

文章编号: 1001-0920(2008)09-0999-05

基于辅助模型的多新息广义增广随机梯度算法

王冬青¹, 丁 锋²

(1. 青岛大学 自动化工程学院, 山东 青岛 266071; 2. 江南大学 控制科学与工程研究中心, 江苏 无锡 214122)

摘 要: 将辅助模型辨识思想与多新息辨识理论相结合, 利用系统可测信息建立一个辅助模型, 分别用辅助模型输出和噪声估计值代替辨识模型信息向量中未知真实输出变量和不可测噪声项, 并引入新息长度扩展标量新息为新息向量, 提出了 Box-Jenkins 模型的辅助模型多新息广义增广随机梯度辨识方法. 所提出方法重复使用系统数据, 能够改善参数估计精度, 加快算法的收敛速度.

关键词: 参数估计; 递推辨识; 随机梯度; 辅助模型; Box-Jenkins 模型; 多新息辨识

中图分类号: TP271 **文献标识码:** A

Auxiliary models based multi-innovation generalized extended stochastic gradient algorithms

WANG Dong-qing¹, DING Feng²

(1. College of Automation Engineering, Qingdao University, Qingdao 266071, China; 2. Control Science and Engineering Research Center, Jiangnan University, Wuxi 214122, China. Correspondent: WANG Dong-qing, E-mail: dqwang64@163.com)

Abstract: Combining the auxiliary model identification idea with the multi-innovation identification theory, this paper establishes an auxiliary model by using the measurable data of Box-Jenkins systems, replaces the unknown noise-free outputs and noise terms in the information vector with the outputs of the auxiliary model and the estimated noise terms, and presents an auxiliary model based multi-innovation generalized extended stochastic gradient (AM-MF-GESG) algorithm for Box-Jenkins models by introducing the innovation length and expanding the scalar innovation to an innovation vector. The proposed algorithm repeatedly utilizes the available input-output data, and can improve the parameter estimation accuracy and speed up the convergence rate of the algorithms.

Key words: Parameter estimation; Recursive identification; Stochastic gradient; Auxiliary model; Box-Jenkins models; Multi-innovation identification

1 引 言

考虑下列 Box-Jenkins 模型的辨识问题(见图 1):

$$y(t) = \frac{B(z)}{A(z)} u(t) + \frac{D(z)}{C(z)} v(t). \quad (1)$$

其中: $\{u(t)\}$ 和 $\{y(t)\}$ 分别为系统的输入和输出序列; $\{v(t)\}$ 为零均值、不相关随机白噪声序列(不可测); $A(z)$, $B(z)$, $C(z)$ 和 $D(z)$ 均为单位后移算子 z^{-1} 的多项式 $[z^{-1}y(t) = y(t-1)]$, 且

$$A(z) = 1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_{n_a} z^{-n_a},$$

$$B(z) = b_1 z^{-1} + b_2 z^{-2} + \dots + b_{n_b} z^{-n_b},$$

$$C(z) = 1 + c_1 z^{-1} + c_2 z^{-2} + \dots + c_{n_c} z^{-n_c},$$

$$D(z) = 1 + d_1 z^{-1} + d_2 z^{-2} + \dots + d_{n_d} z^{-n_d}.$$

不妨设当 $t=0$ 时, $u(t)=0, y(t)=0, v(t)=0$, 且阶次 n_a, n_b, n_c 和 n_d 已知. 图 1 中, $x(t)$ 是系统模型的输出(即不可测无噪输出或真实输出), $w(t)$ 是噪声模型的输出(不可测), $y(t)$ 是 $x(t)$ 的含噪量测.




图 1 Box-Jenkins 模型

收稿日期: 2007-12-10; 修回日期: 2008-05-06.

基金项目: 国家自然科学基金项目(60574051, 60673101).

作者简介: 王冬青(1964—), 女, 山东即墨人, 副教授, 博士, 从事系统辨识、过程控制的研究; 丁锋(1963—), 男, 湖北广水人, 教授, 博士生导师, 从事系统建模、系统辨识等研究.

本文的目标是：推导基于辅助模型的多新息广义增广随机梯度 (AM-MF GESG) 算法, 利用系统输入输出数据 $\{u(t), y(t) : t = 1, 2, \dots\}$ 来估计系统 (1) 的参数 a_i, b_i, c_i 和 d_i , 并进行仿真研究.

对于比模型 (1) 简单的 ARX 模型、ARMAX 模型、输出误差模型等, 有多种辨识方法可以估计其参数. 如递推最小二乘法^[11]、递推增广最小二乘法^[11]、偏差补偿最小二乘法^[2-4] 等. 文献[5] 基于残差自相关检验准则, 给出了 Box-Jenkins 模型阶次和时滞的确定方法; [6] 基于信息压缩阵的 UD 分解技术和广义增广最小二乘原理, 提出一种 Box-Jenkins 模型阶次与参数同时估计的递推算法, 但是算法中存在矩阵求逆运算, 计算量较大; [7, 8] 推导了偏差补偿最小二乘辨识算法及其递推算法; [1, 9] 提出了另一种形式的 Box-Jenkins 模型递推广义增广最小二乘算法.

辅助模型辨识方法^[10, 11] 和多新息辨识方法^[12-15] 是近年来提出的新颖辨识方法, 不少国际期刊都刊登了这方面的文章. 如双率采样数据系统的辅助模型最小二乘辨识方法^[10] 和辅助模型随机梯度算法^[11], 多输入单输出系统辅助模型多新息最小二乘算法^[14], 非线性输出误差系统的辅助模型最小二乘算法^[16] 等. 多新息随机梯度辨识方法是在充分使用系统数据的基础上, 通过扩展新息长度而提出的新方法, 已应用于方程误差模型 (即白噪声干扰 ARX 模型) 的辨识. 它能提高参数估计收敛速度和辨识精度^[12], 但要求辨识模型信息向量各元都是可测的.

本文将多新息辨识理论加以推广, 用于研究有色噪声干扰的 Box-Jenkins 模型的辨识. Box-Jenkins 模型辨识的困难在于: 信息向量中既包含不可测中间变量 (称为不可测真实输出或无噪输出), 又包含不可测噪声项. 本文通过使用辅助模型技术^[10], 用系统的可测信息建立一个辅助模型, 用辅助模型的输出代替系统的未知真实输出变量, 用估计的噪声值代替信息向量中不可测噪声项, 并通过扩展新息长度, 提出了 AM-MF GESG 辨识方法.

基于辅助模型的 AM-MF GESG 辨识方法的意义在于: 既能克服偏差补偿最小二乘算法和辅助模型最小二乘算法由于需要计算协方差矩阵而产生的计算量大的缺点, 又能保留辅助模型随机梯度辨识算法不需要矩阵求逆运算的优点, 从而加快了辅助模型随机梯度辨识算法的收敛速度.

2 算法推导

文献[14] 针对多输入单输出的输出误差系统, 提出了基于辅助模型的多新息最小二乘方法, 且量

测噪声为白噪声情形. 这里把这种方法加以推广, 用于研究量测噪声为有色噪声的 Box-Jenkins 模型的辨识, 并推导相应的 AM-MF GESG 辨识算法.

首先引入符号“ $A = : X$ ”或“ $X = : A$ ”, 表示“ A 记作 (定义为) X ” (因为符号 \triangleq 或 $\stackrel{\text{def}}{=}$ 没有左右之分, 含义模糊).

参照图 1, 定义中间不可测变量

$$x(t) = \frac{B(z)}{A(z)} u(t), \quad (2)$$

$$w(t) := \frac{D(z)}{C(z)} v(t). \quad (3)$$

由式 (1) 可得

$$y(t) = x(t) + w(t). \quad (4)$$

由此可以看出, $y(t)$ 是 $x(t)$ 的含噪量测.

定义系统模型参数向量和噪声模型参数向量分别为

$$s = [a_1, a_2, \dots, a_{n_a}, b_1, b_2, \dots, b_{n_b}]^T \quad R^{n_a+n_b},$$

$$n = [c_1, c_2, \dots, c_{n_c}, d_1, d_2, \dots, d_{n_d}]^T \quad R^{n_c+n_d};$$

信息向量

$$s(t) = [-x(t-1), \dots, -x(t-n_a),$$

$$u(t-1), \dots, u(t-n_b)]^T \quad R^{n_a+n_b},$$

$$n(t) = [-w(t-1), \dots, -w(t-n_c),$$

$$v(t-1), \dots, v(t-n_d)]^T \quad R^{n_c+n_d}.$$

其中下标 s 和 n 分别表示系统模型和噪声模型. 于是式 (2) 和 (3) 可写成向量形式

$$x(t) = s^T(t) s, \quad (5)$$

$$w(t) = n^T(t) n + v(t). \quad (6)$$

式 (5) 和 (6) 代入式 (4), 得

$$y(t) = s^T(t) s + n^T(t) n + v(t) =$$

$$\begin{bmatrix} s^T(t) & n^T(t) \end{bmatrix} \begin{bmatrix} s \\ n \end{bmatrix} + v(t) = \begin{bmatrix} s^T(t) & n^T(t) \end{bmatrix} \begin{bmatrix} s \\ n \end{bmatrix} + v(t). \quad (7)$$

其中

$$\begin{bmatrix} s \\ n \end{bmatrix} \in R^n, \quad (t) = \begin{bmatrix} s(t) \\ n(t) \end{bmatrix} \in R^n,$$

$$n = n_a + n_b + n_c + n_d.$$

引入二次型准则函数^[11]

$$J(\cdot) = E[y(t) - \hat{y}(t)]^2,$$

其中矩阵范数定义为 $\|X\|^2 = \text{tr}[XX^T]$. 令 $\hat{y}(t)$ 表示 t 时刻的估计, 极小化 $J(\cdot)$ 得到递推广义增广随机梯度算法 (GESG)^[11] 如下:

$$\hat{y}(t) = \hat{y}(t-1) + \frac{r(t)}{r(t)} [y(t) -$$

$$\hat{y}(t-1)], \quad (8)$$

$$r(t) = r(t-1) + \frac{1}{r(t)}, \quad r(0) = 1. \quad (9)$$

然而, 因为信息向量 (t) 中含有未知变量 $x(t-i)$,

不可测相关噪声项 $w(t-i)$ 和不可测白噪声项 $v(t-i)$, 所以上述常规随机梯度算法 (8) 和 (9) 无法实现. 即常规随机梯度算法无法辨识 Box-Jenkins 模型 (1) 的参数. 本文的解决方案是: 基于辅助模型辨识的思想^[10], 构造一个辅助模型, 如图 2 所示. 其中 $P_a(z) = B_a(z)/A_a(z)$ 为辅助模型的传递函数, $A_a(z)$ 和 $B_a(z)$ 是与 $A(z)$ 和 $B(z)$ 同阶次的多项式; $x_a(t)$ 为辅助模型的输出. 信息向量 $s(t)$ 中未知项 $x(t-i)$ 用辅助模型的输出 $x_a(t-i)$ 代替, 代替后的 $s(t)$ 记为

$$\hat{s}(t) = [-x_a(t-1), \dots, -x_a(t-n_a), u(t-1), \dots, u(t-n_b)]^T. \quad (10)$$




图 2 带辅助模型 Box-Jenkins 模型

信息向量 $s(t)$ 的 $n(t)$ 中未知残差 $v(t-i)$ 用估计残差 $\hat{v}(t-i)$ 代替, 相关噪声项 $w(t-i)$ 用其估计 $\hat{w}(t-i)$ 代替, 代替后的 $s(t)$ 记为

$$\hat{s}_n(t) = [-\hat{v}(t-1), \dots, -\hat{v}(t-n_c), \hat{w}(t-1), \dots, \hat{w}(t-n_d)]^T. \quad (11)$$

由图 2 可知

$$x_a(t) = \frac{B_a(z)}{A_a(z)} u(t).$$

仿照式 (2) 和 (5) 的方式, 把它写成向量形式, 有

$$x_a(t) = \hat{a}_a^T(t) a_a,$$

其中 $\hat{a}_a(t)$ 和 a_a 分别是辅助模型的信息向量和参数向量. 辅助模型的信息向量和参数向量有多种选择方法. 参照文献 [10], 本文把 $\hat{s}_s(t)$ 作为辅助模型的信息向量 $\hat{a}_a(t)$, 把 $\hat{s}_s(t)$ 作为辅助模型的参数向量 a_a , 则有

$$x_a(t) = \hat{s}_s^T(t) \hat{s}_s(t). \quad (12)$$

用 $\hat{s}_s(t)$ 和 $\hat{s}_n(t)$ 代替 $s(t)$ 中 (未知的) $s(t)$ 和 $n(t)$, 代替后记为

$$\hat{s}(t) = \begin{bmatrix} \hat{s}_s(t) \\ \hat{s}_n(t) \end{bmatrix} = [-x_a(t-1), \dots, -x_a(t-n_a), u(t-1), \dots, u(t-n_b), -\hat{v}(t-1), \dots, -\hat{v}(t-n_c), \hat{w}(t-1), \dots, \hat{w}(t-n_d)] \in R^n. \quad (13)$$

由式 (7) 可得

$$v(t) = y(t) - \hat{s}^T(t) \theta.$$

上式中未知的 $\theta(t)$ 用 $\hat{\theta}(t)$ 代替, 用其估计 $\hat{\theta}(t)$ 代替. 于是残差 $\hat{v}(t)$ 可通过下式计算:

$$\hat{v}(t) = y(t) - \hat{s}^T(t) \hat{\theta}(t). \quad (14)$$

由式 (4) 可得

$$w(t) = y(t) - x(t).$$

式中未知的 $x(t)$ 用 $x_a(t) = \hat{s}_s^T(t) \hat{s}_s(t)$ 代替, 可得到 $w(t)$ 的估计值

$$\hat{w}(t) = y(t) - \hat{s}_s^T(t) \hat{s}_s(t). \quad (15)$$

有了上述准备后, 定义和极小化准则函数

$$J(\hat{\theta}) = E[y(t) - \hat{s}^T(t) \hat{\theta}]^2,$$

可得到估计 $\hat{\theta}$ 的基于辅助模型的 (单新息) 广义增广随机梯度辨识算法 (AM-GESG) 如下:

$$\hat{\theta}(t) = \hat{\theta}(t-1) + \frac{\hat{v}(t)}{r(t)} e(t), \quad (16)$$

$$e(t) = y(t) - \hat{s}^T(t) \hat{\theta}(t-1), \quad (17)$$

$$r(t) = r(t-1) + \hat{v}^2(t), \quad r(0) = 1. \quad (18)$$

式 (17) 中 $e(t) = y(t) - \hat{s}^T(t) \hat{\theta}(t-1)$ R^1 是标量单新息, 经典最小二乘法和随机梯度法等都是使用单新息辨识方法.

尽管上述辅助模型随机梯度算法 (16) ~ (18) 可以估计 $\hat{\theta}$, 但是算法的收敛速度很慢 (参见后面的仿真例子). 下面借助于文献 [12] 的多新息辨识理论, 通过扩展新息维数, 导出基于辅助模型的 AM-MF-GESG 算法, 以提高算法的收敛速度和参数估计精度. 具体作法如下:

把标量新息 (单新息) $e(t) = y(t) - \hat{s}^T(t) \hat{\theta}(t-1)$

1) R^1 扩展为向量新息

$$E(p, t) = \begin{bmatrix} y(t) - \hat{s}^T(t) \hat{\theta}(t-1) \\ y(t-1) - \hat{s}^T(t-1) \hat{\theta}(t-1) \\ \dots \\ y(t-p+1) - \hat{s}^T(t-p+1) \hat{\theta}(t-1) \end{bmatrix},$$

即多新息, 其中正整数 p 表示新息长度.

定义堆积向量 $Y(p, t)$ 和堆积信息矩阵 $\Phi(p, t)$ 为

$$Y(p, t) = [y(t), y(t-1), \dots, y(t-p+1)]^T \in R^p, \quad \Phi(p, t) = [\hat{s}^T(t), \hat{s}^T(t-1), \dots, \hat{s}^T(t-p+1)] \in R^{n \times p}.$$

则辨识 Box-Jenkins 模型的 AM-MF-GESG 算法可表达如下:

$$\hat{\theta}(t) = \hat{\theta}(t-1) + \frac{\Phi(p, t)}{r(t)} E(p, t), \quad (19)$$

$$E(p, t) = Y(p, t) - \Phi^T(p, t) \hat{\theta}(t-1), \quad (20)$$

$$r(t) = r(t-1) + \hat{v}^2(t), \quad r(0) = 1, \quad (21)$$

$$\Phi(p, t) =$$

$$[\hat{y}(t), \hat{y}(t-1), \dots, \hat{y}(t-p+1)], \quad (22)$$

$$Y(p, t) = [y(t), y(t-1), \dots, y(t-p+1)]^T, \quad (23)$$

$$\hat{y}(t) = \begin{bmatrix} \hat{y}_s(t) \\ \hat{y}_n(t) \end{bmatrix}, \quad \hat{y}(t) = \begin{bmatrix} \hat{y}_s(t) \\ \hat{y}_n(t) \end{bmatrix}, \quad (24)$$

$$\hat{y}_s(t) = [-x_a(t-1), \dots, -x_a(t-n_a), u(t-1), \dots, u(t-n_b)]^T, \quad (25)$$

$$\hat{y}_n(t) = [-\hat{w}(t-1), \dots, -\hat{w}(t-n_c), \hat{w}(t-1), \dots, \hat{w}(t-n_d)]^T, \quad (26)$$

$$x_a(t) = \hat{y}_s^T(t) \hat{y}_s(t), \quad (27)$$

$$\hat{w}(t) = y(t) - x_a(t), \quad (28)$$

$$\hat{w}(t) = y(t) - \hat{y}^T(t) \hat{y}(t). \quad (29)$$

当新息长度 $p = 1$ 时, AM-MF GESG 算法退化为 AM- GESG 算法.

算法的收敛性证明可仿照双率系统的基于辅助模型(单信息)随机梯度算法的收敛性证明, 参见文献[11].

3 计算量比较

为了说明所提出算法的计算效率, 将辨识模型(1)的 AM-RGELS 算法、AM-MF GESG 算法和 AM- GESG 算法的每步递推计算的乘法次数(包括除法次数)和加法次数(包括减法次数)加以比较, 计算量如表 1 所示. 其中方括号内数据是 $n_a = n_b =$

表 1 算法计算量的比较

算 法	乘法次数	加法次数
AM-RGELS	$2n^2 + 5n[592]$	$2n^2 + 3n[560]$
AM-MF GESG	$2pn + 3n$	$2pn + 2n$
$p = 1$	[80]	[64]
$p = 3$	[144]	[128]
$p = 5$	[208]	[192]
AM- GESG	$5n[80]$	$4n[64]$

$n_c = n_d = 4$ 时的计算次数.

从表 1 可以看出, AM-MF GESG 算法的计算量与 p 值的大小有关. 当 p 较小时(如例子中 $p = 3, p = 5$), AM-MF GESG 算法尽管比相应的单新息 AM- GESG 算法计算量要大些, 但收敛速度更快(参见后面例子); 然而, AM-MF GESG 算法的计算量比最小二乘算法要小. 仿真例子中当 $p = 5$ 时, 算法既有较小的计算量, 又能大大提高梯度算法的收敛速度.

文献[12]指出, 多新息随机梯度算法通过增加新息长度来提高辨识精度(例子中 $p = 5$ 时算法收敛速度有明显提高), 多新息算法比单新息算法($p = 1$)需额外付出的计算量不大(参见式(16), (17)与式(19), (20)的差别), 计算量只是变化为一个矩阵与向量的乘积, 现代计算机完全可以胜任.

表 2 Box-Jenkins 模型参数估计及其误差($\sigma^2 = 0.10^2, \sigma_s = 16.24\%$)

p	t	a_1	a_2	b_1	b_2	c_1	c_2	d_1	d_2	/ %
$p = 1$	100	-0.04881	0.08562	0.12698	0.40743	-0.11763	0.02964	0.11568	-0.02665	70.42714
	200	-0.07105	0.09249	0.13785	0.43818	-0.12245	0.03647	0.12152	-0.03191	67.76959
	500	-0.10018	0.10178	0.15003	0.47021	-0.12508	0.04587	0.12572	-0.03954	64.62809
	1000	-0.12314	0.10868	0.15331	0.49261	-0.12611	0.05251	0.12799	-0.04519	62.42875
	2000	-0.14228	0.11466	0.16036	0.50636	-0.12631	0.05651	0.12887	-0.04854	60.73476
	3000	-0.15407	0.11890	0.16333	0.51340	-0.12603	0.05928	0.12912	-0.05093	59.69575
$p = 3$	100	-0.27410	0.28261	0.16783	0.51232	-0.23178	0.05537	0.21494	-0.03887	49.31370
	200	-0.31193	0.28409	0.17522	0.51534	-0.22981	0.06043	0.21465	-0.04275	47.46275
	500	-0.35062	0.28866	0.17932	0.52040	-0.22686	0.06597	0.21367	-0.04722	45.81388
	1000	-0.37262	0.29185	0.17751	0.52077	-0.22507	0.06879	0.21291	-0.04958	45.02162
	2000	-0.38625	0.29747	0.17884	0.51697	-0.22276	0.07063	0.21123	-0.05104	44.45806
	3000	-0.39354	0.30088	0.17977	0.51502	-0.22144	0.07209	0.21051	-0.05242	44.15511
$p = 5$	100	-0.48969	0.39570	0.17674	0.50308	-0.36881	0.14614	-0.08577	-0.23744	6.30673
	200	-0.48359	0.38389	0.17907	0.49759	-0.36880	0.14596	-0.08599	-0.23839	4.92751
	500	-0.47957	0.36989	0.18088	0.50397	-0.36843	0.14732	-0.08606	-0.23983	3.65612
	1000	-0.47406	0.36298	0.18147	0.50109	-0.36911	0.14707	-0.08561	-0.23970	2.91801
	2000	-0.47068	0.36126	0.18123	0.49845	-0.36878	0.14694	-0.08639	-0.23927	2.58293
	3000	-0.46835	0.35978	0.18103	0.49711	-0.36870	0.14745	-0.08633	-0.23979	2.43166
真 值		-0.46000	0.35000	0.18000	0.50000	-0.36000	0.14000	-0.10000	-0.24000	

4 仿真例子

考虑仿真对象

$$y(t) = \frac{B(z)}{A(z)} u(t) + \frac{D(z)}{C(z)} v(t),$$

$$A(z) = 1 + a_1 z^{-1} + a_2 z^{-2} = 1 - 0.46z^{-1} + 0.35z^{-2},$$

$$B(z) = b_1 z^{-1} + b_2 z^{-2} = 0.18z^{-1} + 0.50z^{-2},$$

$$C(z) = 1 + c_1 z^{-1} + c_2 z^{-2} = 1 - 0.36z^{-1} + 0.14z^{-2},$$

$$D(z) = 1 + d_1 z^{-1} + d_2 z^{-2} = 1 - 0.10z^{-1} - 0.24z^{-2},$$

$$= [a_1, a_2, b_1, b_2, c_1, c_2, d_1, d_2]^T = [-0.46, 0.35, 0.18, 0.50, -0.36, 0.14, -0.10, -0.24]^T.$$

仿真时,输入 $\{u(t)\}$ 采用零均值、单位方差、不相关可测随机信号序列, $\{v(t)\}$ 采用零均值方差 $\sigma^2 = 0.10^2$ 的随机白噪声序列,对应的系统噪声比 $\sigma = 16.24\%$. 取数据长度 $L = 3000$,在不同新息长度 $p = 1, 3, 5$ 下,用 AM-MF-GESG 算法分别进行参数估计. 估计结果及其误差如表 2 所示;参数估计误差 $\delta = \hat{\theta}(t) - \theta / \theta$ 随 t 变化曲线如图 3 所示.




图 3 参数估计误差 随数据长度 t 变化曲线

从表 2 和图 3 可以得出结论: 基于辅助模型的多新息随机梯度辨识算法 ($p > 1$), 比相应的单新息辨识算法 ($p = 1$) 有更快的收敛速度和更高的参数辨识精度;随着新息长度的增大, 辨识精度会得到相应的提高.

5 结 论

本文将多新息辨识理论与辅助模型辨识思想相结合,提出了辨识 Box-Jenkins 模型的 AM-MF-GESG 算法. 辅助模型的引入,使得多新息算法可直接用于 Box-Jenkins 系统的参数辨识. 多新息辨识算法引入了新息长度,充分利用了系统的数据信息,因而比相应的单新息辨识算法有更快的收敛速度和更高的辨识精度. 仿真例子进一步证实了这一结论的正确性.

参考文献(References)

[1] 谢新民, 丁锋. 自适应控制系统[M]. 北京: 清华大学出版社, 2002.
(Xie X M, Ding F. Adaptive control systems [M]. Beijing: Tsinghua University Press, 2002.)

[2] Zheng W X. On a least-squares-based algorithm for identification of stochastic linear systems [J]. IEEE Trans on Signal Processing, 1998, 46(6):1631-1638.

[3] Zheng W X. A bias correction method for identification of linear dynamic errors-in-variables models [J]. IEEE Trans on Automatic Control, 2002, 47(7): 1142-1147.

[4] Ding F, Chen T. Bias compensation based recursive least squares identification algorithm for MISO systems [J]. IEEE Trans on Circuits and Systems — : Express Briefs, 2006, 53(5): 349-353.

[5] 张端金, 李赣湘. Box-Jenkins 模型结构辨识算法 [J]. 信号处理, 1997, 13(3): 231-234.
(Zhang D J, Li G X. A new algorithm for structural identification of Box-Jenkins model [J]. Signal Processing, 1997, 13(3): 231-234.)

[6] 张端金, 张文英, 吴捷. Box-Jenkins 模型阶次与参数同时估计的递推算法 [J]. 电机与控制学报, 2003, 7(2): 157-160.
(Zhang D J, Zhang W Y, Wu J. Recursive algorithm for simultaneous identification of Box-Jenkins model order and parameters [J]. Electric Machines and Control, 2003, 7(2): 157-160.)

[7] 杨慧中, 张勇. Box-Jenkins 模型偏差补偿方法与其他辨识方法的比较 [J]. 控制理论与应用, 2007, 24(2): 215-222.
(Yang H Z, Zhang Y. Comparisons of bias compensation methods and other identification approaches for Box-Jenkins models [J]. Control Theory and Applications, 2007, 24(2): 215-222.)

[8] 张勇, 杨慧中. 有色噪声干扰输出误差系统的偏差补偿递推最小二乘辨识方法 [J]. 自动化学报, 2007, 33(10): 1053-1060.
(Zhang Y, Yang H Z. Bias compensation recursive least squares identification for output error systems with colored noises [J]. Acta Automatica Sinica, 2007, 33(10): 1053-1060.)

[9] 丁锋. 辨识 Box-Jenkins 模型参数的递推广义增广最小二乘法 [J]. 控制与决策, 1990, 5(6): 53-56.
(Ding F. A recursive generalized extended least squares identification algorithm for Box-Jenkins models [J]. Control and Decision, 1990, 5(6): 53-56.)

[10] Ding F, Chen T. Combined parameter and output estimation of dual-rate systems using an auxiliary model [J]. Automatica, 2004, 40(10): 1739-1748.

(下转第 1010 页)

- [C]. LNCS '935. Torino: Springer-Verlag, 1995: 278-297.
- [2] Lakos C A. Object-oriented modeling with object Petri nets[C]. LNCS '2001. Berlin: Springer-Verlag, 2001: 1-37.
- [3] Keen C D, Lakos C A. Information systems modeling using LOOPN++: An object Petri net scheme[C]. Proc of 4th Int Working Conf on Dynamic Modeling and Information Systems. Netherlands: Delft University Press, 1994: 31-52.
- [4] Milan C, Vladimir J, Tomas V. Modeling, prototyping and verifying concurrent and distributed applications using object-oriented Petri nets[J]. Kybernetes, 2002, 31(9/10): 1289-1299.
- [5] Tomas V. Towards formal analysis and verification over space states of object-oriented Petri nets[D]. Bron: Bron University of Technology, 2001.
- [6] Lakos C A, Lamp J W, Keen C D. Modeling network protocols with object Petri nets[C]. Proc of Workshop on Petri Nets Applied to Protocols. Torino: Springer, 1995: 31-42.
- [7] Radek K, Tomas V. A PNTalk-based model of a cooperative editor[C]. Proc of 35th Spring Int Conf on Modelling and Simulation of Systems. Hradec nad Moravicí, 2001: 165-172.
- [8] Lee Y K, J Park S. OPNets: An object-oriented high level Petri net model for real-time system modeling[J]. J of System Software, 1993, 20(1): 69-86.
- [9] Wang L. Object-oriented Petri nets for modeling and analysis of automated manufacturing systems[J]. Computer Integrated Manufacturing Systems, 1996, 26(2): 111-125.
- [10] Girault C, Valk R. Petri nets for systems engineering: A guide to modeling, verification and applications[M]. Berlin: Springer-Verlag, 2002.
- [11] Murata T. Petri nets: Properties, analysis and application[J]. Proc of IEEE, 1989, 77(4): 541-580.
- [12] 黄洪钟, 刘伟, 李丽. 产品协同设计过程建模研究[J]. 计算机集成制造系统, 2003, 9(11): 955-959. (Huang H Z, Liu W, Li L. Process modeling of product collaborative design[J]. Computer Integrated Manufacturing Systems, 2003, 9(11): 955-959.)
- [13] 宋玉银, 褚秀萍, 蔡复之. 基于时间 Petri 网的实时并行设计过程建模研究[J]. 计算机集成制造系统, 1999, 5(6): 17-22. (Song Y Y, Chu X P, Cai F Z. Research of the process modeling of real-time concurrent design based on time Petri net[J]. Computer Integrated Manufacturing Systems, 1999, 5(6): 17-22.)
- [14] Aalst W M P, Hee K M. Workflow management models, methods and systems[M]. London: The MIT Press, 2002.

(上接第 1003 页)

- [11] Ding F, Chen T. Parameter estimation of dual-rate stochastic systems by using an output error method[J]. IEEE Trans on Automatic Control, 2005, 50(9): 1436-1441.
- [12] Ding F, Chen T. Performance analysis of multi-innovation gradient type identification methods[J]. Automatica, 2007, 43(1): 1-14.
- [13] 刘英玉, 申东日, 陈义俊, 等. 基于前向神经网络的多新息随机梯度辨识算法[J]. 哈尔滨商业大学学报, 2006, 22(2): 83-86. (Liu Y Y, Shen D R, Chen Y J, et al. Multi-innovation stochastic gradient identification algorithm based on feedforward neural networks[J]. J of Harbin University of Commerce, 2006, 22(2): 83-86.)
- [14] Ding F, Chen H B, Li M. Multi-innovation least squares identification methods based on the auxiliary model for MISO systems[J]. Applied Mathematics and Computation, 2007, 186(1): 84-192.
- [15] 丁锋, 萧德云, 丁韬. 多新息随机梯度辨识方法[J]. 控制理论与应用, 2003, 20(6): 870-874. (Ding F, Xiao D Y, Ding T. Multi-innovation stochastic gradient identification methods[J]. Control Theory and Applications, 2003, 20(6): 870-874.)
- [16] Ding F, Shi Y, Chen T. Auxiliary model based least-squares identification methods for Hammerstein output-error systems[J]. Systems & Control Letters, 2007, 56(5): 373-380.