

一类非线性系统的自校正预报器及其应用

刘铁男

(大庆石油学院)

摘 要

本文对一类较广泛的非线性随机系统,提出了两种自校正预报器(简记为STP)和一种自校正递推预报器(简记为STRP),并且给出了在油田生产上的应用实例。

一、引 言

Wittenmark 对 SISO 线性随机系统,提出了 STP^[1]。之后 Keyser 等人对同样系统,给出了 STRP^[2]。邓自立直接从原始的多变量线性模型出发,给出了两种多变量 STRP^[3]。

本文对单输出非线性随机系统,提出了两种 STP 和一种 STRP。并且在油田采油指数的预报中得到令人满意的结果,预报误差的相对值均在 2% 以内。

二、非线性自校正预报器

我们考虑的非线性模型是有实际背景的。在某油田生产中,由自喷转为用电(油)泵抽油,其中一个重要的生产指标——采油指数发生较大变化,主要的影响因素是流饱压力比($P_1 = P_w/P_b$)的变化,其次是地饱压力比($P_2 = P_d/P_b$)的变化(P_2 较 P_1 有相对稳定性),并且 P_1 和 P_2 是可量测的。现在生产上急需研究采油指数 η 随 P_1 和 P_2 变化而变化的趋势。 η 的机理静态模型为

$$\eta = \frac{\eta_b}{[a_1 + b_1 \log(P_2)]P_1 + a_2(P_2)b_2} = f[P_1, P_2, \underline{b}], \quad (1)$$

其中 η_b 是饱和压力下的采油指数, $\underline{b}^T = (a_1, a_2, b_1, b_2)$ 是未知参数。

因为生产过程是一个动态系统,并且总存在一些随机干扰。所以把(1)式这样一类模型演化为下面的非线性随机动态模型,更符合实际情况(用我们习惯的变量表示):

$$A(q^{-1})y(k) = f[u(k-d), \underline{b}] + C(q^{-1})e(k), \quad (2)$$

其中 $y(k)$ 是一维输出, $u(k)$ 是 r 维已知输入, $f[\cdot, \cdot]$ 是结构已知的非线性函数, d 是时滞, $\underline{b}$ 是 r 维参数向量, 而后移算子 q^{-1} 的多项式为

$$A(q^{-1}) = 1 + A_a(q^{-1}) = 1 + \sum_{i=1}^n a_i q^{-i}, \quad (3)$$

$$C(q^{-1}) = 1 + C_c(q^{-1}) = 1 + \sum_{i=1}^n C_i q^{-i}. \quad (4)$$

模型 (2) 满足条件: (A)、 $A(z)$ 、 $C(z)$ 的零点在单位圆外; (B)、 $e(k)$ 是零均值白噪声。模型 (2) 可以包括较广的一类非线性模型。对它我们先导出两种 STP。

(一) 第一种自校正预报器

我们记 $\hat{y}(k+l|k)$ 为 $y(k+l)$ 的基于 k 时刻已知信息的向前 l 步预报。引入指标函数

$$V = E\{[y(k+l) - \hat{y}(k+l|k)]^2\} = E\{\varepsilon(k+l)^2\}. \quad (5)$$

我们的目的是寻求最优 (最小方差) 预报使指标函数 (5) 达到最小。为此引入下列等式^[4]:

$$C(q^{-1}) = A(q^{-1})G(q^{-1}) + q^{-l}F(q^{-1}), \quad (6)$$

$$G(q^{-1}) = 1 + G_g(q^{-1}) = 1 + \sum_{i=1}^{l-1} g_i q^{-i}, \quad (7)$$

$$F(q^{-1}) = \sum_{i=0}^{n-1} f_i q^{-i}. \quad (8)$$

我们有如下定理:

定理 1 当模型 (2) 结构和参数已知时, 并且满足相应条件 (A) 和 (B), 则有极小化指标函数 (5) 的最优预报器

$$\hat{y}(k+l|k) = G(q^{-1})f[u(k+l-d), \underline{b}] + F(q^{-1})y(k) - C_c(q^{-1})\hat{y}(k+l|k). \quad (9)$$

证 把 (2) 式中 k 换为 $k+l$, 该式两边乘 $G(q^{-1})$ 得

$$G(q^{-1})A(q^{-1})y(k+l) = G(q^{-1})f[u(k+l-d), \underline{b}] + C(q^{-1})G(q^{-1})e(k+l).$$

应用 (6) 式并整理得

$$C(q^{-1})[y(k+l) - G(q^{-1})e(k+l)] = F(q^{-1})y(k) + G(q^{-1})f[u(k+l-d), \underline{b}],$$

$$y(k+l) = C(q^{-1})^{-1}\{F(q^{-1})y(k) + G(q^{-1})f[u(k+l-d), \underline{b}]\} + G(q^{-1})e(k+l).$$

(10)

把(10)代入(5)式,并注意上式最后项与其它项不相关,可得最优预报器

$$\hat{y}(k+l|k) = C(q^{-1})^{-1} \{F(q^{-1})y(k) + G(q^{-1})f[u(k+l-d), \underline{b}]\}. \quad (11)$$

预报误差为 $\varepsilon(k+l) = G(q^{-1})e(k+l)$. 上式两边乘 $C(q^{-1})$ 并注意(4)式得

$$\hat{y}(k+l|k) = F(q^{-1})y(k) + G(q^{-1})f[u(k+l-d), \underline{b}] - C_e(q^{-1})\hat{y}(k+l|k).$$

证毕.

于是有预报模型

$$\begin{aligned} y(k) &= \hat{y}(k|k-l) + \varepsilon(k) \\ &= F(q^{-1})y(k-l) + f[u(k-d), \underline{b}] + G_g(q^{-1})f[u(k-d), \underline{b}] - \\ &\quad C_e(q^{-1})\hat{y}(k|k-l) + \varepsilon(k). \end{aligned} \quad (12)$$

上式中出现了 q^{-1} 的多项式作用于非线性函数的情况. 一些非线性自校正调节器(如文[5])也有类似情形. 我们规定: $q^{-1}f[u(k-d), \hat{b}(k-1)] = f[u(k-d-1), \hat{b}(k-2)]$.

于是

$$G(q^{-1})f[u(k-d), \hat{b}(k-1)] = f[u(k-d), \hat{b}(k-1)] + \sum_{i=1}^{l-1} g_i f[u(k-d-i), \hat{b}(k-i-1)].$$

为方便, 令

$$f[u(k-d-i), \hat{b}(k-i-1)] = F_{k-i-1}, \quad i=0, 1, \dots, l-1, \quad (13)$$

$$z_1(k) = y(k) - f[u(k-d), \hat{b}(k-1)] = y(k) - F_{k-1}. \quad (14)$$

另外(12)式关于参数是非线性的, 须用两套公式交互地辨识参数 $\underline{b}$ 和其余参数. 把式(13)、(14)用于(12)式有

$$z_1(k) = F(q^{-1})y(k-l) + G_g(q^{-1})F_{k-2} - C_e(q^{-1})\hat{y}(k|k-l) + \varepsilon_1(k). \quad (15)$$

因为 $\{u(k-d-i)\}$ 和 $\{\hat{b}(k-i-1)\}$, $i=0, 1, \dots$ 已知, 所以 $\{F_{k-i-1}, i=0, 1, \dots\}$ 是已知常数序列. 于是(15)式是线性单输出系统. 引入如下向量:

$$\underline{\theta}^T = [f_0, f_1, \dots, f_{n-1}, g_1, \dots, g_{l-1}, c_1, \dots, c_n],$$

$$\underline{\phi}(k)^T = [y(k-l), \dots, y(k-l-n+1), F_{k-2}, \dots, F_{k-l},$$

$$-\hat{y}(k-1|k-l-1), \dots, -\hat{y}(k-n|k-l-n)].$$

于是(15)式可写成

$$\underline{z}_1(k) = \underline{\phi}(k)^T \underline{\theta} + \varepsilon_1(k). \quad (16)$$

对于(16)式, 文[6]的算法有如下形式^[7]:

$$\hat{\underline{\theta}}(k) = \hat{\underline{\theta}}(k-1) + \delta \|\underline{\phi}(k)\|^{-2} \underline{\phi}(k) \{z_1(k) - \underline{\phi}(k)^T \hat{\underline{\theta}}(k-1)\}, \quad (17)$$

这里 δ 是正常数, $0 < \delta \leq 1$, 而 $\|\cdot\|$ 是欧氏范数. 把 $\hat{\underline{\theta}}(k)$ 代入 (12) 式, 并令 $z_2(k) = y(k) - \underline{\phi}(k)^T \hat{\underline{\theta}}(k)$, 则有

$$z_2(k) = f[u(k-d), \underline{b}] + \varepsilon_2(k). \quad (18)$$

对 (18) 式, 文 [6] 的算法有如下形式 [7]:

$$\begin{aligned} \hat{\underline{b}}(k) = & \hat{\underline{b}}(k-1) + \delta \|\nabla_{\underline{b}} f[\hat{\underline{b}}(k-1), k]\|^{-2} \nabla_{\underline{b}} f[\hat{\underline{b}}(k-1), k] \{z_2(k) \\ & - f[u(k-d), \hat{\underline{b}}(k-1)]\}, \end{aligned} \quad (19)$$

其中 $\nabla_{\underline{b}} f[\hat{\underline{b}}(k-1), k] = \left. \frac{\partial}{\partial \underline{b}} f[u(k-d), \underline{b}] \right|_{\underline{b} = \hat{\underline{b}}(k-1)}.$

于是此 STP 可用如下步骤实现:

1) $f[\cdot, \cdot]$ 的结构可由实际系统的机理来确定, 而模型 (16) 的阶数可事先离线地确定 [8]. 然后在 k 时刻用算法 (17) 得到 (16) 式中 $\underline{\theta}$ 的估值, 用式 (19) 求 (18) 式中 $\underline{b}$ 的估值.

2) 把 $\hat{\underline{\theta}}(k)$ 和 $\hat{\underline{b}}(k)$ 代入 (12) 式 (注意 $\hat{\underline{b}}(k)$ 代入 (12) 式第二项), 于是可得向前 l 步 STP 为

$$\begin{aligned} \hat{y}(k+l|k) = & f[u(k+l-d), \hat{\underline{b}}(k)] + \sum_{i=0}^{n-1} \hat{f}_i(k) y(k-i) \\ & + \sum_{i=1}^{l-1} \hat{g}_i(k) f[u(k+l-d-i), \hat{\underline{b}}(k-i)] - \sum_{i=1}^n \hat{c}_i(k) \hat{y}(k+l-i|k-i). \end{aligned}$$

本文在分析给出的两种 STP 和一种 STRP 的渐近最优性时, 用到文 [9] 的定理 3 和 4. 须指出的是: 上述定理对处理 “自校正” 问题而得到的预报模型 (如 (12) 及下文 (23) 式) 仍成立. 这时 (12) 和 (23) 式中 $\varepsilon(k+l)$ 是零均值白噪声的滑动平均, 并且分别与相应模型的其它项不相关. 于是由文 [9] 定理证明知, 对这样的 $\varepsilon(k+l)$ 仍可证明 $\underline{\theta}^*$ ($\underline{\theta}$ 的真值) 是相应算法对应的微分方程的平稳点, 而原定理中关于零均值白噪声的条件, 也只是在证明这一点时用到了.

如果残差 $\varepsilon_1(k)$ 和 $\varepsilon_2(k)$ 分别与 (16) 和 (18) 式右边其它项不相关, 并且都有零均值, 则如上述, 当 $k \rightarrow \infty$ 时, 有 $\lim_{k \rightarrow \infty} \hat{\underline{\theta}}(k) = \underline{\theta}^*, a.s.$; $\lim_{k \rightarrow \infty} \hat{\underline{b}}(k) = \underline{b}^*, a.s.$ (这里 $\underline{\theta}^*$ 、 $\underline{b}^*$ 表示相应参数的真值). 于是 STP (20) 渐近于最优预报器 (9). 若

$\varepsilon_1(k)$ 和 $\varepsilon_2(k)$ 不满足上述条件, 则STP(20)将是次优的。

(二) 第二种自校正预报器

定理 2 当模型(2)结构和参数已知时, 并且满足相应条件(A)和(B), 则有极小化指标函数(5)的最优预报器

$$\hat{y}(k+l|k) = - \sum_{i=1}^n a_i \hat{y}(k+l-i|k-i) + f[u(k+l-d), \underline{d}] + \sum_{i=0}^{n-1} f_i e(k-i). \quad (21)$$

证 把(2)式中 k 换为 $k+l$, 并应用(6)式得

$$A(q^{-1})[y(k+l) - G(q^{-1})e(k+l)] = f[u(k+l-d), \underline{b}] + F(q^{-1})e(k),$$

$$y(k+l) = G(q^{-1})e(k+l) + A(q^{-1})^{-1}[f[u(k+l-d), \underline{b}] + F(q^{-1})e(k)].$$

(22)

把(22)式代入(5)式, 并注意上式右边两项是不相关的, 于是有最优预报器

$$\hat{y}(k+l|k) = A(q^{-1})^{-1}[f[u(k+l-d), \underline{b}] + F(q^{-1})e(k)].$$

上式两边乘 $A(q^{-1})$, 并应用(3)式得

$$\hat{y}(k+l|k) = - \sum_{i=1}^n a_i \hat{y}(k+l-i|k-i) + f[u(k+l-d), \underline{b}] + \sum_{i=0}^{n-1} f_i e(k-i). \quad \text{证毕.}$$

相应的预报模型为

$$y(k) = -A_0(q^{-1})\hat{y}(k|k-l) + f[u(k-d), \underline{b}] + F(q^{-1})e(k-l) + \varepsilon(k). \quad (23)$$

并且若假定观测起点 $k_0 = -\infty$, $C(z)$ 的零点在单位圆外, 则(21)中 $\{e(k)\}$ 可用已知数据计算为

$$e(k) = [C(q^{-1})]^{-1}\{A(q^{-1})y(k) - f[u(k-d), \underline{b}]\}, \quad (24)$$

其中 $[C(q^{-1})]^{-1}$ 可象文[3]那样计算。

当模型(23)结构和参数未知且 $k_0 \neq -\infty$ 时, 可用如下步骤实现STP:

1) 象(一)节一样确定(23)的结构, 用文[6]的算法估计其参数, 为此置(这里 $\underline{b}^r = (b_1, \dots, b_r)$)

$$\underline{\theta}^- = (a_1, \dots, a_n, \underline{b}^-, f_0, \dots, f_{n-1}).$$

为方便, 令

$$F(\underline{\theta}, k) = -A_0(q^{-1})\hat{y}(k|k-l) + f[u(k-d), \underline{b}] + F(q^{-1})e(k-l).$$

于是(23)式可写成

$$y(k) = F(\underline{\theta}, k) + \varepsilon(k). \quad (25)$$

上式中的 $e(k-l-i)$, $i=0, 1, \dots, n-1$ 可用下式的计算值代替:

$$\hat{e}(k) = y(k) - F(\underline{\hat{\theta}}(k-1), k), \quad (26)$$

对于 (25) 式, 文[6]的算法有如下形式^[7]:

$$\hat{\theta}(k) = \hat{\theta}(k-1) + \delta \|\nabla_{\theta} F[\hat{\theta}(k-1), k]\|^{-2} \nabla_{\theta} F[\hat{\theta}(k-1), k] \{y(k) - F[\hat{\theta}(k-1), k]\}, \quad (27)$$

其中 $\nabla_{\theta} F[\hat{\theta}(k-1), k] = \left. \frac{\partial}{\partial \theta} F[\theta, k] \right|_{\theta = \hat{\theta}(k-1)}$.

2) 把 $\hat{\theta}(k)$ 和 $\{\hat{e}(k)\}$ 代入 (21) 式, 可得到 STP 如下:

$$\hat{y}(k+l|k) = - \sum_{i=1}^n \hat{a}_i(k) \hat{y}(k+l-i|k-i) + f[u(k+l-d), \hat{b}(k)] + \sum_{i=0}^{n-1} \hat{f}_i(k) \hat{e}(k-i). \quad (28)$$

前面已指出, 对于 (23) (即 (25)) 这样的预报模型, 文[9]定理 4 仍成立, 于是当

$k \rightarrow \infty$ 时, $\lim_{k \rightarrow \infty} \hat{\theta}(k) = \theta^*$, a.s.. 于是 (28) 将渐近于最优预报器 (21),

三、非线性自校正递推预报器

我们从非线性模型 (2) 出发给出 STRP. 首先把 (2) 式中 k 换为 $k+l$, 并用 (3) 式得

$$y(k+l) = -A_a(q^{-1})y(k+l) + f[u(k+l-d), b] + C(q^{-1})e(k+l). \quad (29)$$

设 F_k 是由 $\{e(k), u(k-d), e(k-1), u(k-d-1), \dots\}$ 生成的 σ -代数. 设 (29) 式结构和参数已知. 由条件数学期望的性质^[10]知, (5) 式可写成

$$V = E\{E[\hat{y}(k+l|k) - y(k+l)]^2 | F_k\}, \quad l=1, 2, \dots, L. \quad (30)$$

于是由 (30) 和 (26) 式可得最优预报器为

$$\hat{y}(k+l|k) = \begin{cases} - \sum_{i=1}^n a_i \hat{y}(k+l-i|k) + f[u(k+l-d), \underline{b}] + \sum_{i=l}^n c_i e(k+l-i) & \text{当 } 1 \leq l \leq n \text{ 时,} \\ - \sum_{i=1}^n a_i \hat{y}(k+l-i|k) + f[u(k+l-d), \underline{b}] & \text{当 } l > n \text{ 时.} \end{cases} \quad (31)$$

在上式中规定: $i \geq l$ 时, $\hat{y}(k+l-i|k) = y(k+l-i)$, 并且在满足前述条件时, 可由 (24) 式计算 $\{e(k)\}$.

当模型 (29) 结构和参数未知且 $k_0 = -\infty$ 时, 可用如下步骤实现 STRP:

1) 用前述方法确定 (29) 式的结构, 用形如 (27) 式的算法估计预报器 (31) 中

的参数, 而(31)式的 $\{e(k)\}$ 用形如(26)式来计算;

2) 把计算出的 $\hat{\theta}(k)$ 和 $\hat{e}(k)$ 代入(31)式可得到STRP. 并且由文[9]定理4知, $k \rightarrow \infty$ 时, $\lim_{k \rightarrow \infty} \hat{\theta}(k) = \theta^*$, a.s.. 则此STRP将渐近于最优预报器(31).

为进一步提高STP和STRP的预报精度, 可以在状态预报之前, 先对模型中参数进行预报, 详见下节.

四、应用实例

我们应用本文给的方法对采油指数 η 作了大量预报, 处理了七个区块, 21组数据, 都得到很好的结果. 为省篇幅仅举两个区块六组数据为例, 其数据列在表(1)中. 依据表(1)数据, 建立了如下模型:

$$\eta(k) = a_1 \eta(k-1) + a_2 \eta(k-2) + f[P_1, P_2, b] + c_1 e(k-1) + c_2 e(k-2) + e(k), \quad (32)$$

其中 $f(\cdot, \cdot, \cdot)$ 的结构同(1)式.

为进一步提高状态预报精度, 我们对参数也作了与状态同步数预报^[11]. 由表1可见, η 的实际数据有一个下降的趋势, 在依据上述数据对(32)式中参数估计时, 发现

表1 两个区块六组数据

地区 P ₁ \ P ₂	区块 1			区块 2		
	1.0	1.1	1.2	1.0	1.1	1.2
1.0	3.65	3.72	3.81	3.91	3.95	3.97
0.95	3.32	3.51	3.59	3.52	3.59	3.69
0.90	2.93	3.08	3.28	3.06	3.24	3.43
0.85	2.54	2.81	3.04	2.80	3.04	3.26
0.80	2.30	2.54	2.83	2.53	2.80	3.06
0.75	2.15	2.42	2.72	2.37	2.65	2.94
0.70	1.95	2.30	2.61	2.17	2.49	2.84
0.65	1.83	2.22	2.55	2.09	2.41	2.78
0.60	1.75	2.15	2.50	1.98	2.31	2.68
0.55	1.68	2.07	2.46	1.93	2.25	2.63
0.50	1.62	1.99	2.42	1.88	2.21	2.58

估值序列也有同样趋势, 这启示我们用“参数平均增量”法. 用 $\Delta \theta$ 表示参数的平均增量, 用 $\hat{\theta}^*(k+l)$ 表示对参数的 l 步预报, 则有:

$$\hat{\theta}^*(k+l) = \hat{\theta}(k) + l \cdot \Delta \theta,$$

$$\Delta \theta = \frac{1}{l} \sum_{j=k-l+1}^k [\hat{\theta}(j) - \hat{\theta}(j-1)],$$

表 2 η 的预报值和预报误差的相对值

	预 报 值	相 对 误 差	预 报 值	相 对 误 差	预 报 值	相 对 误 差
区 块 1	1.828	0.84%	2.194	1.2%	2.522	1.1%
	1.748	0.97%	2.120	1.4%	2.481	0.75%
	1.681	-0.54%	2.056	0.59%	2.451	0.38%
	1.621	-0.81%	2.002	-0.64%	2.425	-0.22%
	1.61		1.956		2.345	
	1.568		1.915		2.325	
	1.529		1.878		2.303	
区 块 2	2.01	-1.5%	2.373	1.5%	2.824	0.57%
	1.942	-0.62%	2.309	0.08%	2.743	1.1%
	1.881	-0.05%	2.257	-0.32%	2.686	-0.24%
	1.838		2.213	-0.11%	2.632	0.07%
	1.793		2.145		2.583	0.01%
	1.75		2.113		2.464	
	1.71		2.084		2.426	

我们用 STP 预报了区块 1 的采油指数 η ，取预报步数 $l=4$ 。为省篇幅，对每组数据仅列出了对应最后四个数据的预报值。并且对第一组数据用的是第（一）节的 STP，后两组数据则用第（二）节的 STP。最大预报误差相对值是 1.4%，并且对 η 的未来趋势（数据未知）也作了预报。

用 STRP 预报了区块 2 的采油指数 η 。对其中三组数据，分别取预报步数为 3、4 和 5 并且分别列出了对应其最后 3、4 和 5 个数据的预报值。最大相对误差为 1.5%，并对 η 的未来趋势也作了预报。

五、结 论

本文对较广泛的一类非线性系统给出了两种 STP 和一种 STRP。使“自校正”的概念在非线性系统的领域前进了一步。并且通过对实际非线性时变系统的预报可见，它们对此类系统具有较好的适应性，预报精度较高。提高了传统预报方法的精度。例如，用最小二乘法以曲线拟合处理上述问题，预报的相对误差为 10% 左右。并且本文给出的 STP（特别是第二种）和 STRP 计算量（比对线性系统用最小二乘法辨识）较小，便于应用和推广。

参 考 文 献

- [1] Wittenmark, B., IEEE Trans. Autom. Cont., A Self-tuning Predictor, AC-19 (1974), 848-851.
- [2] Keyser, R. M. C. and A. R. Van Cauwenberghe, A Self-tuning Multistep Predictor Application, Automatica, 17 (1981), 167-174.
- [3] 邓自立、赵永胜等, 多变量多步自校正递推预报器及其应用, 自动化学报, 9, 2 (1983), 241-246.
- [4] Åström, K. J., Introduction to Stochastic Control Theory, Academic Press, New York, (1970), 174-175.
- [5] Zanker, P. and P. E. Wellstead (1979), Practical Features of Self-tuning, Proc. 5th IFAC Symp. System Identification and Parameter Estimation, 1148.
- [6] Z. G. Han (1982), A Recursive Estimates Method of the Nonlinear Stochastic System and its Convergence Analysis, 6th IFAC Symp. on Identification and System Parameter Estimation, Washington D. C. .
- [7] 姜继忱, 关于一类递推算法的进一步探讨, 黑龙江大学自然科学学报, 1, (1982), 18-28.
- [8] Åström, K. J., Eykhoff, P., Automatica, System Identification a Survey, 7 (1971), 123-162.
- [9] 韩志刚, 关于递推算法收敛性分析的常微分方程方法, 黑龙江大学自然科学学报, 1, (1982), 1-13.
- [10] 严士健等, 概率论基础, 科学出版社, (1982), 307-308.
- [11] 韩志刚, 动态系统预报的一种新方法, 自动化学报, 9, 3, (1983), 161-168.

SELF-TUNING PREDICTORS FOR NONLINEAR SYSTEMS AND THEIR APPLICATION

Liu Tienan

(Daqing petroleum Institute)

Abstract

This paper presents two kinds of self-tuning predictors and a kind of self-tuning recursive predictors for nonlinear systems. And a practical example in the oil field production is given.