

# 基于高阶累积量的 Hammerstein 模型记忆效应辨识

胡 啸 马 洪

(武汉国家光电实验室 武汉 430074) (华中科技大学电子与信息工程系 武汉 430074)

**摘 要** 旨在研究存在加性高斯噪声时, Hammerstein 模型的记忆效应辨识问题。在输入信号统计量和 Hammerstein 模型的无记忆非线性效应均未知的情况下, 利用模型输出信号的高阶累积量建立两种线性方程组, 并从理论上证明了两种线性方程组均具有唯一解; 提出将两个线性方程组结合使用的系数提取方法, 其过程不受 Hammerstein 模型的无记忆非线性模块影响。最后的仿真结果表明, 在高斯(有色或无色)噪声存在的情况下, 此类辨识方法比直接提取参数法具有更好的数值鲁棒性。

**关键词** 高阶累积量, Hammerstein 模型, 记忆效应, 非线性效应, 鲁棒性

**中图分类号** TN911.7 **文献标识码** A

## Higher-Order-Cumulant Based Memory Effect Identification of Hammerstein Model

HU Xiao MA Hong

(Wuhan National Laboratory for Optoelectronics, Wuhan 430074, China)

(Department of Computer Science and Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

**Abstract** This paper focused on memory effect identification of Hammerstein model in Gaussian noise. When input statistics and nonlinearity of Hammerstein are unknown, by using higher order cumulant of output signal, two sets linear equations were proposed to extract coefficients of linear block with memory. Theoretical derivation shows that those two sets of linear equations have unique solutions. They could be used alternately to identify the memory effect of Hammerstein model, and the identification process is not affected by memory-less nonlinear block. Finally, simulations verify that the new developments have higher performance than direct extraction method.

**Keywords** Higher-order-cumulant, Hammerstein model, Memory effect, Nonlinearity, Robustness

Hammerstein 非线性模型可以表示为非线性无记忆模块与线性记忆模块的级联, 具有结构简单、普适性较强等优点, 被广泛用于非线性系统的建模。由于非线性模型中的非线性无记忆效应和线性记忆效应相互耦合, 因此对记忆效应的辨识一直是非线性系统辨识的难点。基于信号高阶统计量的非线性系统辨识方法具有不依赖于输入信号时频分布特征的“盲”处理特性, 近年来逐渐得到人们的关注。使用高阶统计量对非线性系统记忆效应辨识的工作始于 P. Koukoulas 和 N. Kalouptsidis 的文章<sup>[1]</sup>, 他们将 GM 线性模型辨识的方法扩展于 Hammerstein 模型的辨识, 但是由于此方法对 Hammerstein 模型的线性模块与非线性模块不加区分地辨识, 因此其辨识步骤十分繁琐。

在此之前, 高阶统计量的方法主要用于线性模型的辨识, 主要可以分为: 封闭式方法、线性代数法和优化方法<sup>[2]</sup>。其中线性代数法因为具有计算简单、没有局部极值点和鲁棒性强等优点而得到广泛使用。例如, Giannakis 和 Mendel 首次利用输入/输出信号的统计量建立线性方程组以提取 MA 模型的参数<sup>[3]</sup>, 即著名的 GM 方程; Friedlander 和 Porat 在 GM 方

程的基础上提出了自适应的解法, 即 R-GM 方法<sup>[4]</sup>; Tugnait 重组了 GM 方程, 提出了利用线性代数的方法求解, 被称为 T-GM 方法<sup>[5]</sup>, 以上方法被统称为 RC(自相关-累积量)解法, 只适合存在白噪声的情况(高斯或非高斯), 而无法胜任在有噪声存在情况下的辨识。为此张贤达与张远声曾提出了基于高阶累积量的 FIR 滤波器辨识方法, 其利用线性代数的方法, 在加性高斯噪声存在的情况下提取模型参数, 被称之为 Zhang-zhang 算法<sup>[6]</sup>。

本文首先通过理论推导分析了 Hammerstein 模型输出信号的高阶累积量的特征, 结论表明 Zhang-zhang 算法可以扩展用于对模型线性记忆模块进行参数提取。理论推导结果表明, 线性记忆参数提取过程不受 Hammerstein 模型非线性无记忆模块的影响, 并且适用于有色高斯噪声存在的情况。多组仿真结果表明此方法具有较强的数值鲁棒性。

## 1 Hammerstein 模型输出累积量分析

Hammerstein 模型可以视为特殊的 Volterra 模型, 具有较好的普适性, 其表达式可以写为:

到稿日期: 2010-03-11 返修日期: 2010-06-07 本文受国家自然科学基金(10975056), 航天科技创新基金重点项目(CASC200904)和武汉光电国家实验室创新基金(Z080005)资助。

胡 啸(1984—), 男, 博士生, 主要研究方向为非线性信号处理等, E-mail: hx517@163.com; 马 洪(1966—), 男, 教授, 博士生导师, 主要研究方向为电磁场与微波技术、非线性信号处理等。

$$Z(n) = y(n) + \eta(n) \\ = \sum_{m=0}^M [h(m) \cdot (\sum_{k=1}^P a_k x^k(n-m))] + \eta(n) \quad (1)$$

式中,  $M$  和  $P$  分别代表了 Hammerstein 模型的记忆深度和非线性阶数,  $a_k$  和  $h(m)$  分别为无记忆非线性模块和线性记忆模块的系数。  $\eta(n)$  为加性高斯噪声。由式(1)可知, Hammerstein 模型可以表示为无记忆的幂级数模块和有记忆 FIR 滤波器模块的级联, 如图 1 所示。




图 1 Hammerstein 模型框图

将式(1)整理如下:

$$Z(n) = \sum_{m=0}^M [h(m) \cdot (\sum_{k=1}^P a_k x^k(n-m))] + \eta(n) \\ = \sum_{m=0}^M [h(m) \cdot A \cdot W(n-m)] + \eta(n) \\ = \sum_{m=0}^M [B(m) \cdot W(n-m)] + \eta(n)$$

其中:

1.  $A = [a_1, a_2, \dots, a_P]$  为无记忆非线性模块的系数向量。

2.  $W(n) = [x(n), x^2(n), \dots, x^P(n)]^T$  为输入向量, 上标  $T$  代表转置。

3.  $h(m), m=0, 1, \dots, M$  为待辨识的 FIR 滤波器系数;  $M$  为 FIR 滤波器阶数, 即 Hammerstein 模型的记忆深度;  $B(m) = h(m) \cdot A$ 。

首先做如下假设:

假设 1  $h(m) \equiv 0, \forall m > M$  或  $m < 0$ , 因此  $B(m) = [0, \dots, 0], \forall m > M$  或  $m < 0$ 。

假设 2  $\eta(n)$  为统计量未知的加性高斯噪声, 与输入信号  $x(n)$  相互独立。

假设 3  $h(0), h(M) \neq 0$ 。

若输入信号  $x(n)$  为稳定的零均值高阶白噪声, 则  $W(n)$  同样为高阶白噪声向量<sup>[7]</sup>。输入向量  $W(n)$  的  $K$  阶累积量 ( $K > 2$ ) 可以写为<sup>[8]</sup>:

$$c_{kW}(\tau_1, \tau_2, \dots, \tau_{k-1}) \\ = cum[W(n), W(n+\tau_1), \dots, W(n+\tau_{k-1})] \quad (2) \\ = \gamma_{kW} \cdot \delta(\tau_1, \tau_2, \dots, \tau_{k-1})$$

式中,  $\gamma_{kW}$  为  $P^k \times 1$  维向量; 令  $\gamma_{kW}(i_1, i_2, \dots, i_k)$  表示向量  $\gamma_{kW}$  中第  $(i_1-1)P^{k-1} + (i_2-1)P^{k-2} + \dots + i_k$  个元素, 则:

$$\gamma_{kW}(i_1, i_2, \dots, i_k) = \gamma_{kW}[(i_1-1)P^{k-1} + (i_2-1)P^{k-2} + \dots + i_k] \\ = cum[w_{i_1}(n), w_{i_2}(n), \dots, w_{i_k}(n)] \\ = cum[x^{i_1}(n), x^{i_2}(n), \dots, x^{i_k}(n)] \\ i_1, i_2, \dots, i_k = 1, \dots, P$$

由于加性高斯噪声  $\eta(n)$  大于 2 阶累积量恒为 0, 因此输出信号  $Z(n)$  的  $k$  阶累积量可以写为<sup>[7]</sup>:

$$c_{kZ}(\tau_1, \tau_2, \dots, \tau_{k-1}) = c_{ky}(\tau_1, \tau_2, \dots, \tau_{k-1}) \\ = [\sum_{i=0}^M B(i) \otimes B(i+\tau_1) \otimes \dots \otimes B(i+\tau_{k-1})] \cdot \gamma_{kW} \quad (3)$$

式中,  $\otimes$  表示 Kronecker 乘积。

此时, 对式(3)取累积量的特殊切片:

$$c_{ky}(0, 0, \dots, 0, m) = [\underbrace{\sum_{i=0}^M B^{(k-1)}(i) \otimes B(i+m)}_{1 \times P^k \text{ 维向量}}] \cdot \gamma_{kW} \quad (4)$$

其中:

$$B^{(k-1)}(i) = \underbrace{B(i) \otimes B(i) \otimes \dots \otimes B(i)}_{1 \times P^{k-1} \text{ 维向量}} \\ = h^{k-1}(i) \cdot \underbrace{A \otimes A \otimes \dots \otimes A}_{1 \times P^{k-1} \text{ 维向量}} = h^{k-1}(i) \cdot A^{(k-1)}$$

因此, 式(4)可以进一步写为:

$$c_{ky}(0, 0, \dots, 0, m) = [A^{(k)} \cdot \gamma_{kW}] \cdot \sum_{i=0}^M h^{k-1}(i) \cdot h(i+m) \quad (5a)$$

根据高阶累积量的对称性, 式(4)同样可以表示为:

$$c_{ky}(0, 0, \dots, 0, m) = [A^{(k)} \cdot \gamma_{kW}] \cdot \sum_{j=0}^M h^{k-1}(j-m) \cdot h(j) \quad (5b)$$

注意, 此时  $[A^{(k)} \cdot \gamma_{kW}]$  为标量。

## 2 Hammerstein 模型记忆深度的确定

作者曾提出了一种利用非线性对角元素乘积(NPODE)的方法来确定 Hammerstein 模型的记忆深度  $M$ , 将记忆深度确定问题转换为矩阵求秩问题。本节将其简述如下。

为简单起见, 令  $\bar{c}_{ky}(\tau, m) = c_{ky}(0, 0, \dots, \tau, m)$ 。首先观察一种特殊的矩阵: 利用  $\bar{c}_{ky}(0, m), m=1, \dots, M$  组成 Hankel 矩阵  $C$ :

$$C = \begin{bmatrix} \bar{c}_{ky}(0, 0) & \bar{c}_{ky}(0, 1) & \dots & \bar{c}_{ky}(0, M) \\ \bar{c}_{ky}(0, 1) & \dots & \bar{c}_{ky}(0, M) & 0 \\ \vdots & & & 0 \\ \bar{c}_{ky}(0, M) & 0 & \dots & 0 \end{bmatrix}$$

根据假设 1 和假设 3 可知:  $\bar{c}_{ky}(0, M) \neq 0$ , 并且由于  $C$  为上三角矩阵, 因此可以得出  $C$  为满秩矩阵, 且  $rank(C) = M+1$ 。

所以对于记忆深度的确定, 可以采用如下步骤:

步骤 1 选取记忆深度的扩展值  $M_e$ , 使  $M_e > M$ , 计算  $\bar{c}_{ky}(0, m), m=1, \dots, M_e$ ;

步骤 2 形成扩展的 Hankel 矩阵:

$$C_e = \begin{bmatrix} \bar{c}_{ky}(0, 0) & \bar{c}_{ky}(0, 1) & \dots & \bar{c}_{ky}(0, M_e) \\ \bar{c}_{ky}(0, 1) & \dots & \bar{c}_{ky}(0, M_e) & 0 \\ \vdots & & & 0 \\ \bar{c}_{ky}(0, M_e) & 0 & \dots & 0 \end{bmatrix}$$

由于  $\bar{c}_{ky}(0, m) = 0, \forall m > M$ , 扩展矩阵的秩  $C_e$  等于  $C$ , 因此通过求  $C_e$  的秩便可以得到 Hammerstein 模型的记忆深度:  $M = rank(C) - 1 = rank(C_e) - 1$ 。

矩阵  $C_e$  秩的确定等价于寻找使  $[-\bar{c}_{ky}(0, m)]^{m+1} \neq 0$  的最大  $m$  值, 即寻找  $[-\bar{c}_{ky}(0, m)]^{m+1}$  从非零值到零值跳变的位置作为记忆深度的值, 这种方法被称之为非线性对角元素乘积方法(Nonlinear-PODE); 同样可以将 Giannakis<sup>[9]</sup> 提出的线性模型定阶方法直接扩展用于记忆深度的确定, 即直接寻找使  $\bar{c}_{ky}(0, m) \neq 0$  的最大  $m$  值来得到模型的记忆深度, 但是由于实际数据长度有限, 且存在噪声干扰的情况下, 当  $m > M$  时  $\bar{c}_{ky}(0, m)$  并不严格等于零, 使得直接检验令  $\bar{c}_{ky}(0, m) \neq 0$  的最大正整数变得十分困难; 由于  $\bar{c}_{ky}(0, m), m=0, 1, \dots, M_e$

通常比较小,从而使得检验令 $[-\bar{c}_{ky}(0, m)]^{m+1} \neq 0$ 的最大正整数要容易得多,因此利用 NPODE 方法确定模型的记忆深度具有更强的鲁棒性。此外,将拐点定阶法<sup>[10]</sup>扩展用于 Hammerstein 模型确定记忆深度的基本思路为:利用矩阵  $C_c$  的相邻两个变化最大的奇异值位置来确定模型的阶数。3 种方法的结果将在仿真部分列出。

### 3 线性记忆模块参数提取

重新取累积量的特殊切片,并考虑到当  $m < 0$  或者  $m > M$  时  $h(m) \equiv 0$ ,可以得到:

$$\begin{aligned} \bar{c}_{ky}(m, M) &= h^{k-2}(0) \cdot h(M) \cdot h(m) \cdot [A^{(k)} \cdot \gamma_{kw}] \\ &= \frac{h(m)}{h(0)} \cdot \bar{c}_{ky}(0, M) \end{aligned}$$

不失一般性地假设  $h(0) = 1$ ,根据式(6)可以直接提取线性记忆模块的参数:

$$h(m) = \frac{\bar{c}_{ky}(M, m)}{\bar{c}_{ky}(M, 0)} \quad (6)$$

式(6)为作者在文献[7]中提出的直接算法在 Hammerstein 模型辨识中的扩展,当模型的无记忆非线性参数未知时可以直接提取线性模块的参数。此方法虽然简单,但是对样本累积量的估计误差太敏感,数值性能较差,并且当  $[A^{(k)} \cdot \gamma_{kw}]$  很小时,容易引发“病态”问题。因此可以进一步将式(6)代入式(5b)中,整理后得到:

$$\begin{aligned} \bar{c}_{ky}(0, m) \cdot \bar{c}_{ky}^{k-1}(M, 0) \\ = [A^{(k)} \cdot \gamma_{kw}] \cdot \sum_{j=0}^M \bar{c}_{ky}^{k-1}(M, j-m) \cdot h(j) \quad (7) \end{aligned}$$

令  $m = M$ ,并考虑到  $h(0) = 1$  和当  $m < 0$  或者  $m > M$  时  $c_{ky}(M, m) \equiv 0$ ,可以得到:

$$[A^{(k)} \cdot \gamma_{kw}] = \frac{\bar{c}_{ky}^2(M, 0)}{\bar{c}_{ky}(M, M)} \quad (8)$$

将式(8)代入式(7)得到:

$$\bar{c}_{ky}(0, m) \cdot \bar{c}_{ky}^{k-3}(M, 0) \cdot \bar{c}_{ky}(M, M) = \sum_{j=0}^M \bar{c}_{ky}^{k-1}(M, j-m) \cdot h(j) \quad (9)$$

尽管 Hammerstein 模型的无记忆非线性模块参数  $A$  及输入信号的统计量未知,但这并不影响记忆效应的辨识。

令:

$$T_1 = \begin{bmatrix} \bar{c}_{ky}^{k-1}(M, M) & & & 0 & & 0 \\ \bar{c}_{ky}^{k-1}(M, M-1) & \bar{c}_{ky}^{k-1}(M, M) & & 0 & & \\ \vdots & \vdots & & \ddots & & \\ \bar{c}_{ky}^{k-1}(M, 1) & \bar{c}_{ky}^{k-1}(M, 2) & \cdots & \bar{c}_{ky}^{k-1}(M, M) & & 0 \end{bmatrix}$$

$$T_2 = \begin{bmatrix} \bar{c}_{ky}^{k-1}(M, 0) & \bar{c}_{ky}^{k-1}(M, 1) & \cdots & \bar{c}_{ky}^{k-1}(M, M) \\ 0 & \bar{c}_{ky}^{k-1}(M, 0) & \cdots & \bar{c}_{ky}^{k-1}(M, M-1) \\ \vdots & & \ddots & \vdots \\ 0 & & & \bar{c}_{ky}^{k-1}(M, 0) \end{bmatrix}$$

$$H = [h(0), h(1), \dots, h(M)]^T$$

$$t_1 = \begin{bmatrix} \bar{c}_{ky}(-M, 0) \cdot \bar{c}_{ky}^{k-3}(M, 0) \cdot \bar{c}_{ky}(M, M) \\ \bar{c}_{ky}(-M+1, 0) \cdot \bar{c}_{ky}^{k-3}(M, 0) \cdot \bar{c}_{ky}(M, M) \\ \vdots \\ \bar{c}_{ky}(-1, 0) \cdot \bar{c}_{ky}^{k-3}(M, 0) \cdot \bar{c}_{ky}(M, M) \end{bmatrix}$$

$$t_2 = \begin{bmatrix} \bar{c}_{ky}(0, 0) \cdot \bar{c}_{ky}^{k-3}(M, 0) \cdot \bar{c}_{ky}(M, M) \\ \bar{c}_{ky}(1, 0) \cdot \bar{c}_{ky}^{k-3}(M, 0) \cdot \bar{c}_{ky}(M, M) \\ \vdots \\ \bar{c}_{ky}^{k-2}(M, 0) \cdot \bar{c}_{ky}(M, M) \end{bmatrix}$$

因此,式(9)的矩阵化形式可以表示为:

$$\begin{bmatrix} T_1 \\ T_2 \end{bmatrix} H = \begin{bmatrix} t_1 \\ t_2 \end{bmatrix}$$

$T_2$  为上三角矩阵,由于  $h(0), h(M) \neq 0$ ,因此其对角线元素的  $\bar{c}_{ky}^{k-1}(M, 0) \neq 0$ ,所以:

$$\text{rank}(T_2) = \text{rank}\left(\begin{bmatrix} T_1 \\ T_2 \end{bmatrix}\right) = M+1$$

因此  $H$  有唯一解。为满足归一化的假设,在利用 LS 方法求解  $H$  时,通常取  $\frac{\hat{h}(i) = h(i)}{h(0)}$  作为系数的最后估计值,这就是本文提出的第一种参数提取方法。

为进一步增强鲁棒性,将式(8)代入式(5a)可以得到另外一组线性方程,即第二种参数提取公式:

$$\frac{\bar{c}_{ky}(0, m) \cdot \bar{c}_{ky}(M, M)}{\bar{c}_{ky}(M, 0)} = \sum_{j=0}^M \bar{c}_{ky}(M, i+m) \cdot h^{k-1}(i)$$

同理,将其矩阵化后可以得到  $h^{k-1}(i)$  的唯一解,其同样可以通过  $\frac{h^{k-1}(i)}{h^{k-1}(0)}$  满足归一化的假设。当  $k-1$  为偶数时,可

以利用  $|\hat{h}(i)| = [h^{k-1}(i)/h^{k-1}(0)]^{1/k-1}$  得到归一化参数的绝对值,其符号采用式(6)所示的直接提取方法得到。

为了增强鲁棒性,建议两种方法同时使用,若算法 1 所得到的  $h(0)$  比算法 2 得到的  $\hat{h}^{k-1}(0)$  更加接近 1,则可以判断算法 1 的鲁棒性强于算法 2,反之则同样操作。

### 4 仿真分析

本节将通过两组仿真实验验证本文的算法对具有不同强度非线性 Hammerstein 模型辨识的鲁棒性。输入信号是均值为 0、方差为 1 的单边指数分布信号;加性高斯噪声  $\eta(n)$  的方差为 0.01。利用 Hammerstein 模型对输出信号的 3 阶累积量进行辨识,实验样本点数  $N = 4096$ ,仿真得到的数据为 20 次实验后得到的均值与方差。

为了描述 Hammerstein 的非线性强弱,定义系统的非线性强度 (Max Nonlinear Intensity, MND) 为  $\text{MND} = 20 \lg$

$\left(\frac{a_1}{\max_{k>1} |a_k|}\right)$ ,即当 Hammerstein 模型的非线性模块系数分别为  $A = [1 \ 0.001 \ -0.001]$  和  $A = [1 \ 0.05 \ -0.01]$  时, Hammerstein 模型的 MND 分别为 60dB 和 26dB。

#### 实验 1

令 Hammerstein 模型的记忆深度  $M$  为 3,其线性记忆模块的传输函数为:

$$y(n) = g(n) + 0.9 \cdot g(n-1) + 0.385 \cdot g(n-2) - 0.771 \cdot g(n-3)$$

式中,  $g(n)$  为线性记忆模块的输入。

为简单起见,本文仅对实验 1 的记忆深度确定进行仿真,其数据如表 1 所列。表 2 列举了在 Hammerstein 模型的 MND 分别为 60dB 和 26dB 时,直接计算方法与本文新提出的两种方法的参数提取情况。

#### 实验 2

令 Hammerstein 模型的记忆深度  $M$  为 5,其线性记忆模块的传输函数为:

$$y(n) = g(n) - 2.33 \cdot g(n-1) + 0.75 \cdot g(n-2) + 0.5 \cdot g(n-3) + 0.3 \cdot g(n-4) - 1.4 \cdot g(n-5)$$

表 3 列举了同样非线性强度情况下实验 2 的数据。

表 1 对实验 1 进行记忆深度辨识的数据  
(格式为均值±标准差)

MND	m	$\bar{c}_{ky}(0, m)$	$[-\bar{c}_{ky}(0, m)]^{m+1}$	$C_c$ 的奇异值
60dB	0	2.5266±0.1874	2.5266±0.1874	4.0808±0.0899
	1	2.0914±0.1267	4.3898±0.5329	2.1532±0.0476
	2	-0.4524±0.0649	-0.0982±0.0412	0.7213±0.0368
	3	-1.4744±0.0982	4.8515±1.3160	0.5971±0.0460
	4	-0.0061±0.0622	0.0000±0.0000	0.0130±0.0117
	5	-0.0033±0.0730	0.0000±0.0000	0.0029±0.0032
26dB	0	2.6703±0.1773	2.6703±0.1773	4.0597±0.2187
	1	2.2092±0.1107	4.8925±0.4901	2.1555±0.1068
	2	-0.4831±0.0777	-0.1214±0.0560	0.7181±0.0571
	3	-1.5508±0.0944	5.9139±1.4789	0.6125±0.0829
	4	0.0013±0.0573	0.0000±0.0000	0.0051±0.0066
	5	-0.0095±0.0577	0.0000±0.0000	0.0020±0.0032
	6	-0.0093±0.0631	0.0000±0.0000	0.0002±0.0005

表 2 对实验 1 进行参数提取的数据  
(格式为均值±标准差)

MND	真实系数	直接算法	算法 1	算法 2
60dB	h(1)=0.9	0.8903±0.0047	0.8998±0.0074	0.9347±0.005
	h(2)=0.385	0.3796±0.0047	0.3986±0.0066	0.3991±0.0014
	h(3)=-0.771	-0.7708±0.0083	-0.762±0.0081	-7.7899±0.0014
26dB	h(1)=0.9	0.9266±0.004	0.9205±0.0111	0.9051±0.003
	h(2)=0.385	0.3993±0.0057	0.4354±0.0141	0.3598±0.002
	h(3)=-0.771	-0.7643±0.0121	-0.8135±0.0127	-0.7648±0.0008

表 3 对实验 2 进行参数提取的数据  
(格式为均值±标准差)

MND	真实系数	直接算法	算法 1	算法 2
60dB	h(1)=-2.33	-2.594±0.5316	-2.3233±0.0697	-2.714±0.8045
	h(2)=0.75	0.8732±0.131	0.8011±0.1349	1.0244±0.497
	h(3)=0.5	0.5905±0.0834	0.4665±0.0704	0.5728±0.108
	h(4)=0.3	0.34601±0.048	0.3618±0.0147	0.3703±0.2302
	h(5)=-1.4	-1.626±0.392	-1.4653±0.0490	-1.678±0.738
26dB	h(1)=-2.33	-2.7548±0.5933	-2.4235±0.12053	-2.4095±0.1071
	h(2)=0.75	0.95157±0.429	0.8754±0.12131	0.7783±0.1027
	h(3)=0.5	0.6066±0.11854	0.49135±0.0423	0.4956±0.0453
	h(4)=0.3	0.29231±0.0295	0.32538±0.0372	0.33565±0.1522
	h(5)=-1.4	-1.6346±0.8586	-1.4914±0.1355	-1.4933±0.120

通过对表 1 分析可知,当  $m$  由 3 变为 4 时,3 种方法得到的数据的均值都趋于 0,因此可以判断 Hammerstein 记忆深度  $M=4-1$ ;而当  $m>3$  时,  $[-\bar{c}_{ky}(0, m)]^{m+1}$  (NPODE 方法的数据)比其余两类方法的数据更加接近于 0,由此可以得出,就鲁棒性而言,NPODE 方法是最优的。

由表 2 可知,当 Hammerstein 模型的记忆深度为 3 时,算法 1 和算法 2 得到的数据中,总有一组数据的均值比直接计

算方法更加接近真实系数的均值,且具有更小的方差,但是这样的差异表现并不十分明显。从表 3 的数据可知,当记忆深度增加至 5 时,算法 1 或者算法 2 得到的数据较直接计算方法具有明显的优势(均值比直接计算方法更加接近真实值,方差更接近 0)。此结果表明,当记忆深度逐渐增加时,本文提出的方法比直接计算方法的鲁棒性更强。

**结束语** 本文研究了在加性高斯噪声存在的情况下,利用高阶统计量对 Hammerstein 模型的记忆效应进行辨识的方法。在输入信号统计量和无记忆非线性效应未知的情况下,仅仅利用 Hammerstein 模型输出信号的高阶累积量,建立两种线性方程组;理论证明,两种线性方程组均具有唯一解,可以组合使用以提取线性记忆模块的系数,并且系数提取过程不受 Hammerstein 模型的无记忆非线性模块影响。最后的仿真结果表明,在高斯(有色或无色)噪声存在情况下,此类辨识方法比直接提取参数法具有更好的数值鲁棒性。

### 参考文献

- [1] Koukoulas P, Kalouptsidis N. Blind identification of second order Hammerstein series [J]. Signal Processing, 2003, 83(1): 213-234
- [2] 邱天爽, 张旭秀, 李小兵. 统计信号处理[M]. 北京: 电子工业出版社, 2004: 79
- [3] Giannakis G B, Mendel J M. Identification of nonminimum phase systems using higher order statistics[J]. IEEE Trans. on Acoustics, Speech, Signal Processing, 1989, 37: 360-377
- [4] Friedland B, Porat B. Adaptive IIR algorithms based on high order statistics[J]. IEEE Trans. on Acoustics, Speech, Signal Processing, 1989, 37: 485-485
- [5] Tugnait. New results on FIR system identification using higher-order statistics[J]. IEEE Trans. on Signal Processing, 1991, 39: 2216-2221
- [6] Zhang X D, Zhang Y S. FIR system identification using higher order cumulants alone[J]. IEEE Trans. on Signal Processing, 1994, 42(10): 2854-2858
- [7] Kalouptsidis N, Koukoulas P. Blind Identification of Volterra-Hammerstein Systems [J]. IEEE trans on signal processing, 2005, 53: 2777-2787
- [8] 张贤达. 时间序列分析-高阶统计量方法[M]. 北京: 清华大学出版社, 1996: 281
- [9] Giannakis G B, Mendel J M. Cumulant-based order determination of non-Gaussian ARMA models[J]. IEEE Trans. on Acoustics, Speech, Signal Processing, 1990, 38: 1411-1422
- [10] 王少水, 戴永寿. 参数化地震子波估计模型定阶方法研究综述[J]. 地球物理学进展, 2009, 24(4): 1405-1410

(上接第 178 页)

- [3] McDermott D, Hendler J. Planning: What it is, what it could be, an introduction to the special issue on planning and scheduling [J]. Journal of Artificial Intelligence, 1995, 76: 1-16
- [4] Boutilier C, Brafman R, Domshlak C, et al. Preference-based constrained optimization with CP-Nets[J]. Journal of Computational Intelligence, 2004, 20(2): 137-157
- [5] Blum A L, Furst M L. Fast planning through planning graph analysis[J]. Journal of Artificial Intelligence, 1997, 90: 281-300
- [6] Do MB, Kambhampati S. Solving planning-graph by compiling it into CSP[C]//Proceedings of the 5th International Conference

- on Artificial Intelligence Planning and Scheduling(AIPS). 2000: 82-91
- [7] 雍分. 基于知识的钢铁材料智能设计系统开发和应用[D]. 北京: 中国科学院计算技术研究所, 2009
- [8] Gruber T R. Towards principles for the design of ontologies used for knowledge sharing[J]. International Journal of Human-Computer Studies, 1993, 43: 907-928
- [9] Cao Cun-gen, Feng Qiang-ze, Gao Yin, et al. Progress in the development of national knowledge infrastructure[J]. Journal of Computer Science and Technology, 2002, 17(5): 1-16
- [10] 顾芳. 多学科领域本体的设计方法研究[D]. 北京: 中国科学院计算技术研究所, 2005