

文章编号: 1001-0920(2015)08-1491-06

DOI: 10.13195/j.kzyjc.2014.0973

非均匀 Hammerstein-Wiener 系统的递阶随机梯度辨识算法

刘冉冉^{1,2}, 潘天红¹, 李正明¹

(1. 江苏大学 电气信息工程学院, 江苏 镇江 212013; 2. 江苏理工学院 汽车与交通工程学院, 江苏 常州 213001)

摘要: 针对一类非均匀数据采样 Hammerstein-Wiener 系统, 提出一种递阶多新息随机梯度算法. 首先基于提升技术, 推导出系统的状态空间模型, 并考虑因果约束关系, 将该模型分解成两个子系统, 利用多新息遗忘随机梯度算法辨识出此模型的参数; 然后, 引入可变遗忘因子, 提出一种修正函数并在线确定其大小, 提高了算法的收敛速度及抗干扰能力. 仿真实例验证了所提出算法的有效性和优越性.

关键词: 参数估计; 随机梯度; Hammerstein-Wiener 系统; 递阶辨识; 可变遗忘因子

中图分类号: TP273

文献标志码: A

Hierarchical stochastic gradient identification for Hammerstein-Wiener systems with non-uniformly sampling

LIU Ran-ran^{1,2}, PAN Tian-hong¹, LI Zheng-ming¹

(1. School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 212013, China; 2. School of Automotive and Traffic Engineering, Jiangsu University of Technology, Changzhou 213000, China. Correspondent: PAN Tian-hong, E-mail: thpan@ujs.edu.cn)

Abstract: A hierarchical multi-innovation stochastic gradient identification algorithm is proposed for Hammerstein-Wiener(H-W) nonlinear systems with non-uniformly sampling. The corresponding state space models of H-W are derived by using the lifting technique. Considering the causality constraints, the H-W system is decomposed into two subsystems firstly. Then the model parameters are identified by using the multi-innovation based stochastic gradient algorithm with forgetting factors. In order to improve the convergent rate and the disturbance rejection, a new kind of variable forgetting factor algorithm is also presented. Simulation examples demonstrate that the proposed algorithm has fast convergence speed and is robust to the noise.

Keywords: parameters estimation; stochastic gradient; Hammerstein-Wiener system; hierarchical identification; varying forgetting factor

0 引言

在工业生产过程中, 受传感器采样频率、物理设备的特性, 以及机械、环境因素等影响, 使得系统采样呈现不规则状态, 即多率系统. 由于该系统能够反映实际工业生产中数据采样特点, 且直接影响控制系统性能, 受到了工业界与学术界的普遍关注. 对于线性非均匀多率系统而言, 利用提升技术, 结合多新息递阶辨识原理与最小二乘算法, 在不同噪声条件下, 基于不同的模型结构(如: CAR、CARIMA、Box-Jenkins等), 涌现出一系列辨识方法, 并取得了良好的辨识效果^[1-7].

然而, 实际的工业过程几乎都呈现不同的非线性, 很难直接使用上述算法. 文献[8]基于多项式转换技术, 提出了一种辨识 Hammerstein 非线性双率系统的最小二乘辨识算法, 但提升后的系统参数向量维数大, 且在参数分离过程中大量参数被重复估计, 导致计算量较大. 文献[9-10]针对具有预负载特性的双率非线性系统, 通过关键项分离将系统模型转换为辨识模型, 并利用多项式转换技术, 提出两种改进的随机梯度算法. 但上述算法不仅待辨识参数维数高, 而且在有色噪声干扰下, 无法直接由辨识参数计算出原系统参数.

收稿日期: 2014-06-18; 修回日期: 2014-08-30.

基金项目: 国家自然科学基金项目(61273142); 江苏省自然科学基金项目(BK2011466); 江苏省研究生培养创新工程项目(CXLX12_0648); 江苏省六大人才高峰项目(2012-DZXX-045); 江苏省高校优势学科建设工程项目(PAPD).

作者简介: 刘冉冉(1982-), 女, 博士生, 从事非线性多率系统辨识的研究; 潘天红(1974-), 男, 教授, 博士生导师, 从事非线性系统模型辨识与优化控制等研究.

为此, 本文基于文献 [11-12] 的方法, 以非均匀采样数据 Hammerstein-Wiener (H-W) 非线性系统为对象, 提出一种带可变遗忘因子的递阶多新息随机梯度算法. 该方法利用递阶辨识原理, 将系统分解为两个子系统, 直接对系统参数进行辨识, 从而降低计算负荷; 同时引入可变遗忘因子, 以提高算法的抗干扰能力及辨识精度.

1 问题描述

一类非均匀采样数据 H-W 非线性系统结构如图 1 所示. 其中: $f(\cdot)$ 、 $h(\cdot)$ 分别为输入和输出静态非线性模块, P_c 为动态线性模块.




图 1 非均匀采样 H-W 系统

设静态非线性模块 $h(\cdot)$ 可逆, 则有

$$\begin{aligned} \bar{u}(kT + t_{j-1}) &= f(u(kT + t_{j-1})) = \\ &= c_{1f_1}(u(kT + t_{j-1})) + \cdots + c_{n_c} f_{n_c}(u(kT + t_{j-1})) = \\ &= \sum_{s=1}^{n_c} c_s f_s(u(kT + t_{j-1})), \end{aligned} \quad (1)$$

$$\begin{aligned} \bar{y}(kT) &= h^{-1}(y(kT)) = g(y(kT)) = \\ &= d_{1g_1}(y(kT)) + \cdots + d_{n_d} g_{n_d}(y(kT)) = \\ &= \sum_{l=1}^{n_d} d_l g_l(y(kT)). \end{aligned} \quad (2)$$

其中: $f_1(\cdot), \dots, f_{n_c}(\cdot)$ 和 $g_1(\cdot), \dots, g_{n_d}(\cdot)$ 为已知基函数; c_1, \dots, c_{n_c} 和 d_1, \dots, d_{n_d} 为静态非线性模块的未知参数;

$$\begin{aligned} \bar{u}(t) &= \\ &= \begin{cases} \bar{u}(kT), & kT \leq t < kT + t_1; \\ \bar{u}(kT + t_1), & kT + t_1 \leq t < kT + t_2; \\ \vdots \\ \bar{u}(kT + t_{m-1}), & kT + t_{m-1} \leq t < kT + T; \end{cases} \\ &= \begin{cases} \sum_{s=1}^{n_c} c_s f_s(u(kT)), & kT \leq t < kT + t_1; \\ \sum_{s=1}^{n_c} c_s f_s(u(kT + t_1)), & kT + t_1 \leq t < kT + t_2; \\ \vdots \\ \sum_{s=1}^{n_c} c_s f_s(u(kT + t_{m-1})), & kT + t_{m-1} \leq t < kT + T. \end{cases} \end{aligned} \quad (3)$$

在周期 $[kT, kT+T]$ 上, 非均匀零阶保持器 H_τ 控制输入 \bar{u} 非均匀刷新 m 次, 即控制系统的输入信号 u 非均匀刷新 m 次, 时间间隔为 $\{\tau_1, \tau_2, \dots, \tau_m\}$, 则输入刷新时刻点依次为 $kT + t_{j-1}, j = 1, 2, \dots, m$, 其中

$t_{j-1} := \tau_1 + \tau_2 + \cdots + \tau_{j-1}$. 为方便起见, 令 $t_0 = 0$, 则系统框架周期为 $T = t_m = \tau_1 + \tau_2 + \cdots + \tau_m$, 经提升技术处理后特性如式 (3) 所示.

设 P_c 状态空间模型为

$$P_c := \begin{cases} \dot{\mathbf{x}}(t) = \mathbf{A}_1 \mathbf{x}(t) + \mathbf{B}_1 \bar{u}(t), \\ \bar{y}(t) = \mathbf{C} \mathbf{x}(t) + D \bar{u}(t). \end{cases} \quad (4)$$

其中: $\mathbf{x}(t) \in R^n$ 为状态向量; $y(t) \in R, \bar{u}(t) \in R$ 分别为系统的输出和输入; $\mathbf{A}_1 \in R^{n \times n}, \mathbf{B}_1 \in R^n, \mathbf{C} \in R^{1 \times n}, D \in R$ 分别为系统的参数矩阵. 非均匀刷新的输入数据为 $u(kT + t_{j-1}), j = 1, 2, \dots, m$, 周期采样的输出数据为 $y(kT)$, 以周期 T 离散化系统 (4)^[13], 得

$$y(kT) = \alpha(z) \bar{y}(kT) + \sum_{j=1}^m \beta_j(z) \bar{u}(kT + t_{j-1}). \quad (5)$$

其中

$$\alpha(z) = \alpha_1 z^{-1} + \alpha_2 z^{-2} + \cdots + \alpha_{n_a} z^{-n_a},$$

$$\beta_1(z) = \beta_{10} + \beta_{11} z^{-1} + \cdots + \beta_{1n_b} z^{-n_b},$$

$$\beta_j(z) = \beta_{j1} z^{-1} + \beta_{j2} z^{-2} + \cdots + \beta_{jn_b} z^{-n_b}.$$

这里: $j = 2, 3, \dots, m; z^{-1}$ 为后移因子, 即 $z^{-1} x(kT) = x(kT - T)$. 不失一般性, 引入白噪声, 综合式 (1)、(2)、(5), 可得

$$y(kT) = \alpha(z) \sum_{l=1}^{n_d} d_l g_l(y(kT)) + \sum_{j=1}^m \beta_j(z) \times \sum_{s=1}^{n_c} c_s f_s(u(kT + t_{j-1})) + v(kT). \quad (6)$$

其中: n_a, n_b, n_c, n_d 为给定的模型阶次; 当 $k \leq 0$ 时, $u(kT + t_{j-1}) = 0, y(kT) = 0, v(kT) = 0$. 定义系统线性部分参数向量 \mathbf{a}, \mathbf{b} 及非线性部分参数向量 \mathbf{c}, \mathbf{d} 分别为

$$\mathbf{a} := [\alpha_1, \alpha_2, \dots, \alpha_{n_a}]^T \in R^{n_a},$$

$$\mathbf{b} := [\beta_{10}, \beta_{11}, \dots, \beta_{1n_b}]^T \in R^{mn_b+1},$$

$$\mathbf{c} := [c_1, c_2, \dots, c_{n_c}]^T \in R^{n_c},$$

$$\mathbf{d} := [d_1, d_2, \dots, d_{n_d}]^T \in R^{n_d}.$$

其中

$$\beta_1 := [\beta_{10}, \beta_{11}, \dots, \beta_{1n_b}]^T \in R^{n_b+1},$$

$$\beta_j := [\beta_{j1}, \beta_{j2}, \dots, \beta_{jn_b}]^T \in R^{n_b}, j = 2, 3, \dots, m.$$

于是系统的参数向量为 $\boldsymbol{\Theta} = [\mathbf{a}, \mathbf{b}, \mathbf{c}, \mathbf{d}]^T$.

2 带可变遗忘因子的多新息随机梯度算法

定义系统的输出与输入信息 $\mathbf{G}(kT)$ 和 $\mathbf{F}(kT)$ 分别为

$$\mathbf{G}(kT) = \begin{bmatrix} g_1(y(kT - T)) & \cdots & g_{n_d}(y(kT - T)) \\ \vdots & \ddots & \vdots \\ g_1(y(kT - n_a T)) & \cdots & g_{n_d}(y(kT - n_a T)) \end{bmatrix}, \quad (7)$$

$$\mathbf{F}(kT) = \begin{bmatrix} f_1(u(kT)) & \cdots & f_{n_c}(u(kT)) \\ \vdots & \ddots & \vdots \\ f_1(u(kT-n_bT)) & \cdots & f_{n_c}(u(kT-n_bT)) \\ f_1(u(kT-T+t_1)) & \cdots & f_{n_c}(u(kT-T+t_1)) \\ \vdots & \ddots & \vdots \\ f_1(u(kT-n_bT+t_1)) & \cdots & f_{n_c}(u(kT-n_bT+t_1)) \\ f_1(u(kT-T+t_{m-1})) & \cdots & f_{n_c}(u(kT-T+t_{m-1})) \\ \vdots & \ddots & \vdots \\ f_1(u(kT-n_bT+t_{m-1})) & \cdots & f_{n_c}(u(kT-n_bT+t_{m-1})) \end{bmatrix} \quad (8)$$

其中: $\mathbf{F}(kT) \in R^{(mn_b+1) \times n_c}$, $\mathbf{G}(kT) \in R^{n_a \times n_d}$. 则式(6)可写成

$$y(kT) = \mathbf{a}^T \mathbf{G}(kT) \mathbf{d} + \mathbf{b}^T \mathbf{F}(kT) \mathbf{c} + v(kT). \quad (9)$$

基于递阶辨识原理, 可将非均匀采样数据 H-W 非线性系统(9)分解为两个子系统: 一个包含线性动态模块的参数 $\boldsymbol{\eta} := [\mathbf{a}, \mathbf{b}]^T$; 另一个包含非线性静态模块的参数 $\boldsymbol{\gamma} := [\mathbf{d}, \mathbf{c}]^T$. 由于参数 $\mathbf{a}, \mathbf{b}, \mathbf{c}, \mathbf{d}$ 未知, 在 kT 时刻, 用前一周期 $(k-1)T$ 时的估计值 $\hat{\mathbf{a}}_{k-1}, \hat{\mathbf{b}}_{k-1}, \hat{\mathbf{c}}_{k-1}, \hat{\mathbf{d}}_{k-1}$ 代替, 定义 $\hat{\boldsymbol{\eta}}(kT) := [\hat{\mathbf{a}}_k, \hat{\mathbf{b}}_k]^T$, $\hat{\boldsymbol{\gamma}}(kT) := [\hat{\mathbf{c}}_k, \hat{\mathbf{d}}_k]^T$ 分别表示 kT 时刻 $\boldsymbol{\eta}, \boldsymbol{\gamma}$ 的估计值, 定义广义信息向量 $\varphi(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT) \in R^{n_a+mn_b+1}$, $\psi(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT) \in R^{n_c+n_d}$ 分别为

$$\varphi(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT) = \begin{bmatrix} \mathbf{G}(kT) \hat{\mathbf{d}}_{k-1} \\ \mathbf{F}(kT) \hat{\mathbf{c}}_{k-1} \end{bmatrix}, \quad (10)$$

$$\psi(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT) = \begin{bmatrix} \mathbf{G}^T(kT) \hat{\mathbf{a}}_{k-1} \\ \mathbf{F}^T(kT) \hat{\mathbf{b}}_{k-1} \end{bmatrix}. \quad (11)$$

于是系统(9)可以分解为如下两个子系统:

$$M_1: y(kT) = \varphi^T(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT) \boldsymbol{\eta} + v(kT), \quad (12)$$

$$M_2: y(kT) = \psi^T(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT) \boldsymbol{\gamma} + v(kT). \quad (13)$$

M_1 中只含线性动态参数 $\boldsymbol{\eta}$, M_2 中只含非线性静态参数 $\boldsymbol{\gamma}$, 两个子系统通过向量 $\varphi(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT)$, $\psi(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT)$ 相关联. 为了充分利用系统历史采样数据, 基于多新息理论, 定义信息矩阵 $\Phi(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT) \in R^{p \times (n_a+mn_b+1)}$, $\Psi(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT) \in R^{p \times (n_c+n_d)}$ 以及堆积输出向量 $\mathbf{Y}(p, kT) \in R^p$ 分别为

$$\mathbf{Y}(p, kT) = \begin{bmatrix} y(kT) \\ y(kT-T) \\ \vdots \\ y(kT-(p-1)T) \end{bmatrix}, \quad (14)$$

$$\Phi(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT) = \begin{bmatrix} \varphi(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT) \\ \vdots \\ \varphi(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT-(p-1)T) \end{bmatrix}, \quad (15)$$

$$\Psi(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT) = \begin{bmatrix} \psi(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT) \\ \vdots \\ \psi(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT-(p-1)T) \end{bmatrix}, \quad (16)$$

其中 p 为新息长度.

以辨识误差平方和为准则函数, 即

$$J_1(\boldsymbol{\eta}) = \|\mathbf{Y}(p, kT) - \Phi^T(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT) \boldsymbol{\eta}\|^2, \quad (17)$$

$$J_2(\boldsymbol{\gamma}) = \|\mathbf{Y}(p, kT) - \Psi^T(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT) \boldsymbol{\gamma}\|^2, \quad (18)$$

其中 $\|\cdot\|^2$ 为向量范数.

J_1, J_2 分别相应于参数 $\boldsymbol{\eta}, \boldsymbol{\gamma}$ 的梯度为

$$\begin{aligned} \text{grad}[J_1(\boldsymbol{\eta})] &= \frac{\partial J_1(\boldsymbol{\eta})}{\partial \boldsymbol{\eta}} = \\ &= -2\Phi^T(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT) [\mathbf{Y}(p, kT) - \Phi(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT) \boldsymbol{\eta}], \\ \text{grad}[J_2(\boldsymbol{\gamma})] &= \frac{\partial J_2(\boldsymbol{\gamma})}{\partial \boldsymbol{\gamma}} = \\ &= -2\Psi^T(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT) [\mathbf{Y}(p, kT) - \Psi(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT) \boldsymbol{\gamma}]. \end{aligned}$$

根据随机梯度搜索原理, 极小化两个准则函数^[14], 并考虑复杂度影响, 引入固定遗忘因子 λ_1 和可变遗忘因子 $\lambda_2(kT)$, 可得估计参数 $\hat{\boldsymbol{\eta}}, \hat{\boldsymbol{\gamma}}$ 的带可变遗忘因子的递阶多新息随机梯度递推算法(VFF-HMISG)为

$$\begin{aligned} \hat{\boldsymbol{\gamma}}(kT) &= \\ \hat{\boldsymbol{\gamma}}(kT-T) &+ \frac{\Psi^T(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT)}{r_1(kT)} \times \\ &[\mathbf{Y}(p, kT) - \Psi(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT) \hat{\boldsymbol{\gamma}}(kT-T)]; \quad (19) \end{aligned}$$

$$\begin{aligned} r_1(kT) &= \lambda_1 r_1(kT-T) + \|\psi(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT)\|^2, \\ r_1(0) &= 1, \quad 0 < \lambda_1 \leq 1; \quad (20) \end{aligned}$$

$$\begin{aligned} \hat{\boldsymbol{\eta}}(kT) &= \\ \hat{\boldsymbol{\eta}}(kT-T) &+ \frac{\Phi^T(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT)}{r_2(kT)} \times \\ &[\mathbf{Y}(p, kT) - \Phi(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT) \hat{\boldsymbol{\eta}}(kT-T)]; \quad (21) \end{aligned}$$

$$\begin{aligned} r_2(kT) &= \\ \lambda_2(kT-T) r_2(kT-T) &+ \|\varphi(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1}, kT)\|^2, \\ r_2(0) &= 1. \quad (22) \end{aligned}$$

其中 $1/r_1(kT), 1/r_2(kT)$ 为收敛因子. 遗忘因子用于调节收敛因子的大小, 进而影响对非平稳信号的自适应能力. 其值越小, 算法的跟踪能力越强, 但对于噪声

干扰也越敏感, 参数估计波动也越大; 反之, 对噪声干扰不敏感, 参数估计误差也较小, 但收敛速度较慢.

为了保证算法的收敛速度, 并提高算法的抗干扰能力, 减小参数估计误差, 本文 $\lambda_2(kT)$ 采用可变遗忘因子. 在参数辨识的初始阶段, 设定一个较小的 $\lambda_2(kT)$, 随着参数估计的稳定 $\lambda_2(kT)$ 逐渐趋向于 1, 由此提出一种新的遗忘因子修正函数

$$\lambda_2(kT) = \lambda_{\min} + (1 - \lambda_{\min})^{2^{R(kT)}};$$

$$\text{s.t. } \begin{cases} R(kT) = \text{NINT}(\rho|\xi(kT)|), \\ \xi(kT) = y(kT) - \hat{\mathbf{a}}_{k-1}^T G(kT) \hat{\mathbf{d}}_{k-1} - \hat{\mathbf{d}}_{k-1}^T F(kT) \hat{\mathbf{c}}_{k-1}. \end{cases} \quad (23)$$

其中: $\lambda_2(kT)$ 为 kT 时刻的遗忘因子; λ_{\min} 为遗忘因子最小值, $0 \leq \lambda_{\min} \leq 1$; ρ 为敏感增益系数, 控制 $\lambda_2(kT)$ 趋向于 1 的速率; $\xi(kT)$ 为 kT 时刻输出量测值与估计值的误差; $\text{NINT}(\cdot)$ 表示最接近 (\cdot) 的整数.

由修正函数可知, 遗忘因子 $\lambda_2(kT)$ 由误差 $\xi(kT)$ 控制. 当 $\xi(kT)$ 较大时, $\lambda_2(kT)$ 较小, 算法能快速地跟踪信号变化; 反之, $\lambda_2(kT)$ 较大, 算法对噪声干扰不敏感, 收敛时参数估计误差也较小; 当 $\xi(kT) = 0$ 时, $\lambda_2(kT) = 1$ 可以保证参数估计误差最小.

在 VFF-HMISG 算法 (19)~(23) 中:

- 1) 若 $\lambda_2(kT)$ 为常数, 则算法蜕变为递阶多新息遗忘随机梯度算法 (HMIFG);
- 2) 若 $p = 1$, 则算法蜕变为带可变遗忘因子的递阶随机梯度算法 (VFF-HSG);
- 3) 若 $\lambda_{\min} = 1$, 则算法蜕变为递阶多新息随机梯度算法 (HMISG);
- 4) 若 $p = 1, \lambda_{\min} = 1$, 则算法蜕变为递阶随机梯度算法 (HSG).

为叙述方便, 引入符号 $[\theta(kT)](p:q)$ 表示参数向量 $\theta(kT)$ 中第 $p \sim q$ 个向量数据, 则 VFF-HMISG 算法总结如下.

Step 1: 选择 p, λ_{\min}, ρ , 令 $k = 1, \hat{\theta}(0) = \mathbf{1}_{n_a+mn_b+1}/p_0, \hat{\gamma}(0) = \mathbf{1}_{n_c+n_d}/p_0, p_0 = 10^6$, 这里 $\mathbf{1}_n$ 为元均为 1 的 n 维列向量.

Step 2: 采集 $u(kT+t_{j-1})$ 和 $y(kT)$, 由式 (1) 和 (2) 计算 $\bar{u}(kT+t_{j-1})$ 和 $\bar{y}(kT)$, 构造输入输出信息矩阵 $\mathbf{G}(kT)$ 和 $\mathbf{F}(kT)$. 再由式 (14)、(16)、(11)、(7)、(8) 分别构造堆积向量 $\mathbf{Y}(p, kT)$ 和 广义信息向量 $\Psi(\hat{\mathbf{a}}_{k-1} \hat{\mathbf{b}}_{k-1}, kT)$.

Step 3: 由式 (20) 计算 $r_1(kT)$.

Step 4: 由式 (19) 刷新参数估计向量 $\hat{\gamma}(kT)$, 并令

$$\hat{\mathbf{d}}_k := [\hat{\gamma}(kT)](1:n_d),$$

$$\hat{\mathbf{c}}_k := [\hat{\gamma}(kT)](n_d+1:n_d+n_c).$$

Step 5: 由式 (10) 构造广义信息向量 $\varphi(\hat{\mathbf{c}}_{k-1} \hat{\mathbf{d}}_{k-1},$

$kT)$, 由式 (22)~(23) 计算 $r_2(kT)$.

Step 6: 由式 (21) 刷新参数估计向量 $\hat{\eta}(kT)$, 并令

$$\hat{\mathbf{a}}_k := [\hat{\eta}(kT)](1:n_a),$$

$$\hat{\mathbf{b}}_k := [\hat{\eta}(kT)](n_a+1:n_a+mn_b+1).$$

Step 7: $k = k + 1$, 转 Step 2.

3 算法性能分析

3.1 计算量分析

为了评价算法的计算量, 用算法的乘法次数 (包括除法次数) 和加法次数 (包括减法次数) 来衡量. VFF-HMISG 算法每递推一步的乘法次数与加法次数分别为

$$3p(n_a+mn_b+1) + \min(n_a+mn_b+1, n_c+n_d) + p + 1,$$

$$3p(n_a+mn_b+1) + \min(n_a+mn_b+1, n_c+n_d) + 2,$$

则算法的计算量为

$$6p(n_a+mn_b+1) + 2\min(n_a+mn_b+1, n_c+n_d) + p + 3.$$

3.2 收敛性分析

由于在线性动态参数 $\hat{\eta}(kT)$ 估计中引入了可变遗忘因子 $\lambda_2(kT)$, 其辨识过程更具一般性. 为此, 本文以 $\hat{\eta}(kT)$ 为例, 分析算法的收敛性能.

引理 1 对于系统 (12) 及 VFF-HMISG 算法 (19)~(23), 若信息向量 $\varphi(kT)$ 持续激励, 即存在常数 $0 < \alpha \leq \beta < \infty$ 和正整数 $N \geq n$, 使得下述持续激励条件成立^[15]:

$$(A1) \quad \alpha \mathbf{I} \leq \frac{1}{N} \sum_{i=0}^{N-1} \varphi(kT+iT) \varphi^T(kT+iT) \leq \beta \mathbf{I}, \text{ a.s.}$$

$$k > 0.$$

假设信息向量 $\varphi(kT)$ 有下界 $\|\varphi(kT)\|^2 \geq \alpha > 0$, 且 $r_2(0)$ 满足

$$r_2(0) \leq \frac{nN\beta}{1-\lambda_{\min}}, \quad 0 \leq \lambda_{\min} < 1, \quad (24)$$

则对于所有的 $k > 0$, 式 (22) 中的 $r_2(kT)$ 满足不等式

$$r_2(kT) \leq \frac{nN\beta}{1-\lambda_{\min}}, \text{ a.s. } 0 \leq \lambda_{\min} < 1. \quad (25)$$

定理 1 对于系统 (12) 以及 VFF-HMISG 算法 (19)~(23), 若条件 (A1) 成立, 则 $r_2(0)$ 由式 (24) 确定, 且观测噪声 $\{v(kT)\}$ 为满足条件

$$(A2) \quad E[v(kT)] = 0,$$

$$(A3) \quad E[v^2(kT)] \leq \sigma_v^2 < \infty$$

的零均值随机序列. 令新息长度 $p = N, E[\|\hat{\eta}(0)\|^2] = E[\|\hat{\eta}(0) - \eta(0)\|^2] = \delta_0 < \infty$. 则 VFF-HMISG 算法的参数估计误差是均方有界的, 即

$$E[\|\hat{\eta}(kT) - \eta(kT)\|^2] \leq$$

$$[\sqrt{1-\mu}]^k \delta_0 + \frac{1}{(1-\sqrt{1-\mu})^2} \times$$

$$\frac{N^2\beta(1-\lambda_{\min})^2\sigma_v^2}{\alpha^2} =: f_u(\lambda_{\min}, k).$$

其中: $0 < \mu := \frac{\alpha(1-\lambda_{\min})}{n\beta} < 1, 0 < \lambda_{\min} < 1, 0 < \mu < 1,$
 δ_0 为有限值, 当 k 趋于无穷大时, $[\sqrt{1-\mu}]^k \delta_0$ 趋于 0.
 从而得到参数估计误差的近似上界为

$$E[|\hat{\eta}(kT) - \eta(kT)|^2] = f_u(\lambda_{\min}, k) \approx$$

$$\frac{1}{(1-\sqrt{1-\mu})^2} \times \frac{N^2\beta(1-\lambda_{\min})^2\sigma_v^2}{\alpha^2} =$$

$$f(a_0, \lambda_{\min}) =: f(\lambda_{\min}).$$

文献 [16] 给出了引理 1 和定理 1 的证明过程, 本文不再赘述.

4 仿真验证

考虑某一非均匀采样数据 H-W 非线性系统

$$y(kT) =$$

$$\alpha(z) \sum_{l=1}^{n_d} d_l g_l(y(kT)) +$$

$$\sum_{j=1}^m \beta_j(z) \sum_{s=1}^{n_c} c_s f_s(u(kT + t_{j-1})) + v(kT), \quad (26)$$

$$\alpha(z) = \alpha_1 z^{-1} + \alpha_2 z^{-2} = -1.529z^{-1} + 10.5z^{-2},$$

$$\beta_1(z) = \beta_{10} + \beta_{11}z^{-1} + \beta_{12}z^{-2} =$$

$$0.1234 + 0.06899z^{-1} + 0.01538z^{-2},$$

$$\beta_2(z) = \beta_{21}z^{-1} + \beta_{22}z^{-2} =$$

$$0.0421z^{-1} + 0.08506z^{-2},$$

$$\bar{u}(kT + t_i) = \sum_{s=1}^{n_c} c_s f_s(u(kT + t_i)) =$$

$$0.6 \sin(u(kT + t_i)) + 0.1 \cos(u^2(kT + t_i)),$$

$$\bar{y}(kT) = \sum_{l=1}^{n_d} d_l g_l(y(kT)) =$$

$$0.2 \sin(y(kT)) + 0.1 \cos(y^2(kT)),$$

$$\Theta = [\alpha_1, \alpha_2, \beta_{10}, \beta_{11}, \beta_{12}, \beta_{21}, \beta_{22}, c_1, c_2]^T.$$

系统输入非均匀刷新次数 $m = 2$, 输出采样周期 $T = 2.5$ s, 输入采样间隔 $\tau_1 = 1$ s, $\tau_2 = 1.5$ s, 则 $t_0 = 0$ s, $t_1 = \tau_1 = 1$ s, $t_2 = \tau_1 + \tau_2 = T = 2.5$ s, 输入 $\{u(kT), u(kT + t_1)\}$ 以零均值单位方差持续信号激励系统, $\{v(kT)\}$ 为零均值方差为 σ^2 的白噪声, 数据长度设为 4 000. 采用 VFF-HMISG 算法辨识模型 (26) 的参数. 为了评估算法的有效性, 定义性能指标如下:

$$\delta = \left\| \frac{\hat{\theta}(kT) - \theta}{\theta} \right\| \times 100\%. \quad (27)$$

当 $\sigma^2 = 0.1$ 时, 选取 $p = 2, \lambda_{\min} = 0.9, \rho = 5, \lambda_1 = 1$, 参数估计及不同采样周期长度下的估计误差 δ 如表 1 所示. 由表 1 可知, 随着采样周期的增加, 参数估计误差减小, 到 1 000 周期时, 趋于稳定.

表 1 VFF-HMISG 估计及误差

k	100	200	500	1000	2000	3000	4000	真值
a_1	-1.473 77	-1.538 48	-1.573 61	-1.532 66	-1.528 49	-1.514 77	-1.514 34	-1.529 00
a_2	10.249 50	10.386 04	10.388 51	10.465 99	10.481 63	10.492 37	10.496 64	10.500 00
b_{10}	-0.004 26	-0.004 55	-0.005 02	-0.005 41	-0.005 66	-0.005 64	-0.005 64	0.123 40
b_{11}	-0.012 09	-0.012 54	-0.012 97	-0.013 18	-0.013 53	-0.013 64	-0.013 65	0.068 99
b_{12}	-0.009 35	-0.009 56	-0.010 01	-0.010 32	-0.010 63	-0.010 79	-0.010 88	0.015 38
b_{21}	0.006 58	0.006 37	0.005 88	0.005 43	0.005 20	0.005 05	0.005 02	0.042 10
b_{22}	0.008 28	0.008 17	0.008 23	0.007 82	0.007 50	0.007 44	0.007 42	0.085 06
d_1	-0.199 53	-0.200 66	-0.199 53	-0.200 09	-0.200 36	-0.200 49	-0.200 47	0.200 00
d_2	-0.101 11	-0.101 29	-0.099 51	-0.099 80	-0.099 45	-0.099 39	-0.099 52	0.100 00
c_1	0.000 09	0.000 14	0.000 24	0.000 32	0.000 39	0.000 44	0.000 48	0.600 00
c_2	-0.001 41	-0.001 38	-0.001 32	-0.001 26	-0.001 19	-0.001 17	-0.001 15	0.100 00
$\delta/\%$	7.679 76	7.376 52	7.375 48	7.299 84	7.295 89	7.295 76	7.295 57	0.000 00

参数 p, λ_{\min}, ρ 对算法的收敛速度与精度的影响较大, 其性能指标变化曲线如图 2 所示. 可以看出: 适当增大新息长度, 算法的辨识性能有所提高; 引入可变遗忘因子后, 算法的收敛速度明显加快 (如图 2 中虚线所示), 且 800 周期后参数估计较为平稳; 适当改变增益 ρ 的取值, 参数估计的收敛速度更为敏感 (如图 2 中点线所示).

为了验证算法对噪声的抗干扰能力, 选取 $p = 2, \lambda_1 = 1, \sigma^2$ 分别为 0.1、0.3 时 VFF-HMISG ($\lambda_{\min} = 0.95, \rho = 5$)、HMIFG ($\lambda_2 = 0.95$) 算法的估计误差随采样周

期长度的变化曲线如图 3 所示.




图 2 VFF-HMISG 参数估计误差 δ 变化曲线




图3 不同方差下两种算法的参数估计误差 δ 变化曲线

可以看出,在辨识过程中,噪声扰动增大时,算法HMISG出现了明显波动,而VFF-HMISG算法在保证辨识精度的同时,具有更强的抗干扰能力。

5 结论

本文针对非均匀采样数据H-W非线性系统,提出了带可变遗忘因子的递阶多新息随机梯度辨识算法。相比文献[10]中先辨识转换模型参数,后分离出系统参数的方法,本文算法直接辨识系统参数,降低了计算量,引入可变遗忘因子后,算法收敛速度提高,对噪声的抗干扰能力有所增强。该算法经简单的变换即可直接用于Hammerstein、Wiener系统的参数辨识,并可结合其他参数辨识方法,用于线性及非线性系统的参数估计、状态识别及故障检测,但 p 、 λ_{\min} 、 ρ 选择等问题还有待进一步研究。

参考文献(References)

- [1] 丁洁, 谢莉, 丁锋. 非均匀采样系统多新息随机梯度辨识性能分析[J]. 控制与决策, 2011, 26(9): 1338-1342.
(Ding J, Xie L, Ding F. Performance analysis of multi-innovation stochastic gradient identification for non-uniformly sampled systems[J]. Control and Decision, 2011, 26(9): 1338-1342.)
- [2] Liu Y, Ding F, Shi Y. Least squares estimation for a class of non-uniformly sampled systems based on the hierarchical identification principle[J]. Circuits, Systems, and Signal Processing, 2012, 31(6): 1985-2000.
- [3] 蒋红霞, 王金海, 丁锋. 一类非均匀采样系统最小二乘迭代辨识[J]. 系统工程与电子技术, 2008, 30(8): 1535-1539.
(Jiang H X, Wang J H, Ding F. Least-square-iterative identification of a class of non-uniform sampled-data systems[J]. Systems Engineering and Electronics, 2008, 30(8): 1535-1539.)
- [4] Xie L, Yang H. Gradient-based iterative identification for nonuniform sampling output error systems[J]. J of Vibration and Control, 2011, 17(3): 471-478.
- [5] 谢莉, 丁锋. 非均匀采样数据系统的一种辨识方法[J]. 控制工程, 2008, 15(4): 402-404.
(Xie L, Ding F. Identification method of non-uniformly sampled-data systems[J]. Control Engineering of China, 2008, 15(4): 402-404.)
- [6] 谢莉, 刘艳君. 非均匀采样数据系统AM-MI-GESG算法[J]. 仪器仪表学报, 2009, 30(6): 25-29.
(Xie L, Liu Y J. AM-MI-GESG algorithms for non-uniformly sampled-data systems[J]. Chinese J of Scientific Instrument, 2009, 30(6): 25-29.)
- [7] Xie L, Yang H Z, Ding F. Recursive least squares parameter estimation for non-uniformly sampled systems based on the data filtering[J]. Mathematical and Computer Modeling, 2011, 54(1/2): 315-324.
- [8] 陈聪. 基于Hammerstein模型的双速率系统辨识[D]. 杭州: 浙江大学控制科学与工程学系, 2010.
(Chen C. Nonlinear identification of dual-rate systems based on Hammerstein model[D]. Hangzhou: Department of Control Science and Engineering, Zhejiang University, 2010.)
- [9] Jing Chen, Lixing Lü, Ruifeng Ding. Multi-innovation stochastic gradient algorithms for dual-rate sampled systems with preload nonlinearity[J]. Applied Mathematics Letters, 2013, 26(1): 124-129.
- [10] Chen J, Lü L X, Ding R F. Parameter estimation for dual-rate sampled data systems with preload nonlinearities[J]. Advances in Intelligent and Soft Computing, 2011, 125: 43-50.
- [11] Wang D Q, Ding F. Least squares based and gradient based iterative identification for Wiener nonlinear systems[J]. Signal Processing, 2011, 91(5): 1182-1189.
- [12] Ding F. Hierarchical multi-innovation stochastic gradient algorithm for Hammerstein nonlinear system modeling[J]. Applied Mathematical Modelling, 2013, 37(4): 1694-1704.
- [13] Ding F, Qiu L, Chen T. Reconstruction of continuous-time systems from their non-uniformly sampled discrete-time systems[J]. Automatica, 2009, 45(2): 324-332.
- [14] Goodwin G C, Sin K S. Adaptive filtering prediction and control[M]. Englewood Cliffs: Prentice-hall, 1984: 68-79.
- [15] Ljung L. Consistency of the least-squares identification method[J]. IEEE Trans on Automatic Control, 1976, 21(5): 779-781.
- [16] Ding F, Chen T W. Performance analysis of multi-innovation gradient type identification methods[J]. Automatica, 2007, 43(1): 1-14.