

拟线性对称超松弛形两步递推辨识算法

叶春生 余俊 熊有伦

(华中理工大学机械一系·武汉, 430074)

摘要: 本文提出一种线性系统拟线性对称超松弛形两步递推辨识新算法, 并对其收敛性应用常微分方程的方法进行了分析。仿真结果表明算法和本文的收敛定理是一致的。

关键词: 拟线性; 对称超松弛; 两步递推辨识; 收敛性

1 引言

系统辨识的递推算法其关键在于在每步递推中处理逆矩阵的计算, 通常处理逆矩阵的方法是求逆公式^[2,6,7]。但使用求逆公式的递推算法在数值上是不可靠的, 因为应用求逆公式的递推方程对舍入误差很敏感, 而且误差还可积累, 从而使逆矩阵失去正定性。文献[3,4,5]研究的递推算法, 实际上是改进了的递推辨识算法,[4]由于引入了松弛因子, 较[3,5]的算法有更好的数值稳定性, 且不破坏递推算法中的递推矩阵特征值的严格正实条件。

本文研究的拟线性对称超松弛形递推算法是对递推算法中的矩阵求逆的问题采用递推算法解决, 这就导出了对称超松弛形递推算法。因为实际计算时, 逆矩阵的递推只能进行有限步, 因此与拟线性的递推算法联合起来, 就形成本文研究的拟线性对称超松弛形递推辨识算法。本文较文[4,5]的优点在于保证递推矩阵特征值的严格正实条件, 程序的复杂性没有增加, 因而也易于实现系统的在线辨识, 精度与文[2]给出的 PLR 和 RPEM 算法的结果基本一致, 但计算量有明显的减少。从理论上, 它也满足 Lyapunov 漐近收敛的性质^[1]。

2 系统描述

假定 n 个输出 r 个输入系统如方程(1)所示:

$$y(t) = -A_1y(t-1) - \dots - A_py(t-p) + B_1u(t-1) + \dots + B_qu(t-q) + e(t) \quad (1)$$

$$= \beta^T \varphi(t) + e(t), \quad (2)$$

$$\beta = [A_1, \dots, A_p, B_1, \dots, B_q]^T,$$

$$\varphi(t) = [-y^T(t-1), \dots, -y^T(t-p), u^T(t-1), \dots, u^T(t-q)]^T,$$

$$A_i \in \mathbb{R}^{n \times n}, \quad i = 1, 2, \dots, p; \quad B_j \in \mathbb{R}^{n \times r}, \quad j = 1, 2, \dots, q.$$

其中 β 为辨识的参数, $e(t)$ 为随机噪声, $\varphi(t)$ 是已知的测量输入和输出, 且有

$$E\{e(t)\} = 0; \quad E\{e(t)e^T(t)\} = \sigma^2 I; \quad E\{e(t)e^T(s)\} = 0, \quad (s \neq t).$$

为将辨识的参数 β 转化为向量的形式, 给出如下定义^[8,9]:

设 $A = [a_1, a_2, \dots, a_r] \in \mathbb{R}^{n \times r}$, 定义 $nr \times 1$ 向量

$$\text{vec}(A) = [a_1^T, a_2^T, \dots, a_r^T] \in \mathbb{R}^{nr \times 1},$$

这是将矩阵 A 按列向量依次排成的向量, 称这个程序叫矩阵的向量化.

公式 1 设 A, B, C 分别是 $n \times r, r \times p, p \times q$ 矩阵, 有

$$\text{vec}(ABC) = (C^T \otimes A)\text{vec}(B). \quad (3)$$

这里 \otimes 表示矩阵或向量的 Kronecker 积.

对式(2)应用公式 1 得

$$\begin{aligned} \text{vec}(y(t)) &= \text{vec}(\beta^T(\varphi(t)) + \text{vec}(e(t))) \\ &= \text{vec}(I_n \beta^T(\varphi(t)) + \text{vec}(e(t))) \\ &= (\varphi^T(t) \otimes I_n) \text{vec}(\beta^T) + e(t). \end{aligned}$$

设 $\Phi(t) = \varphi(t) \otimes I_n$; $\theta = \text{vec}(\beta^T)$, 则式(2)可写成

$$y(t) = \Phi^T(t)\theta + e(t). \quad (4)$$

由(4)得到的拟线性递推公式为^[2]

$$e(t) = y(t) - \Phi^T(t)\hat{\theta}(t), \quad (5)$$

$$\hat{\theta}(t+1) = \hat{\theta}(t) + \gamma(t)R^{-1}(t+1)\Phi(t)e(t), \quad (6)$$

$$R(t+1) = R(t) + \gamma(t)(\Phi(t)\Phi^T(t) - R(t)), \quad (7)$$

$$t = 0, 1, 2, \dots, N,$$

式(6)中的 $\gamma(t)$ 是收敛因子, $R(t)$ 由拟线性递推公式算出.

在一定的条件下递推公式(5), (6)和(7)的收敛性等价于其连带常微分方程(8)和(9)的收敛性(见文献[2]):

$$\frac{d}{d\tau}\theta_D(\tau) = R_D^{-1}(\tau)f(\theta_D(\tau)), \quad (8)$$

$$\frac{d}{d\tau}R_D(\tau) = g(\theta_D(\tau)) - R_D(\tau). \quad (9)$$

$$f(\theta_D(\tau)) = E\{\Phi(t, \theta_D)e(t, \theta_D)\}, \quad (10)$$

$$g(\theta_D(\tau)) = E\{\Phi(t, \theta_D)\Phi^T(t, \theta_D)\}, \quad (11)$$

3 辨识算法

当采用递推算法(5)~(7)辨识系统时, 必须考虑如何导出 $R(t)$ 的求逆的问题. 本文采用的求逆方法是递推解法, 这就导出了本文的对称超松弛形递推算法, 因为实际计算时, 递推算法只能进行有限步, 因此递推算法(6)与 $R(t)$ 求逆的递推联合起来就形成本文研究的对称超松弛形递推算法. 本文研究的算法能降低极小化问题的计算时间和加快收敛的速度, 适合于求解大规模系统辨识问题.

不妨设: $P(t) = R^{-1}(t)$ 有

$$R(t)P(t) = I, \quad (12)$$

解方程式(12)的定常递推的公式总可写成为下列形式

$$P(t, k+1) = U(t)P(t, k) + B^{-1}(t). \quad (13)$$

为使递推算法(13)对称化, 给出的递推公式如下:

$$P(t, k+1/2) = W(t)P(t, k) + V^{-1}(t), \quad (14)$$

$$P(t, k+1) = M(t)P(t, k+1/2) + N^{-1}(t). \quad (15)$$

其中

$$W(t) = V^{-1}(t)F(t),$$

$$V(t) - F(t) = R(t),$$

$$V(t) = (D(t) - wL(t))/w, \quad (16)$$

$$F(t) = ((1-w)D(t) + wU(t))/w, \quad (17)$$

$$M(t) = N^{-1}(t)G(t),$$

$$N(t) - G(t) = R(t),$$

$$N(t) = (D(t) - wU(t))/w, \quad (18)$$

$$G(t) = ((1-w)D(t) + wL(t))/w. \quad (19)$$

式中的 w 是松弛因子, 有

$$V(t) = N^T(t), \quad (20)$$

$$F(t) = G^T(t), \quad (21)$$

$$\begin{aligned} P(t, k+1) &= M(t)(W(t)P(t, k) + V^{-1}(t)) + N^{-1}(t) \\ &= M(t)W(t)P(t, k) + M(t)V^{-1}(t) + N^{-1}(t). \end{aligned} \quad (22)$$

不妨设

$$H(t) = M(t)W(t),$$

$$B(t) = (M(t)V^{-1}(t) + N^{-1}(t))^{-1}.$$

可推得

$$B(t) = \frac{1}{w(2-w)}(D(t) - wL(t))D^{-1}(t)(D(t) - wU(t)), \quad (23)$$

$$\begin{aligned} H(t) &= M(t)W(t) \\ &= N^{-1}(t)G(t)V^{-1}(t)F(t) \\ &= N^{-1}(t)(N(t) - R(t))V^{-1}(t)(V(t) - R(t)) \\ &= (I - N^{-1}(t)R(t))(I - V^{-1}(t)R(t)) \\ &= I - (N^{-1}(t) + V^{-1}(t) - N^{-1}(t)R(t)V^{-1}(t))R(t). \end{aligned}$$

得

$$H(t) = I - B^{-1}(t)B(t). \quad (24)$$

其中 $V(t)$ 和 $N(t)$ 是易逆的矩阵, $D(t), L(t), U(t)$ 分别为 $R(t)$ 的严格对角阵, 严格下三角阵, 严格上三角阵, 且有

$$R(t) = D(t) - L(t) - U(t).$$

仅反复利用(13)可导出

$$P(t, k+1) = H^{k+1}(t)P(t, 0) + (\sum_{i=0}^k H^i(t))B^{-1}(t). \quad (25)$$

取 $P(t, 0) = 0$ 有

$$P(t, k+1) = (\sum_{i=0}^k H^i(t))B^{-1}(t). \quad (26)$$

当递推次数 $k \rightarrow \infty$, $P(t, k+1) \rightarrow P(t)$; 如果递推过程只进行有限步, 不妨取为有限的 m 步, 则式(6)的递推算法可写成为:

$$\hat{\theta}(t+1) = \hat{\theta}(t) + \gamma(t)(\sum_{i=0}^{m-1} H^i(t+1))B^{-1}(t+1)\Phi(t)[y(t) - \Phi^T(t)\hat{\theta}(t)], \quad (27)$$

$$t = 0, 1, 2, \dots, N.$$

则由(27)和(5), (7)生成的递推算法, 本文称为拟线性对称超松弛形两步递推辨识算法。

它的收敛性等价于其连带常微分方程(28)或(29)和(9)的收敛性.

$$\frac{d}{d\tau} \theta_D(\tau) = \left(\sum_{i=0}^{n-1} H^i(\tau) \right) B^{-1}(\tau) f(\theta_D(\tau)) \quad (28)$$

$$\text{或} \quad \frac{d}{d\tau} \theta_D(\tau) = P(\tau, m) f(\theta_D(\tau)). \quad (29)$$

关于 $R(\tau)$ 的连带方程与式(9)相同.

4 收敛性分析

下面将分析递推公式(5), (27), (7)的收敛性, 在分析收敛性之前, 先给出几个条件.

条件 1 式(7)中的 $R(t)$ 是正定矩阵, 当 $t \rightarrow \infty$ 时, 有

$$\lim_{t \rightarrow \infty} R(t) = R > \delta I.$$

式中 δ 是任给定的大于 0 的正数.

条件 2 正定矩阵 $R(t)$ 的分解是唯一的. 且有

$$R(t) = D(t) - L(t) - U(t)$$

和

在上述条件下, 有如下几个定理成立.

定理 1 在条件 1 和 2 成立的前提下, 当 $t \rightarrow \infty$ 时, 有下述公式成立:

- A1) $R^{-1}(t) \rightarrow R^{-1}$;
- A2) $B(t) \rightarrow B$;
- A3) $B^{-1}(t) \rightarrow B^{-1}$;
- A4) $P(t, m) \rightarrow P(m)$.

证 仅证明 A1), 其它的公式同理可得.

$$\begin{aligned} \|R^{-1}(t) - R^{-1}\| &= \|R^{-1}(t)(R - R(t))R^{-1}\| \\ &\leq \|R^{-1}(t)\| \|R - R(t)\| \|R^{-1}\| \\ &\leq \delta^{-1} \|R - R(t)\| \delta^{-1} \quad (\text{当 } t \rightarrow \infty \text{ 时}) \\ &= \delta^{-2} \|R - R(t)\|. \end{aligned}$$

由 $\delta > 0$ 的任意性知, 则当 $t \rightarrow \infty$ 时, 有

$$R^{-1}(t) \rightarrow R^{-1}$$

成立. 证毕.

定理 2 如果 X 是正半定矩阵且 $k > 1$ 是一给定整数, 则存在唯一的一正半定矩阵 Y , 使 $Y^k = X$. 如果 X 正定, 则 Y 正定.

证 见 [10].

定理 3 式(24)中的矩阵 $B^{-1}R$ 的特征值当 $0 < w < 2$ 时, 为小于 1 的正实数.

证. 1) 矩阵 $B^{-1}R$ 的特征值正实数

不妨设矩阵 $B^{-1}R$ 的任一特征值为 λ 及其对应的特征向量为 x , 有

$$\lambda x = B^{-1}R x.$$

即 $\lambda Bx = Rx$. 两边同乘以 x^T 得

$$\lambda = x^T R x / x^T B x.$$

同理得:

$$\lambda^T = \mathbf{x}^T R \mathbf{x} / \mathbf{x}^T B \mathbf{x} = \lambda.$$

也就是 $\lambda = \lambda^T$ 故得矩阵 $B^{-1}R$ 的特征值正实数成立。

2) 矩阵 $B^{-1}R$ 的特征值小于 1。

由(23)和定理 2 得

$$\begin{aligned} & (D - wL)D^{-1}(D - wU) - w(2 - w)R \\ &= (1 - w)^2 D + w(1 - w)(L + U) + wLD^{-1}U \\ &= (1 - w)^2 D + w(1 - w)(L + U) + w^2 LD^{-\frac{1}{2}}U, \end{aligned}$$

且 $LD^{-\frac{1}{2}} = (D^{-\frac{1}{2}}U)^T$. 则对任意非零向量 \mathbf{x} , 且令 $y = D^{-\frac{1}{2}}U\mathbf{x}$, 即 $D^{\frac{1}{2}}y = U\mathbf{x}$, 可得

$$\begin{aligned} & \mathbf{x}^T((D - wL)D^{-1}(D - wU) - w(2 - w)R)\mathbf{x} \\ &= (1 - w)^2 \mathbf{x}^T D \mathbf{x} + w(1 - w)(y^T D^{\frac{1}{2}} \mathbf{x} + \mathbf{x}^T D^{\frac{1}{2}} y) + w^2 y^T y \\ &= \mathbf{x}^T((1 - w)D^{\frac{1}{2}} + wD^{-\frac{1}{2}}U)^T((1 - w)D^{\frac{1}{2}} + wD^{-\frac{1}{2}}U)\mathbf{x} > 0 \end{aligned}$$

所以 $B - R$ 矩阵仍为正定矩阵。有

$$\lambda = \mathbf{x}^T R \mathbf{x} / \mathbf{x}^T B \mathbf{x} < 1.$$

证毕。

定理 4 如果 R 是正定矩阵且 $2 > w > 0$ 时, 则矩阵 H 的谱半径 $\rho(H)$ 满足

$$\rho(H) < 1.$$

证 由定理 3, 显然成立。

定理 5 如果 R 是正定矩阵, 则矩阵 H 的谱半径 $\rho(H)$ 和矩阵 $R^{\frac{1}{2}}HR^{-\frac{1}{2}}$ 的谱半径有下述关系:

$$\rho(R^{\frac{1}{2}}HR^{-\frac{1}{2}}) \leq \rho(H).$$

证 不妨设矩阵 $R^{\frac{1}{2}}HR^{-\frac{1}{2}}$ 的任一特征值为 λ 及其对应的特征向量为 \mathbf{x} , 有

$$\lambda \mathbf{x} = R^{\frac{1}{2}}HR^{-\frac{1}{2}}\mathbf{x}$$

上式两边同乘 $R^{-\frac{1}{2}}$ 得

$$\begin{aligned} \lambda^2 &= \mathbf{x}^T R^{-\frac{1}{2}} H^T H R^{-\frac{1}{2}} \mathbf{x} / \mathbf{x}^T R^{-1} \mathbf{x} \\ &\leq \rho(H^T H) \|R^{-\frac{1}{2}} \mathbf{x}\|^2 / \|R^{-\frac{1}{2}} \mathbf{x}\|^2 \\ &= \rho(H^T H). \end{aligned}$$

证毕。

定理 6 如果 R 是正定矩阵, 则对任意非零向量 \mathbf{x} 有

$$\mathbf{x}^T P(m) \mathbf{x} = \mathbf{x}^T (H^{m-1} + \dots + I) B^{-1} \mathbf{x} > 0.$$

证 由恒等式 $I - H^m = (I - H)(H^{m-1} + \dots + I)$ 和 $I - H = B^{-1}R$ 可得

$$\mathbf{x}^T P(m) \mathbf{x} = \mathbf{x}^T (H^{m-1} + \dots + I) B^{-1} \mathbf{x} = \mathbf{x}^T (I - H^m) R^{-1} \mathbf{x}.$$

令 $y = R^{-\frac{1}{2}} \mathbf{x}$ 有 $\mathbf{x} = R^{\frac{1}{2}}y$ 和等式 $\mathbf{x}^T P(m) \mathbf{x} = \mathbf{x}^T P^T(m) \mathbf{x}$ 可推导得

$$\begin{aligned} 2\mathbf{x}^T P(m) \mathbf{x} &= 2y^T R^{\frac{1}{2}} (I - H^m) R^{-\frac{1}{2}} y \\ &= y^T (2I - R^{\frac{1}{2}} H^m R^{-\frac{1}{2}} - R^{-\frac{1}{2}} (H^m)^T R^{\frac{1}{2}}) y \\ &= y^T (I - (R^{\frac{1}{2}} H^m R^{-\frac{1}{2}})^T R^{\frac{1}{2}} H^m R^{-\frac{1}{2}}) y \\ &\quad + y^T (I - R^{\frac{1}{2}} H^m R^{-\frac{1}{2}})^T (I - R^{\frac{1}{2}} H^m R^{-\frac{1}{2}}) y. \end{aligned}$$

$$y^T (I - R^{\frac{1}{2}} H^m R^{-\frac{1}{2}})^T (I - R^{\frac{1}{2}} H^m R^{-\frac{1}{2}}) y \geq 0$$

和定理 5 及定理 4 可推导得

由

$$\begin{aligned}
 2x^T P(m)x &= x^T P(m)x + x^T P^T(m)x \\
 &= y^T(I - (R^{1/2}H^m R^{-1/2})^T R^{1/2} H^m R^{-1/2})y \\
 &\quad + y^T(I - R^{1/2}H^m R^{-1/2})^T(I - R^{1/2}H^m R^{-1/2})y \\
 &\geq y^T(I - \rho^2(H^m))y > 0.
 \end{aligned}$$

证毕.

定理 7 如果递推程序(5)是收敛的, 满足假设条件 1 和 2, 且 $2 > w > 0$. 则递推程序(14)不管参数估计值的初始值如何选择, 参数估计值 $\hat{\theta}(t)$ 总是大范围一致收敛的, 即有

$$\lim_{t \rightarrow \infty} \hat{\theta}(t) = \theta_0.$$

证 下面首先构造一个 Lyapunov 函数:

$$V(t, \theta_D) = \frac{1}{2} E e^T(t, \theta_D) e(t, \theta_D).$$

$$\begin{aligned}
 \text{有 } \frac{d}{dt} V(t, \theta_D) &= \frac{d}{d\theta_D} V(t, \theta_D) \Big|_{\theta_D = \theta_D(\tau)} \frac{d}{d\tau} \theta_D(\tau) \\
 &= -f^T(\theta_D(\tau)) P(\tau, m) f(\theta_D(\tau)) \\
 &= -f^T(\theta_D(\tau)) P(m) f(\theta_D(\tau)) - f^T(\theta_D(\tau))(P(\tau, m) - P(m)) f(\theta_D(\tau)).
 \end{aligned}$$

由定理 1 得

$$\frac{d}{dt} V(t, \theta_D) \approx -f^T(\theta_D(\tau)) P(m) f(\theta_D(\tau)).$$

又由定理 6, 有

$$\frac{d}{dt} V(t, \theta_D) < 0.$$

也就是

$$\lim_{t \rightarrow \infty} \hat{\theta}(t) = \theta_0.$$

证毕.

H 实际是解方程组 $R(t)P(t)=I$ 的递推矩阵, 因而 $k=m$ 时的渐近收敛速度是 $k=1$ 时的 m 倍, 而计算也恰好是 m 次. 则在实时辨识时, 为使程序设计简单, 要取 $m=1$ 或 $m=2$. 当要求有快的收敛速度时, 故选 m 适当大是适宜的. 从大量的仿真结果知, $m \geq 3$ 时得到的辨识结果较为理想.

5 仿真结果

考虑下述二个系统的仿真.

例 1

$$\begin{aligned}
 y(t) &= 1.5y(t-1) + 0.7y(t-2) \\
 &= 1.0u(t-1) + 0.5u(t-2) + e(t) \\
 &\quad - 1.0e(t-1) + 0.2e(t-2).
 \end{aligned}$$

例 2 $y(t) = 1.6y(t-1) + 1.61y(t-2) - 0.776y(t-3)$

$$\begin{aligned}
 &= 1.2u(t-1) - 0.95u(t-2) + 0.2u(t-3) + e(t) + 0.1e(t-1) \\
 &\quad + 0.25e(t-2) + 0.873e(t-3).
 \end{aligned}$$

其中输入 $u(t)$ 是用的幅值为 1 的 PRBS 序列, $e(t)$ 是均值为零, 方差为 1 的白噪声序列.

$y(t) = 0.02$, $R(0) = 10^4 I$. 输入输出的观测个数为 500, $m=2$.

由本文的两步递推算式得到的估计参数随递推次数的变化的情况在表 1, 2 中给出,

其反映的结果与本文研究的收敛定理一致。表 2 中还给出了 PLR 和 RPEM 算法的结果^[2],由表 2 中的结果比较可看出,本文近似求逆的计算结果与精确求逆的计算结果基本一致。

仿真结果还表明,上述的递推算法基本上克服了使用求逆公式的递推算法在数值上的不可靠性及造成逆矩阵的不确定的特点。

表 1 例 1 的参数随递推次数的变化

递推次数 <i>t</i>	辨识参数					
	a1	a2	b1	b2	c1	c2
50	-0.120	-0.092	0.009	0.011	0.008	0.004
100	-0.717	-0.021	0.260	0.203	-0.004	0.011
150	-1.573	0.745	1.004	0.247	-0.530	-0.150
200	-1.628	0.848	0.917	0.267	-1.269	0.094
250	-1.480	0.722	0.910	0.369	-0.809	0.220
300	-1.855	0.963	1.219	0.096	-1.372	0.099
350	-1.589	0.828	1.369	0.200	-1.072	0.227
400	-1.666	0.850	0.983	0.519	-1.313	0.545
500	-1.460	0.681	1.087	0.619	-0.882	0.134
真值	-1.500	0.700	1.000	0.500	-1.000	0.200

表 2 例 2 的参数随递推次数的变化

递推次数 <i>t</i>	辨识参数							
	a1	a2	a3	b1	b2	b3	c1	c2
50	-0.009	0.000	0.000	0.001	0.000	-0.000	0.002	0.001
100	-0.083	0.051	0.079	0.009	0.003	-0.005	0.011	0.007
150	-0.333	0.147	0.172	0.035	-0.023	-0.049	0.094	0.048
200	-0.523	0.412	0.214	0.190	-0.078	-0.063	0.086	0.080
250	-1.197	1.030	-0.352	0.676	-0.636	-0.292	0.360	0.437
300	-1.381	1.435	-0.594	1.320	-0.730	0.368	0.295	0.324
350	-1.508	1.417	-0.668	1.333	-1.110	0.157	0.236	0.234
400	-1.539	1.504	-0.709	1.199	-0.826	0.117	0.062	0.451
500	-1.593	1.623	-0.760	1.279	-0.858	0.162	0.182	0.201
PLR 500	-1.593	1.599	-0.767	1.206	-0.985	0.160	0.144	0.212
RPEM 500	-1.575	1.582	-0.748	1.206	-0.946	0.171	0.178	0.200
真值	-1.6	1.61	-0.776	1.2	-0.95	0.2	0.1	0.25

参 考 文 献

- [1] Ljung, L.. Analysis of a General Recursive Prediction Error Identification Algorithm. Automatica, 1981, 17, 89-100
- [2] Ljung, L. and Soderstrom, T.. Theory and Practice of Recursive Identification. The MIT Press, Cambridge, Mass., 1983
- [3] 叶春生. MIMO 系统的循环递推算法, 湖北工学院学报, 1991, 11(3), 25-30
- [4] 叶春生, 叶邦华. 线性系统拟线性超松弛型递推辨识算法、控制理论及其应用年会论文集, 杭州, 1991

- [5]叶春生.工业锅炉的热工试验建模、仿真及计算机辅助设计.华中理工大学博士学位论文,1992
- [6]方崇智,萧德云.过程辨识.北京:清华大学出版社,1988
- [7]韩崇昭,王月娟,万百五.随机系统理论.西安:西安交通大学出版社,1987
- [8]王松桂.线性模型的理论及其应用.合肥:安徽教育出版社,1987
- [9]黄琳.系统与控制理论中的线性代数.北京:科学出版社,1984
- [10]Horn, R. A. and Johnson, C. R.. Matrix Analysis. Cambridge University Press, Cambridge, 1985

Pseudolinear Symmetric Successive Overrelaxation Type of Two-Step Recursive Identification Algorithm

YE Chunsheng, YU Jun and XIONG Youlun

(First Department of Mechanical Engineering, Huazhong University of Science and Technology • Wuhan, 430074, PRC)

Abstract: A new algorithm for multi-input multi-output linear systems, pseudolinear symmetric successive overrelaxation type of two-step recursive identification algorithm, is proposed in this paper. The algorithm convergence is investigated by method of ordinary differential equation. Simulation shows that the algorithm is consistent with the theorem of asymptotic convergence in this paper.

Key words: pseudolinear; symmetric successive overrelaxation; two-step recursive identification; convergence

本文作者简介

叶春生 1962年生.1983年获西安交通大学信控系学士学位,1986年获华中理工大学系统工程专业硕士学位,1988年以来在华中理工大学机械学专业攻读博士学位.主要研究领域为工业锅炉的建模、仿真和计算机辅助设计.

余俊 1921年生.1944年毕业于武汉大学机械系,1956年毕业于哈尔滨工业大学机械系研究生班,现为华中理工大学机械系教授,并为机械学专业博士生导师.近十多年来主要致力于机械优化设计,计算机辅助设计的研究.

熊有伦 1939年生.1966年毕业于西安交通大学研究生班,后分配到华中理工大学机械一系任教,1980年至1982年赴美国 Sheffield 大学控制工程系进修访问,1988年至1989年作为美国 Salford 大学航空和机械工程系客座教授从事机器人多指抓取的研究,现任华中理工大学教授和数控教研室主任.主要研究领域为机器人基本理论和应用技术.