据对于参数更新的影响, 提高算法的鲁棒性, 阶数自学习ARHMM算法采用先检测后更新, 根据检测结果采用不同更新办法的思

想, 有效抑制了异常数据对于参数更新的影响, 保证了异常数据检测的准确性.

试验与应用表明, 改进后的ARHMM算法能准确的确定最优的模型阶数, 且具有很好的在线检测精度.

2 阶数自学习ARHMM异常数据检测(Order self-learning ARHMM outlier detection method)

改进的阶数自学习ARHMM算法, 主要针对工业控制过程数据检测的特点, 利用BDT-KICvc算法解决ARHMM中AR模型阶数无法在线求解的问题. 为了适应工业控制过程数据的数据量大、实时性强等特点, 改进后的BDT-KICvc算法以模型阶数迭代为内环, 以时间序列迭代为外环, 构成双重迭代结构, 并利用适合有限数据样本下的AR模型阶数确定准则——KICvc准则——确定最优的AR模型阶数, 实现了在线确定阶数, 在线更新ARHMM参数的目的, 保证了异常数据检测的准确性.

2.1 BDT双重迭代结构(Structure of double iteration in BDT)

2.1.1 传统BDT算法(Traditional BDT algorithm)

传统的BDT算法是 Brockwell^[16]在 Levinson-Durbin算法基础上改进得到的, 该算法用全部数据做统计量, 从阶数角度进行迭代以确定前向以及逆向的AR模型系数.

假设待检测时间序列为 $x_t(t = 1, 2, \dots)$, 其中 x_t 为 $m \times 1$ 维列向量, 前向AR模型可以表示为

$$x_t = \sum_{i=1}^k a_k(i)x_{t-i} + \varepsilon_k(t), \quad (1)$$

式中: $\varepsilon_k(t)$ 表示 k 阶模型下的前向残差, 服从均值为零的高斯分布; $a_k(i)$ 表示 k 阶模型下的前向AR模型系数. 由于BDT算法从阶数角度迭代, 因此文中用下脚标 k 强调当前迭代的模型阶数.

类似于式(1), 可以得到逆向AR模型为

$$x_t = \sum_{j=1}^k b_k(j)x_{t+j} + \eta_k(t), \quad (2)$$

式中: $\eta_k(t)$ 表示 k 阶模型下的逆向残差; $b_k(j)$ 表示 k 阶模型下的逆向AR模型系数.

据此以所有数据的前向、逆向残差和最小作为目标函数, 其广义目标函数为^[17]:

$$\min \sum_{t=k+1}^n [\hat{\varepsilon}_k(t)^T \omega_1 \hat{\varepsilon}_k(t) + \hat{\eta}_k(t-k)^T \omega_2 \hat{\eta}_k(t-k)], \quad (3)$$

式中: n 表示数据总个数; ω_1, ω_2 分别表示前向、逆向的加权系数矩阵, ω_1, ω_2 取不同值分别形成Burg算法、Vieira-Morf算法以及Nuttall-Strand算法, 在BDT

算法中 ω_1, ω_2 均取1; $\hat{\varepsilon}_k(t)$ 表示 t 时刻, k 阶数模型下的前向估计残差; $\hat{\eta}_k(t-k)$ 表示 $t-k$ 时刻, k 阶数模型下的逆向估计残差:

$$\hat{\varepsilon}_k(t) = x_t - \sum_{i=1}^k a_k(i)x_{t-i}, \quad (4)$$

$$\hat{\eta}_k(t-k) = x_{t-k} - \sum_{j=1}^k b_k(j)x_{t-k+j}, \quad (5)$$

其中: $a_k(i)(i = 1, 2, \dots, k), b_k(j)(j = 1, 2, \dots, k)$ 均为 $m \times m$ 维方阵.

传统BDT算法具体形式如下^[17]:

$$a_k(k) = \left(\frac{1}{n} \sum_{t=1}^{n+k} \hat{\varepsilon}_{k-1}(t)\hat{\eta}_{k-1}(t-k)^T\right)\hat{V}_{k-1}^{-1}, \quad (6)$$

$$a_k(i) = a_{k-1}(i) - a_k(k)b_{k-1}(k-i), \quad (7)$$

$$i = 1, \dots, k-1,$$

$$b_k(k) = \hat{V}_{k-1}a_k(k)^T\hat{U}_{k-1}^{-1}, \quad (8)$$

$$b_k(j) = b_{k-1}(j) - b_k(k)a_{k-1}(k-j), \quad (9)$$

$$j = 1, \dots, k-1,$$

$$\hat{U}_k = \hat{U}_{k-1} - a_k(k)\hat{V}_{k-1}a_k(k)^T, \quad (10)$$

$$\hat{V}_k = \hat{V}_{k-1} - b_k(k)\hat{U}_{k-1}b_k(k)^T, \quad (11)$$

$$\hat{\varepsilon}_k(t) = \hat{\varepsilon}_{k-1}(t) - a_k(k)\hat{\eta}_{k-1}(t-k), \quad (12)$$

$$\hat{\eta}_k(t) = \hat{\eta}_{k-1}(t) - b_k(k)\hat{\varepsilon}_{k-1}(t+k), \quad (13)$$

其中 \hat{U}_k, \hat{V}_k , 分别表示 k 阶下的前向、逆向白噪声估计方差.

传统BDT算法的初始条件为:

$$\hat{\varepsilon}_\emptyset(t) = \hat{\eta}_\emptyset(t) = \begin{cases} x_t, & t \in \{1, 2, \dots, n\}, \\ 0, & \text{其他}, \end{cases} \quad (14)$$

$$\hat{U}_\emptyset = \hat{\Gamma}(0) = \hat{V}_\emptyset, \quad (15)$$

其中: 下脚标 \emptyset 表示初始迭代时, 阶数集合为空; $\hat{\Gamma}(0)$ 表示待检测数据的协方差矩阵

$$\hat{\Gamma}(0) = \frac{1}{n} \sum_{t=1}^n x_t x_t^T. \quad (16)$$

2.1.2 双重迭代BDT算法(Double iteration BDT algorithm)

改进的BDT算法仍以式(3)为目标函数, 通过引入遗忘因子 r 增强算法的动态性能, 并构成以阶数迭代为内环, 时间序列迭代为外环的双重迭代结构.

设以 R_k 表示式(6)中 $\frac{1}{n} \sum_{t=1}^{n+k} \hat{\varepsilon}_{k-1}(t)\hat{\eta}_{k-1}(t-k)^T$ 部分, 即:

$$R_i = \frac{1}{n} \sum_{t=1}^{n+i} \hat{\varepsilon}_{i-1}(t)\hat{\eta}_{i-1}(t-i)^T, \quad (17)$$

$$i = 1, 2, \dots, k, \dots, K,$$

其中 K 表示事先设定的最大迭代阶数. 可以看出 R_i 实际表示 $\hat{\varepsilon}_{i-1}(t)$ 与 $\hat{\eta}_{i-1}(t-i)$ 协方差矩阵的平均值,

考虑到被控对象模型参数时变的影响, 因此所有AR模型系数更新过程中的参数, 均采用带有遗忘因子的更新方式来达到从时间序列角度上的迭代公式:

$$R_i^t = rR_i^{t-1} + (1-r)\hat{\varepsilon}_{i-1}(t)\hat{\eta}_{i-1}(t-i), \quad (18)$$

$$i = 1, 2, \dots, k, \dots, K,$$

$$\hat{\Gamma}(0)^t = r\hat{\Gamma}(0)^{t-1} + (1-r)x_t x_t^T, \quad (19)$$

式中 R_i^t 表示 t 时刻下的 $\hat{\varepsilon}_{i-1}(t)$ 与 $\hat{\eta}_{i-1}(t-i)$ 协方差矩阵的均值.

逆向残差 $\hat{\eta}_k(t)$ 的计算式(13)相应改为计算 $t-k$ 时刻的残差

$$\hat{\eta}_k(t-k) = \hat{\eta}_{k-1}(t-k) - b_k(k)\hat{\varepsilon}_{k-1}(t). \quad (20)$$

具体双重迭代算法的结构如图1所示.

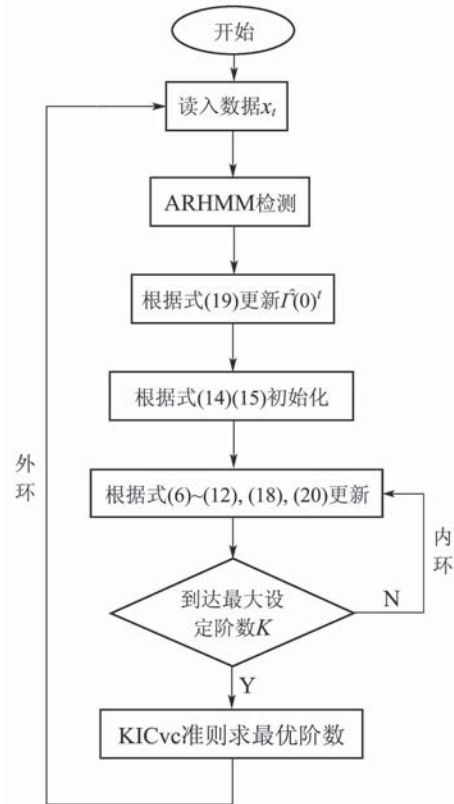


图1 双重迭代算法的流程图

Fig. 1 Flow chart of double iteration algorithm

2.2 双重迭代BDT算法收敛性分析(Convergence analysis of double iteration BDT algorithm)

传统BDT算法式(6)中 $\frac{1}{n} \sum_{t=1}^{n+k} \hat{\varepsilon}_{k-1}(t)\hat{\eta}_{k-1}(t-k)^T$

实际为 $\hat{\varepsilon}_{k-1}(t)$ 与 $\hat{\eta}_{k-1}(t-k)$ 协方差矩阵的平均值, 利用所有 n 个数据计算得到, 而在改进的BDT算法中为了实现参数在线更新以适应动态系统的要求, 引入遗忘因子得到式(18). 比较式(6)与式(18), 可以看出只有当式(18)的无偏估计与 $\frac{1}{n} \sum_{t=1}^{n+k} \hat{\varepsilon}_{k-1}(t)\hat{\eta}_{k-1}(t-k)^T$ 的无偏估计相等时才能保证改进后的BDT算法

收敛于传统的BDT算法. 为了简单易懂, 可以提取出数学问题如下:

假设一组样本 $\xi_i (i = 1, 2, \dots, n+p)$ 采用两种方法计算这组样本均值分别为:

$$\bar{\xi} = \frac{1}{n+p} (p\mu + \sum_{i=1}^n \xi_i), \quad (21)$$

$$\bar{\xi}^* = r^n \mu + \sum_{i=1}^n r^{n-i} (1-r) \xi_i. \quad (22)$$

需要证明的是: 当 $n \rightarrow \infty$ 时, $\bar{\xi}$ 与 $\bar{\xi}^*$ 的无偏估计量相等.

式中 μ 为利用 p 个样本得到的初始化均值, 即 $E(\xi_i) = \mu (i = 1, 2, \dots, p)$. 假设迭代过程中 n 个样本的均值为 $\bar{\mu}$, 即 $E(\xi_i) = \bar{\mu} (i = 1, 2, \dots, n)$. 式(21)代表通过传统BDT算法计算出的 $n+p$ 个样本的均值统计量 $R_k(n+p)$; 式(22)代表改进后BDT算法通过式(18)计算出的 $n+p$ 个样本的均值统计量 $R_k(n+p)$. $\bar{\xi}$ 的无偏估计量为

$$E\left(\frac{1}{n+p} (p\mu + \sum_{i=1}^n \xi_i)\right) = \frac{1}{n+p} (pE(\mu) + \sum_{i=1}^n E(\xi_i)) = \frac{1}{n+p} (p\mu + n\bar{\mu}). \quad (23)$$

同理 $\bar{\xi}^*$ 的无偏估计量为

$$\begin{aligned} E(r^n \mu + \sum_{i=1}^n r^{n-i} (1-r) \xi_i) &= \\ r^n E(\mu) + \sum_{i=1}^n r^{n-i} (1-r) E(\xi_i) &= \\ r^n \mu + \sum_{i=1}^n r^{n-i} (1-r) \bar{\mu} &= r^n \mu + (1-r^n) \bar{\mu}. \end{aligned} \quad (24)$$

比较式(23)与式(24)可知: 当 n 较小时, 令遗忘因子 $r = (\frac{p}{n+p})^{\frac{1}{n}}$ 时, $\bar{\xi}^*$ 与 $\bar{\xi}$ 的无偏估计量完全相等, 此时意味着所有数据占有相同的比重; 当 $n \rightarrow \infty$ 时, 式(23)中 $p\mu$ 与 $n\bar{\mu}$ 比较可忽略不计, 因此

$$E\left(\frac{1}{n+p} (p\mu + \sum_{i=1}^n \xi_i)\right) \approx \bar{\mu} - \frac{p\bar{\mu}}{p+n} \approx \bar{\mu},$$

而式(24)中, 由于 $r \in (0, 1)$, 当 $n \rightarrow \infty$ 时, $r^n \rightarrow 0$, 因此

$$E(r^n \mu + \sum_{i=1}^n r^{n-i} (1-r) \xi_i) \approx \bar{\mu}.$$

因此可以证明当数据足够多时, 改进后的BDT算法收敛于传统的BDT算法.

2.3 阶数自学习 ARHMM 检测算法实现 (Implementation of order self-learning ARHMM detection algorithm)

2.3.1 ARHMM结构 (Structure of ARHMM)

传统的ARHMM结构由两部分组成^[18]:

其中之一是马尔可夫链, 它描述了状态的转移, 由初始状态概率 π 和状态转移矩阵 $A = (a_{ij})_{N \times N}$ 描

述, 其中: $a_{ij} = P(S_t = s_t | S_{t-1} = s_i), 1 \leq i, j \leq N$, 式中: S_t 表示 t 时刻状态; N 表示HMM链的状态总个数, $P(\cdot)$ 表示条件概率.

ARHMM的另一部分为通过AR模型计算的观测值概率矩阵 $B = (b_{tj})_{N \times N}$ 描述, 其中 $b_{tj} = P(x_t = \hat{x}_t | S_t = s_j)$, 反映了状态 s_j 和观测值 \hat{x}_t 之间的统计对应关系:

$$b_{tj} = P(\hat{x}_t | S_t = s_j) = N(\hat{x}_t | \sum_{i=1}^k a_k(i) x_{t-i}, \hat{\Sigma}_k), \quad (25)$$

其中: $N(\cdot)$ 表示高斯函数; $\hat{\Sigma}_k$ 表示高斯分布的估计方差.

2.3.2 ARHMM异常数据检测算法 (ARHMM outlier detection algorithm)

ARHMM异常数据检测算法主要分两步:

其一, 由式(1)可知, 通过AR模型得到的估计值 \hat{x}_t 与实际值 x_t 存在下列关系:

$$x_t = \hat{x}_t + \varepsilon_k(t). \quad (26)$$

当偏差 $\varepsilon_k(t)$ 为环境噪声, 服从高斯分布. 因此对数据是否异常的初步判断原则为预测偏差服从高斯分布概率:

$$P\{x_t | s_t = 1\} = \exp\{-\frac{1}{2} \hat{\varepsilon}_p(t)^T \hat{U}_p^{t-1} \hat{\varepsilon}_p(t)\}, \quad (27)$$

式中 s_t 为1表示数据正常, 为0表示数据异常. 初步判断结果为

$$s_t = \begin{cases} 1, & P\{x_t | s_t = 1\} \geq 0.5, \\ 0, & P\{x_t | s_t = 1\} < 0.5, \end{cases} \quad (28)$$

式(27)中下脚标 p 表示通过KICvc准则得到的最优模型阶数. KICvc准则为^[19]:

$$\begin{aligned} \text{KICvc}(i) &= \\ n \ln(|\text{ave} \hat{\Sigma}_i^t|) + \frac{nm(2im + m + 1)}{n - im - m - 1} + \\ \frac{nm}{n - im - (m-1)/2} + \frac{2m^2i + m^2 - m}{2n}, \end{aligned} \quad (29)$$

其中: $i = 1, 2, \dots, K$; $\text{ave} \hat{\Sigma}_i^t (i = 1, 2, \dots, K)$ 表示各阶下的残差均值^[19]:

$$\text{ave} \hat{\Sigma}_i^t = \frac{\text{sum} \hat{\Sigma}_i^t}{t-1}, \quad (30)$$

$$\text{sum} \hat{\Sigma}_i^t = \text{sum} \hat{\Sigma}_i^{t-1} + \hat{\varepsilon}_i(t-1) \hat{\varepsilon}_i(t-1)^T. \quad (31)$$

其二, 由于AR模型预测存在一定误差, 为了更准确的对数据进行判断, 该检测算法将初步判断结果 $P\{x_t | s_t = 1\}$ 作为HMM双链中的观测值链 b_{tj} , 通过求解HMM最优状态链的Viterbi算法^[20], 得到代表数据异常情况的最优状态隐链, 最终对数据做出更准确的判断.

传统的Viterbi算法需要根据:

$$\begin{aligned} \varphi_0(k) &= \ln \pi_k \cdot b_{0k}, \\ \varphi_t(k) &= \max_{i=1, \dots, N} \{ \varphi_{t-1}(i) + \ln a_{ik} \} + \\ &\quad \ln b_{tk}, \quad k = 1, \dots, N. \end{aligned} \quad (32)$$

计算所有数据的 φ 值后确定最优状态序列, 而在改进的ARHMM算法中, 由于在检测 t 时刻数据时, 对于 t 时刻以前的数据都已做出判断, 所以只需计算第 t 时刻的检测指标:

$$\varphi_t(1) = a_{i1} \cdot P_t(1), \quad \varphi_t(0) = a_{i0} \cdot P_t(0), \quad (33)$$

其中: $\varphi_t(1)$ 表示数据为正确数据的概率; $\varphi_t(0)$ 表示数据为异常的概率; $P_t(1) = P\{x_t | s_t = 1\}$ 由式(27)计算; $P_t(0) = 1 - P_t(1)$; 如果 $\varphi_t(1) > \varphi_t(0)$, 则数据正常, 否则数据异常.

因此图1中“ARHMM检测”方框可以展开成如图2虚线框内的形式.

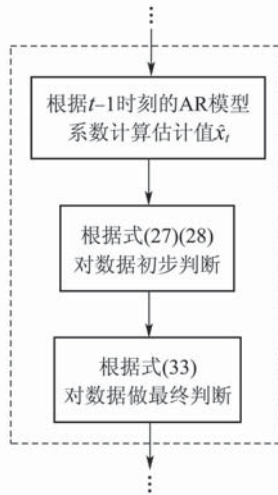


图 2 ARHMM检测步骤

Fig. 2 Detection processes by ARHMM

从图2中可以看出ARHMM异常数据检测算法中的两步判断方法, 既避免了传统方法的检测阈值设定问题又能够保证判断的准确性.

2.4 异常数据下的参数更新算法 (Parameters updating by outlier)

阶数自学习ARHMM算法中需要在线更新的参数有: 估计残差平均值 $\text{ave} \hat{\Sigma}_i^t$, 状态转移矩阵 A , 改进的BDT算法在 t 时刻的初始值 $\hat{\varepsilon}_\emptyset(t)$, $\hat{\eta}_\emptyset(t)$, $\hat{\Gamma}^t(0)$ 以及 R_i . 其中 $\text{ave} \hat{\Sigma}_i^t$, $\hat{\varepsilon}_\emptyset(t)$, $\hat{\eta}_\emptyset(t)$, $\hat{\Gamma}^t(0)$, R_i 均根据检测结果不同有两套不同的更新方式, 具体更新算法如下:

1) 估计残差平均值 $\text{ave} \hat{\Sigma}_i^t$ 的更新算法: 为了减小异常值对于阶数判断的影响, 采用上一步的 $\hat{\varepsilon}_i(t-1)$ 更新当前的 $\text{ave} \hat{\Sigma}_i^t$ 值: 如果 $t-1$ 时刻数据检测为正常数据, 则按照式(30)(31)更新 $\text{ave} \hat{\Sigma}_i^t$ 值; 否则, $\text{ave} \hat{\Sigma}_i^t$ 值暂不更新.

2) 状态转移矩阵 A 的更新算法: 数据检测中ARHMM状态只有两种—1表示正确数据; 0表示异常数据, 所以对应的状态转移矩阵为 $A = (a_{ij})_{2 \times 2}$, 其中各个元素更新计算如下^[18]:

$$\begin{cases} a_{01} = \frac{N(a_{01})}{N(a_{01} + a_{00})}, & a_{11} = \frac{N(a_{11})}{N(a_{11} + a_{10})}, \\ a_{00} = 1 - a_{01}, & a_{10} = 1 - a_{11}, \end{cases} \quad (34)$$

其中 $N(a_{ij})$ 表示前一时刻数据状态为 i , 后一时刻数据状态为 j 这种情况出现的次数^[21].

3) 改进的BDT在 t 时刻的初始值 $\hat{\varepsilon}_\emptyset(t)$, $\hat{\eta}_\emptyset(t)$, $\hat{\Gamma}^t(0)$ 以及 R_i 的更新均要考虑异常数据的影响问题, 具体方法如下:

a) $\hat{\varepsilon}_\emptyset(t)$, $\hat{\eta}_\emptyset(t)$ 的更新方法: 数据正常情况下按照式(14)正常更新, 异常情况下利用数据均值代替该异常数据.

b) $\hat{\Gamma}^t(0)$ 更新方法: 数据正常情况下按照式(19)更新, 异常情况下引入惩罚因子, 按照式(35)更新:

$$\hat{\Gamma}^t(0) = \eta r \hat{\Gamma}^{t-1}(0) + (1 - \eta r) x_t x_t^T. \quad (35)$$



c) R_i 更新方法: 数据正常情况下按照式(18)更新, 异常情况下引入惩罚因子, 按照式(36)更新计算:

$$\begin{aligned} R_i^t &= \eta r R_i^{t-1} + (1 - \eta r) \hat{\varepsilon}_{i-1}(t) \hat{\eta}_{i-1}(t - i), \\ &\quad i = 1, 2, \dots, k, \dots, K. \end{aligned} \quad (36)$$

3 验证与应用 (Validation and application)

3.1 依据模型验证 (Model-based validations)

为了验证该算法在检测模型阶数方面的准确性, 本文首先利用已知阶数的模型得到以下3组数据: a) 利用三阶模型生成1000个检测数据; b) 利用五阶模型生成1000个检测数据; c) 选取三阶模型数据中前200个点加入25.92%的噪声, 得到第3组检测数据数据; 3组待检测数据如图3所示, 检测结果如图4所示.








图3 检测阶数的数据


Fig. 3 Data for order detection



(a)



(b)



(c)


图4 模型阶数检测结果

Fig. 4 Results of order detection


图4中, 每组图中第1个图像为信号拟合图像, “圆点”为拟合值, “叉号”表示待检测数据; 第2个图像为模型阶数判断图像。从图4(a)(b)可以看出, 对于已知阶数的三阶、五阶模型数据, 该算法通过短期调节过程后, 能正确的检测出模型的阶数; 图4(c)中由于存在较大的噪声, 调节时间较长, 而后能够正

确的检测出模型阶数, 证明了该算法在检测模型阶数上的有效性及抗噪性。

为验证该算法对于工业控制过程异常数据检测的实用性, 本文利用电弧炉模型生成以下两组数据: a) 在电弧炉模型数据中加入25.92%的白噪声后又加入14个异常点(模拟电弧炉炼钢过程中的塌料和断弧); b) 在电弧炉模型数据中加入25.92%的白噪声后又加入14个幅值较小的异常点, 得到第2组数据。两组待检测数据如图5所示, 检验结果如图6所示。




(a)




(b)

图5 检测异常点的数据

Fig. 5 Data for outlier detection



(a)



(b)

图6 检测结果

Fig. 6 Results of detection

图6中, 每组图中第1个图像为异常数据检测结果, “1”表示数据正常, “0”表示数据异常; 第2个图像为模型阶数检测结果. 图6(a)中, 在25.92%的噪声下该算法能够准确检测出所有异常点, 阶数检测经过调整期后能够稳定于正确阶数值; 图6(b)由于异常点幅值很小, 相对噪声较大, 所以在最初异常点检测不准确, 而后检测结果准确, 且阶数经过调整能够稳定于正确阶数值. 证明了该算法在一定噪声下(25.92%)能够较准确的检测出异常数据.

3.2 应用(Application)

以上海宝钢30t电弧炉电极调节系统为例, 由于电弧炉炼钢过程中存在塌料等现象, 使得采集的被控对象输入输出数据无法直接用于被控对象的模型分析, 因此需要对该数据进行异常检测.

取上海宝钢30t电弧炉2008年4月一炉钢中的1000组数据进行检测, 待检测数据如图7所示, 检测结果如图8所示. 图8中第1个图像为异常数据检测结果图像, 其中“1”表示数据正常, “0”表示数据异常. 从图中可以看出在开始调节阶段存在一处检测不准确, 而后第700步左右存在一处误检现象, 误检率为0.2%; 其他异常点均能正确检出. 图8中第2个图像表示模型阶数判断结果.




图 7 真实待检测数据

Fig. 7 Real data for detection




图 8 真实数据检测结果

Fig. 8 Detection result of real data

完整的检测过程中用时2.1875 s, 所以平均检测一个数据用时2.1875 ms, 与控制周期50 ms比较, 完全满足在线实时检测的要求, 同时也证明了该算法的实用性.

3.3 与 AR 模型异常数据检测方法的比较(Comparison with outlier detection algorithm based on AR model)

Jun-ichi Takeuchi在2006年提出了用于时间序列异常检测的AR模型检测方法^[14], 以上海宝钢现场采集的真实数据(图7所示)为例, 将AR模型异常数据检测方法与本站提出的模型阶数自学习ARHMM异常数据检测方法做比较, 利用AR模型检测图7中数据得到的结果如图9所示.




图 9 真实数据下AR模型检测算法的检测结果

Fig. 9 Detection result by AR model algorithm for real data

由于基于AR模型的异常数据检测算法对每一个数据赋予一个检测分数, 最后通过判断分数确定数据的异常情况, 即认为分数越高数据异常的可能性越大. 因此图9中纵坐标表示各个数据的分数, 通过比较图9与图8可以看出, AR模型异常数据检测方法将系统开始阶段正常的震荡调节过程产生的数据误检为异常数据, 检测结果较不准确. 而且AR模型判断数据是否异常需要通过事先设定一个阈值分数, 即分数大于该阈值的数据为异常数据. 然而在检测之前对于先验未知的过程数据, 准确设定检测阈值是非常困难的. 因此可以看出与AR模型异常数据检测算法相比, 本文提出的模型阶数自学习的ARHMM异常数据检测算法更适合先验未知且震荡不稳定的过程数据的异常检测.

4 结论(Conclusion)

本文针对工业控制过程数据在线检测的要求以及ARHMM直接应用于工业数据分析的不足, 提出了阶数自学习的ARHMM控制工业异常数据检测算法. 该算法将适合分析时间序列随机过程分类的ARHMM与用于求解AR模型参数的BDT算法相结合, 并适当改进, 使其能够适用于工业控制过程数据的在线分析. 考虑到工业过程数据实时性强, 数据量大的特点, 该算法将传统从阶数角度迭代用来求解ARHMM系数的BDT算法改进成为以阶数迭代为内环, 以时间迭代为外环的双重迭代结构, 并在每次内环迭代结束后进行KICvc准则判断, 以在线求得最优ARHMM阶数, 从而使得ARHMM能够更准确的分析工业控制过程数据, 对数据是否异常作出准确判断, 扩大了ARHMM应用的领域. 该算法采取先检验后更新的办法, 根据检测结果采取不同的更新方式, 有效地抑制了异常数据对于模型参数更新的

影响. 试验与应用证明该算法具有很好的工业异常数据检测效果. 通过与AR模型异常数据检测算法比较, 证明了基于阶数自学习的ARHMM异常数据检测算法更适合先验未知且震荡不稳定的过程数据的异常检测.

参考文献 (References):

- [1] FACCO P, DOPLICHER F, BEZZO F, et al. Moving average PLS soft sensor for online product quality estimation in an industrial batch polymerization process[J]. *Journal of Process Control*, 2009, 19(3): 520 – 529.
- [2] ZHANG Y, ZHANG Z, XU X, et al. Modal parameter identification using response data only[J]. *Journal of Sound and Vibration*, 2005, 282(1/2): 367 – 380.
- [3] YOUNG P, CHOTAI A. Data-based mechanistic modeling, forecasting, and control[J]. *IEEE Control Systems Magazine*, 2001, 21(5): 14 – 27.
- [4] DICKINSON M. Supervisory control and data acquisition in the forging industry[J]. *Measurement & Control*, 2002, 35(3): 76 – 79.
- [5] BARNET V, LEWIS T. *Outlier in Statistical Data*[M]. Chichester: John Wiley & Sons, 1994.
- [6] KNORR E M, NG R T. Finding intensional knowledge of distance-based outliers[C] // *Proceedings of the 25th International Conference on Very Large Data Bases*. San Francisco, CA, USA: Morgan Kaufmann, 1999, 211 – 222.
- [7] KNORR E M, NG R T. Algorithms for mining distance-based outliers[C] // *Proceedings of the 24th International Conference on Very Large Data Bases*. San Francisco, CA, USA: Morgan Kaufmann, 1998, 392 – 403.
- [8] RAMASWAMY, RASTOGI S, KYUSEOK R. Efficient algorithms for mining outliers from large data sets[C] // *Proceedings of the ACM SIGMOD International Conference on Management of Data Dallas*. Teas: ACM Press, 2000: 427 – 438.
- [9] 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.
- [10] ALMEIDA Jas, BARBOSA Lms, PAIS Aacc. Improving hierarchical cluster analysis: a new method with outlier detection and automatic clustering[J]. *Chemometrics and Intelligent Laboratory Systems*, 2007, 87(2): 208 – 217.
- [11] BULLEN R J, CORNFORD D, NABNEY I T. Outlier detection in scatterometer data: neural network approaches[J]. *Neural Networks*, 2003, 16(3/4): 419 – 426.
- [12] 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*. Los Alamitos, CA, USA: IEEE, 2008: 555 – 560.
- [13] AGRAWAL R, RAGARAN P. A linear method for deviation detection in large databases[C] // *Knowledge Discovery and Data Mining Conference Proceedings*. Menlo Park, CA, USA: AAAI Press, 1995: 164 – 169.
- [14] JUN Ichi Takeuchi, KENJI Yamanishi. 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.
- [15] HEKIMOGLU S, ERENOGLU R C, KALINA J. Outlier detection by means of robust regression estimators for use in engineering science[J]. *Journal of Zhejiang University, Science A*, 2009, 10(6): 909 – 921.
- [16] BROCKWELL P J, DAHLHAUS R, TRINDADE A A. Modified burg algorithms for multivariate subset autoregression[J]. *Statistica Sinica*, 2005, 15(1): 197 – 213.
- [17] BROCKWELL P J, DAHLHAUS R, TRINDADE A A. Implementing modified burg algorithms in multivariate subset autoregressive modeling[EB/OL]. Gainesville, Department of Statistics, University of Florida, 2003, <http://www.jstatsoft.org/v08/i05/paper>.
- [18] JEFF A B. What HMMs can do[J]. *IEICE Transactions on Information and Systems*, 2006, E89-d(3): 1 – 24.
- [19] ABD K S. Vector autoregressive model-order selection from finite samples using kullback's symmetric divergence[J]. *IEEE Transactions on Circuits and Systems-I: Regular Papers*, 2006, 53(10): 2327– 2335.
- [20] HUI LING LOU. Implementing the viterbi algorithm[J]. *IEEE Signal Processing Magazine*, 1995, 12(5): 42 – 52.
- [21] LAWRENCE R T. A tutorial on hidden Markov models and selected applications in speech recognition[J]. *Proceedings of the IEEE*, 1989, 77(2): 257 – 285.

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, 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.