

基于离散 Hopfield 网络的自相关过程控制方法

崔庆安

CUI Qing-an

郑州大学 管理工程研究所, 郑州 450001

Institute of Management Engineering, Zhengzhou University, Zhengzhou 450001, China

E-mail:cuiqa@zzu.edu.cn

CUI Qing-an. Discrete hopfield networks-based approach of autocorrelated process control. *Computer Engineering and Applications*, 2008, 44(19):8-11.

Abstract: Both traditional statistical methods and Back Propagation (BP) neural network methods have their limitations in monitoring autocorrelated industrial processes. Traditional statistical methods typically result in high false alarm rate. BP neural network methods usually lead to low sensitivity and cause difficulties in network weights training. Based on associative learning and discrete Hopfield network, a new statistical control method for autocorrelated processes is proposed. The method doesn't need training samples. By using orthogonal coding, the process states are stored into Hopfield network in the form of attractors. Then the step shift of the autocorrelated process is detected out by using the associative phase of the Hopfield network. The case studies show that, the Average Run Levels (ARL) of the proposed method increase 27.9% and 55.0% when there is no step shift in the process and decrease at least 74.1% and 81.8% when step shift exists, respectively, compared with Elman networks and EWMA.

Key words: autocorrelated process; Hopfield network; associative learning; statistical process control

摘要:对于自相关过程的统计控制,传统统计学方法虚发警报的概率较大,而 BP 人工神经网络方法权值训练困难,灵敏度不高。提出一种基于联想学习与离散 Hopfield 网络的自相关过程控制方法。不需任何训练样本,通过正交化编码将过程状态以吸引子的形式存储到 Hopfield 网络中,并利用网络的联想功能来检测自相关过程的阶跃型突变。算例研究表明,与 Elman 网络和 EWMA 方法相比,过程正常时,所提方法的平均链长(ARL)分别提高了 27.9% 和 55.0%;过程异常时,所提方法的 ARL 分别降低了 74.1% 与 81.8% 以上。说明了方法的有效性与优越性。

关键词:自相关过程; Hopfield 网络; 联想学习; 统计过程控制

DOI:10.3777/j.issn.1002-8331.2008.19.003 **文章编号:**1002-8331(2008)19-0008-04 **文献标识码:**A **中图分类号:**TP391

1 引言

统计过程控制是保证产品质量的重要手段之一。休哈特控制图采用 3σ 方式来检测过程偏移,被广泛应用于过程质量控制,取得了显著成效。观测值之间相互独立是休哈特控制图的基本应用前提,但是随着现代制造业的兴起,由于高频采样或者是自身理化性质的原因,许多生产过程,例如化工、生物医药等,其质量特性的观测值序列存在显著的自相关,此时应用休哈特控制图将导致大量的虚发警报,严重削弱使用效果。研究者们采用了调整休哈特控制图控制界限、增加报警规则^[1];或者是基于时间序列分析的 CUSUM、EWMA、残差控制图来进行自相关过程控制^[2-4]。但在实际中,由于自相关过程的参数很难精确地估计,因此上述方法的控制效果并不理想^[5]。

近年来,研究者将人工神经网络(Artificial Neural Networks, ANN)方法引入到了自相关过程的统计过程控制之中。ANN 方法不需要估计过程参数,它通过对不同过程均值突变模式下的

训练样本的学习,来对过程的未知变化进行辨识。目前常用的 ANN 方法多基于反向传播算法,例如多层感知器、BP 网络^[6]、RBF 网络^[7]、Elman 网络^[8]等等。与传统统计学方法的相比,ANN 方法取得了显著的优势。但是在应用中,BP 算法网络仍存在不足:(1)对于不同的自相关序列参数,需要训练不同的网络,这不仅增大了训练难度,而且极易导致网络出现“过学习”现象;(2)网络训练时需要大量的样本,理论上只有拥有了包含所有背景噪声模式、所有均值突变模式的训练样本,才能对未知的突变做出正确的辨识;(3)前馈网络对于强自相关或均值突变较小的过程识别率不高,其灵敏度与可靠性仍然有待提高。

为克服上述不足,本文提出一种基于联想学习与离散 Hopfield 网络的自相关过程控制方法。以反馈神经网络作联想存储器,不需要任何训练样本,对不同的自相关参数具有通用性,而且灵敏度与可靠性均优于现有方法。首先对自相关过程和离散 Hopfield 网络进行了简要介绍,然后对基于离散

基金项目:国家自然科学基金(the National Natural Science Foundation of China under Grant No.70572044, No.70740002)。

作者简介:崔庆安(1974-),男,博士,副教授,主要研究领域为质量工程,人工智能等。

收稿日期:2008-02-18 修回日期:2008-03-24

Hopfield 网络的自相关过程控制方法进行了研究, 并且通过不同参数组合下的算例对比, 说明了方法的有效性与优越性。

2 自相关过程的统计描述

令 $\{x_t\}$ 代表过程的质量特性的时间序列观测值, 其中 $t=1, 2, \dots, k$ 代表时间观测点, 并且有:

$$x_t = z_t + s \quad (1)$$

其中 z_t 是为平稳自相关过程, s 是由异常原因引起的过程质量特性均值的突变。

对于 z_t , 多采用一阶自回归移动平均 ARMA(1, 1)模型^[9]来描述:

$$z_t = \phi z_{t-1} - \theta \varepsilon_{t-1} + \varepsilon_t \quad (2)$$

其中 ϕ 称为自回归参数, $|\phi|$ 越大, 表明 z_t 受 z_{t-1} 的影响越大。 θ 代表移动平均参数, ε_t 为相互独立、均值为零的高斯白噪声序列, $\varepsilon_t \sim NID(0, \sigma^2_\varepsilon)$ 。不失一般性, 可以假设:

$$\left\{ \begin{array}{l} E(z_t) = 0 \\ \sigma_z^2 = \frac{1-\phi^2}{1+\theta^2-2\phi\theta} \end{array} \right. \quad (3)$$

于是, x_t 将变为均值为 s , 方差为 1 的序列。 x_t 的方差不随 t 变化的过程称为平稳自相关过程。自相关过程质量控制的目的在于及时、有效地检测出平稳自相关过程的突变 s 。通常采用平均链长 (Average Run Length, ARL) 来评价某一控制方法性能。ARL 是指在某一特定的质量水平上, 控制图检测到过程发生突变所需要的样本的平均数。控制时, 一方面希望在均值发生突变的情况下, 能够有较小的 ARL, 即拥有较高的灵敏度; 而另一方面, 在过程正常时, 则希望拥有较大的 ARL, 尽可能的降低虚发警报的概率, 提高过程的可靠性。一般来说, 过程噪声的方差 σ_ε^2 直接影响 s 的检测准确率, 如果 s 相对于 σ_ε^2 来说过大, 则 s 将被过程噪声 ε_t 所淹没, 很难进行有效的识别。

3 离散 Hopfield 网络与联想学习

3.1 离散 Hopfield 网络原理

离散 Hopfield 网络^[10]属反馈型网络, 其任一神经元的输出经其他神经元后又反馈给自身(图 1)。它是一种模拟生物记忆功能的联想学习网络, 拥有良好的容错和纠错性能, 由各神经元的权重和连接结构来实现记忆与联想的功能, 可以把被污染的、不完整和畸变的输入样本恢复成完整的原形, 因而被广泛应用于分类、识别等领域^[11]。

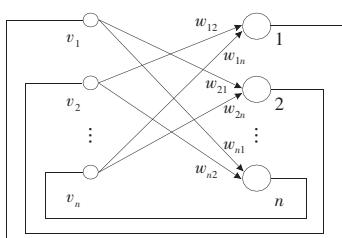


图 1 离散 Hopfield 网络示意图

设 Hopfield 网络共有 n 个神经元, 每个神经元均取 -1 或 1 二值, 则网络共有 2^n 个状态, 并且构成一个离散状态空间。设在学习过程中给 Hopfield 网络存入了 m 个样本: $x_i, i=1, 2, \dots, m$, 若将 x_i 被噪声 v 污染后新值 $x' = x_i + v$ 的作为网络输入, 则通过网络的联想, 可以输出为 x_i , 从而达到还原的目的。这 m 个样本称为 Hopfield 网络的稳定平衡态或吸引子。存在吸引子是 Hopfield 网络进行记忆与联想的关键, 需要通过合理的网络权值设计来实现。

3.2 Hopfield 网络的设计

离散 Hopfield 网络的工作过程可以分为记忆阶段和联想阶段。在记忆阶段, 通过合理地设计网络权值, 使网络具有若干个吸引子。而联想阶段则是给定输入模式, 通过网络的动力学演化过程达到稳定状态, 收敛到吸引子, 回忆起已存储模式的过程。

离散 Hopfield 网络的设计和运行步骤如下:

(1) 对记忆模式进行编码。设在网络中需要存储 m 个 n 维的记忆模式 ($m < n$):

$$U^{(p)} = [u_1^{(p)}, u_2^{(p)}, \dots, u_n^{(p)}]^T, p=1, 2, \dots, m \quad (4)$$

对每一 $u_i^{(p)}, i=1, 2, \dots, n$ 进行编码, 使得 $u_i^{(p)} \in \{-1, 1\}$ 。

(2) 设计网络权值 w_{ij} :

$$w_{ij} = \begin{cases} \frac{1}{n} \sum_{k=1}^m u_i^{(p)} u_j^{(p)}, & j \neq i \\ 0, & j=i \end{cases} \quad (5)$$

式(5)称之为权值设计的外积法。可以证明, 如果记忆模式 $U^{(p)}$, $p=1, 2, \dots, m$ 是两两正交的, 那么外积法可以保证式(4)所代表的 m 个模式, 恰好是网络状态空间中的 m 个吸引子。

(3) 初始化网络状态。设 Hopfield 网络的第 i 个神经元在 t 时刻的输出是 $v_i(t)$, 将需要识别的模式 $U^{(0)} = [u_1^{(0)}, u_2^{(0)}, \dots, u_n^{(0)}]^T$ 设为网络的初始状态, 即令 $v_i(0) = u_i^{(0)}$ 。

(4) 迭代收敛。根据公式(6):

$$v_i(t+1) = \text{Sgn} \left[\sum_{j=1}^n w_{ij} v_j(t) \right] \quad (6)$$

对神经元进行更新, 直至某一时刻 T , 所有神经元的状态不变为止, 即 $v_i(T+1) = v_i(T), i=1, 2, \dots, n$ 。

(5) 网络输出

网络稳定后的状态 $v_i(T)$ 称为网络的输出, 将 $v_i(T)$ 与记忆模式 $U^{(p)}$ 相比较, 即可得出网络对于输入 $U^{(0)}$ 的联想结果。

4 基于 Hopfield 网络的自相关过程控制方法

利用 Hopfield 网络进行自相关过程控制, 其基本思想是将 x_t 分为原形和噪声两个部分。通过网络的记忆与联想, 滤掉噪声干扰, 使过程恢复到原形, 再判断过程是否正常。

考虑式(1)所描述的平稳自相关过程, 由于 $E(x_t) = s$, 因此可以将 t 时刻的 s 值看作该时刻的原形; 另一方面, 对式(2)展开有:

$$z_t = \phi z_{t-1} - \theta \varepsilon_{t-1} + \varepsilon_t = \phi z_0 - \theta(\varepsilon_{t-1} + \phi \varepsilon_{t-2} + \phi^2 \varepsilon_{t-3} + \dots + \phi^{t-1} \varepsilon_0) + \theta \varepsilon_{t-1} + \phi \varepsilon_{t-2} + \phi^2 \varepsilon_{t-3} + \dots + \phi^{t-1} \varepsilon_1 \quad (7)$$

在 $t=0$ 时, 若令 $z_0=0, \varepsilon_0=0$, 则有:

$$\left\{ \begin{array}{l} z_1 = \varepsilon_1 \\ z_t = \varepsilon_t + \phi \varepsilon_{t-1} + \phi^2 \varepsilon_{t-2} + \cdots + \phi^{t-1} \varepsilon_1 - \\ \theta(\varepsilon_{t-1} + \phi \varepsilon_{t-2} + \phi^2 \varepsilon_{t-3} + \cdots + \phi^{t-2} \varepsilon_1) = \\ \varepsilon_t + (\phi - \theta) \varepsilon_{t-1} + (\phi^2 - \phi \theta) \varepsilon_{t-2} + \cdots + (\phi^{t-1} - \phi^{t-2} \theta) \varepsilon_1, t > 1 \end{array} \right. \quad (8)$$

式(8)说明, z_t 是由白噪声序列 $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_t$ 的线性组合而成。因此可以将 z_t 看作 t 时刻的噪声项, 而 x_t 则成为 t 时刻原形 s 被 z_t 污染后的样本。

由于 $s=0$ 代表过程正常, $s \neq 0$ 代表过程失控, 于是通过对 s 进行适当的编码, 可以将过程正常或过程失控两种状态分别作为两个吸引子存储到 Hopfield 网络中。而对于待检测的 x_t , 将其编码后作为网络输入, 通过联想功能滤去 z_t 的影响, 使其收敛到稳定态, 再根据稳定态的类型判断过程是否正常。具体步骤如下:

(1) 吸引子编码

设在第 k_0 ($k_0 \geq 2$) 时刻, 过程均值出现了大小为 s_0 ($s_0 > 0$) 的阶跃型突变, 于是当 $t \geq k_0$ 时有 $E(x_t) = s_0$, 而当 $t < k_0$ 时有 $E(x_t) = 0$ 。以 k_0 时刻作为基准点, 等距离的向前后各延伸 l 个时刻, 共计 $2l$ 个时刻, 对这 $2l$ 时刻内的 s 值进行编码, 若过程均值未发生突变 ($s=0$), 则将 s 值编码为 -1, 若过程均值发生突变 ($s>0$), 则将 s 值编码为 1, 由此形成如表 1 所示的吸引子编码方案。

表 1 过程正常与异常时的吸引子编码

| 过程时刻 (t) | 网络神经元 (v_i) | 过程正常 | | 过程异常 | |
|--------------|-----------------|----------|-----------|----------|-----------|
| | | s | $U^{(1)}$ | s | $U^{(2)}$ |
| k_0-l | v_1 | 0 | -1 | 0 | -1 |
| \vdots | \vdots | \vdots | \vdots | \vdots | \vdots |
| k_0-1 | v_l | 0 | -1 | 0 | -1 |
| k_0 | v_{l+1} | 0 | -1 | s_0 | 1 |
| \vdots | \vdots | \vdots | \vdots | \vdots | \vdots |
| k_0+l-1 | v_{2l} | 0 | -1 | s_0 | 1 |

采用上述编码方案, 吸引子 $U^{(1)}$ 表示在这 $2l$ 个时刻内, s 值未发生变化, 即过程正常; 吸引子 $U^{(2)}$ 表示 s 在第 k_0 时刻出现了阶跃型突变, 即过程发生异常。

(2) 模式记忆与权值设计

由式(5)及 $U^{(1)}, U^{(2)}$, 可计算出网络的权值:

$$W = \frac{1}{l} \begin{bmatrix} W_1 & \mathbf{0} \\ \mathbf{0} & W_2 \end{bmatrix}_{2l \times 2l} \quad (9)$$

$$W_1 = W_2 = \begin{bmatrix} 0 & 1 & \cdots & 1 \\ 1 & 0 & \cdots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & 1 & 0 \end{bmatrix}_{2l \times 2l} \quad (10)$$

由于 $U^{(1)}(U^{(2)})^T = 0$, 说明 $U^{(1)}$ 与 $U^{(2)}$ 正交。因此根据外积法的性质, 这样就将过程正常和过程异常的模式作为吸引子存储到了 Hopfield 网络之中, 该网络共有 $n=2l$ 个神经元。

(3) 待检测样本编码及输入向量生成

对于 $t=k_0-l, \dots, k_0, \dots, k_0+l-1$ 时刻的 x_t 值编码规则如下:

$$c(x_t) = \begin{cases} 1, & x_t > M \\ -1, & x_t < M \end{cases} \quad (11)$$

其中:

$$M = \frac{1}{2} \left(\frac{1}{l} \sum_{j=k_0}^{k_0+l-1} x_j - \frac{1}{l} \sum_{i=k_0-l}^{k_0-1} x_i \right) \quad (12)$$

网络的输入向量为:

$$\mathbf{U}^{(0)} = [u_1^{(0)}, u_2^{(0)}, \dots, u_{2l}^{(0)}]^T = [c(x_{k_0-l}), c(x_{k_0-l+1}), \dots, c(x_{k_0+l-1})]^T \quad (13)$$

(4) 联想与模式判别

利用式(6)对 $U^{(0)}$ 进行迭代运算至网络达到稳定态, 与 $U^{(1)}$ 、 $U^{(2)}$ 相比, 确定过程是否正常。根据 Hopfield 网络的性质, 除了设定的吸引子之外, 网络中将伴随产生其他多余的稳定状态 (伪吸引子)。如果第(5)步网络稳定后的吸引子类型与 $U^{(1)}, U^{(2)}$ 均不相同, 则说明网络稳定到了伪吸引子。此时需要增大 l 的值, 重复步骤(1)~(5), 直至网络稳定至 $U^{(1)}$ 或 $U^{(2)}$ 为止, 此时的 l 值即为网络自 k_0 时刻起检测到过程异常所需的样本量。

5 算例研究

以 ARMA (1,1) 模型描述的平稳自相关过程为对象选取 $\phi = \{-0.95, -0.475, 0, 0.475, 0.95\}$ 和 $\theta = \{-0.9, -0.45, 0, 0.45, 0.9\}$ 的 25 组参数组合来考察方法的效果。该些组合基本上覆盖了模型的参数空间, 并且已被 Jiang^[12], Pacella^[8] 等学者广泛研究, 因而具有良好的代表性和可比性。利用式(3)设定 ε_i , 使过程成为均值为 s , 方差为 1 的自相关过程。

表 2 分别给出了过程正常 ($s=0$), 过程异常 ($s=1, s=1.5$ 与 $s=2$) 时, Hopfield 网络 (HNN)、Elman 网络 (ENN)、EWMA 方法在不同参数组合处 ARL。其中, Hopfield 网络与 EWMA 方法在 25 组参数组合处各做 100 次仿真, 取其平均值作为 ARL, 而 Elman 网络的 ARL 则来源于文献[8]。

为进一步考察 Hopfield 方法的性质, 在过程突变 $s>0$ 的条件下, 以自回归系数 ϕ 、移动平均系数 θ 、过程突变 s 作为影响因子, Hopfield 网络的 ARL 作为响应输出, 作固定效应模型方差分析, 其结果如表 3 所示。

6 结果讨论

(1) 从表 2 可以看出, 在过程正常或异常的情况下, 基于 Hopfield 网络的自相关过程控制方法的效果优于 Elman 网络和 EWMA 方法。当 $s=0$ 时, 与 Elman 网络和 EWMA 相比, Hopfield 网络的平均 ARL 分别提高了 27.9% 和 55.0%, 说明方法虚发警报的概率较低; 当 $s=1, s=1.5, s=2$ 时, 与 Elman 网络相比, Hopfield 网络的平均 ARL 分别降低了 76.7%, 78.4%, 74.1%; 与 EWMA 方法相比, 平均 ARL 则分别降低了 81.8%, 96.5%, 86.7%, 说明方法可以在最短的时间内检测到过程的变异。

(2) 从表 3 可以看出, 除 θ 和 s 的交互作用不显著之外, ϕ 、 θ 、 s 、 ϕ 和 θ 的交互作用、 ϕ 和 s 的交互作用对于 Hopfield 方法

表 2 各种方法的 ARL 对比

| (ϕ, θ) | ARL(s=0) | | | ARL(s=1) | | | ARL(s=1.5) | | | ARL(s=2) | | |
|------------------|----------|-------|-------|----------|-------|------|------------|-------|------|----------|-------|------|
| | Hopfield | Elman | EWMA | Hopfield | Elman | EWMA | Hopfield | Elman | EWMA | Hopfield | Elman | EWMA |
| (0.95, 0.9) | 510.7 | 375.4 | 252.3 | 3.5 | 23.9 | 49.6 | 1.5 | 8.6 | 21.9 | 4.5 | 4.2 | 14.6 |
| (0.95, 0.45) | 279.9 | 375.5 | 39.3 | 24.4 | 75.5 | 42.0 | 6.1 | 37.4 | 28.4 | 5.0 | 21.9 | 19.7 |
| (0.95, 0) | 264.8 | 374.5 | 28.5 | 27.0 | 88.7 | 42.1 | 11.5 | 42.3 | 26.5 | 7.1 | 20.6 | 19.5 |
| (0.95, -0.45) | 412.4 | 370.0 | 27.9 | 23.3 | 86.9 | 42.4 | 8.8 | 45.6 | 27.7 | 5.8 | 28.1 | 22.2 |
| (0.95, -0.9) | 308.7 | 368.0 | 23.7 | 26.3 | 97.9 | 40.4 | 15.4 | 46.7 | 27.2 | 4.7 | 23.8 | 21.5 |
| (0.475, 0.9) | 590.2 | 371.1 | 500.0 | 2.8 | 8.8 | 51.9 | 1.3 | 3.5 | 23.4 | 1.2 | 2.4 | 13.1 |
| (0.475, 0.45) | 495.2 | 370.0 | 405.9 | 3.2 | 16.4 | 47.9 | 1.3 | 9.5 | 20.9 | 1.0 | 6.5 | 13.6 |
| (0.475, 0) | 456.0 | 370.9 | 67.1 | 4.0 | 22.4 | 43.5 | 2.1 | 12.0 | 18.8 | 1.0 | 7.9 | 13.3 |
| (0.475, -0.45) | 322.8 | 370.6 | 34.1 | 4.2 | 29.6 | 42.3 | 1.9 | 17.0 | 18.1 | 1.0 | 11.7 | 13.6 |
| (0.475, -0.9) | 335.4 | 371.8 | 28.9 | 4.7 | 33.3 | 42.0 | 2.1 | 14.9 | 18.6 | 1.0 | 7.9 | 14.1 |
| (0, 0.9) | 566.5 | 371.5 | 500.0 | 2.8 | 5.1 | 55.1 | 1.2 | 3.2 | 33.5 | 1.4 | 2.5 | 13.4 |
| (0, 0.45) | 579.1 | 373.3 | 500.0 | 2.9 | 6.3 | 52.9 | 1.0 | 3.0 | 26.0 | 1.2 | 2.2 | 13.7 |
| (0, 0) | 520.0 | 371.9 | 429.9 | 3.5 | 20.3 | 48.7 | 1.0 | 7.4 | 20.8 | 1.0 | 3.8 | 12.9 |
| (0, -0.45) | 395.5 | 372.2 | 120.3 | 3.2 | 21.0 | 45.2 | 1.0 | 12.0 | 19.1 | 1.0 | 8.0 | 13.5 |
| (0, -0.9) | 426.8 | 377.3 | 84.4 | 3.2 | 25.8 | 44.6 | 1.0 | 12.1 | 19.4 | 1.0 | 6.9 | 13.8 |
| (-0.475, 0.9) | 590.2 | 375.4 | 500.0 | 1.3 | 3.2 | 57.4 | 1.6 | 2.3 | 53.2 | 1.2 | 1.9 | 13.9 |
| (-0.475, 0.45) | 602.4 | 369.8 | 500.0 | 1.3 | 3.0 | 56.5 | 1.4 | 2.0 | 39.3 | 1.4 | 1.7 | 14.3 |
| (-0.475, 0) | 566.8 | 373.1 | 500.0 | 1.4 | 6.2 | 51.9 | 1.1 | 2.8 | 26.9 | 1.2 | 2.1 | 13.7 |
| (-0.475, -0.45) | 473.2 | 370.6 | 438.3 | 1.9 | 29.6 | 48.6 | 1.2 | 17.0 | 21.8 | 1.2 | 11.7 | 13.8 |
| (-0.475, -0.9) | 439.4 | 372.4 | 225.0 | 1.6 | 20.0 | 45.7 | 1.1 | 12.1 | 19.5 | 1.1 | 8.5 | 13.2 |
| (-0.95, 0.9) | 533.4 | 370.0 | 500.0 | 1.0 | 1.1 | 62.5 | 1.0 | 1.0 | 85.0 | 1.0 | 1.0 | 15.6 |
| (-0.95, 0.45) | 544.9 | 367.7 | 500.0 | 1.0 | 1.2 | 61.9 | 1.0 | 1.0 | 84.2 | 1.0 | 1.0 | 15.7 |
| (-0.95, 0) | 521.8 | 369.5 | 500.0 | 1.0 | 1.4 | 61.8 | 1.0 | 1.0 | 76.6 | 1.0 | 1.0 | 15.6 |
| (-0.95, -0.45) | 602.5 | 372.5 | 500.0 | 1.1 | 3.0 | 57.5 | 1.2 | 2.1 | 41.7 | 1.2 | 1.9 | 15.3 |
| (-0.95, -0.9) | 543.4 | 368.6 | 460.7 | 1.9 | 21.5 | 48.7 | 1.1 | 7.5 | 21.9 | 1.1 | 3.7 | 13.2 |
| 平均 | 475.3 | 371.7 | 306.7 | 6.1 | 26.1 | 49.7 | 2.8 | 13.0 | 32.8 | 2.0 | 7.7 | 15.1 |

的 ARL 均有高度显著的影响(P 值均小于 0.01)。在主因子效应中, ϕ 对于 ARL 的影响最大, 而 θ 对于 ARL 的影响则最小。此外, ARL 随着 s 的增大而减小, 至 $s=2$ 时, 平均 ARL 已减少至 2。

表 3 Hopfield 方法的 ARL 的混合效应模型方差分析

| 来源 | 自由度 | 平方和 | 均方 | F 值 | P 值 |
|------|----------------------|-----|---------|---------|-------------|
| 主因子 | ϕ | 4 | 1220.61 | 305.152 | 63.03 0.000 |
| | θ | 4 | 68.71 | 17.176 | 3.55 0.017 |
| | s | 2 | 240.32 | 120.158 | 24.82 0.000 |
| 交互作用 | $\phi \times \theta$ | 16 | 234.61 | 14.663 | 3.03 0.004 |
| | $\phi \times s$ | 8 | 462.16 | 57.769 | 11.93 0.000 |
| 误差 | $\theta \times s$ | 8 | 50.41 | 6.301 | 1.30 0.278 |
| | 总计 | 32 | 154.91 | 4.841 | |
| | | 74 | 2431.72 | | |

(3) 进一步计算可知, 对于 $\phi=0.95$ 以及 $\phi=-0.95$ 强自相关过程, 过程正常时 Hopfield 网络的平均 ARL 为 452.25, 高于 Elman 网络(371.2)和 EWMA 方法(283.2); 而过程异常时平均 ARL 为 6.4, 远低于 Elman 网络(ARL 为 23.4)和 EWMA 方法(ARL 为 37.4)。此外, 对于 $s=1$ 的小突变过程, Hopfield 方法的平均 ARL 仅为 6.1, 也远低于 Elman 网络(ARL 为 26.1)和 EWMA 方法(ARL 为 49.7), 说明方法对于强自相关和均值突变较小的过程的应用效果较为显著。

7 结束语

本文通过正交化编码将过程正常与异常的模式存储到 Hopfield 网络中, 并通过网络的联想功能来检测自相关过程的阶跃型突变, 为自相关过程的统计控制提供了一种新的解决方

法。应用 Hopfield 网络进行自相关过程控制时, 只需对吸引子进行合理编码并存储即可确定网络权值, 网络训练简单, 避免了前馈网络在训练时易出现的“过学习”、局部最小等问题。算例研究表明, 在过程正常或异常的情况下, 本文所提方法的灵敏度与可靠性优于前馈型网络和 EWMA 方法。由于研究还处于初始阶段, 因此一些深层次的问题, 例如伪吸引子、编码方式对于 ARL 的影响, 渐进性突变的检测等等, 还需进行深入的研究, 这些都将是本文的努力方向。

参考文献:

- [1] 张敏, 何桢. 自相关过程的 x-bar 质量控制图[J]. 数理统计与管理, 2007(26): 96–100.
- [2] Lu C W, Reynolds M R. EWMA control chart for monitoring the mean and variance of autocorrelated processes[J]. Journal of Quality Technology, 1999(31): 166–188.
- [3] 孙静. 自相关过程的残差控制图[J]. 清华大学学报, 2002(42): 735–738.
- [4] Yang J H, Yang M S. A control chart pattern recognition system using a statistical correlation coefficient method[J]. Computers & Industrial Engineering, 2005(48): 205–221.
- [5] 孙学静, 刘飞. 自相关过程 SPC 控制及其 ARL 的 Monte-Carlo 分析[J]. 计算机工程与应用, 2007, 43(18): 194–195.
- [6] 何桢, 刘冬生. 神经网络方法在自相关过程控制中的应用[J]. 工业工程, 2006(9): 85–90.
- [7] Chiu C C, Chen M C, Lee K M. Shifts recognition in correlated process data using a neural networks[J]. International Journal of System Science, 2001(32): 137–143.

(下转 30 页)