

随机系统模型参数在线辨识的一种 算法及负荷预报

易允文 李洪心

(中国科学院沈阳自动化研究所)

摘 要

本文提出了一种简化的多变量随机系统状态模型参数在线辨识方法,与最小二乘自适应递推算算法比较,不仅需要辨识的参数减少,而且针对一类模型参数缓慢变化的系统,可以通过选择不同的遗忘因子序列来控制参数变化的幅度,解决了电力系统负荷预报中季节模型的老化问题。本方法基于带有随机噪声状态模型的典型型,大大节省了计算机的运算量和存贮容量,适于微处理机的在线应用。

一、引 言

最近几年来,带噪声和不带噪声的多变量离散时间系统的辨识问题已得到了充分重视。最大或然估计、随机近似算法以及各种形式的最小二乘法被广泛应用于各类模型的参数估计中。

本文首先引出了用最小二乘自适应跟踪算法进行状态模型参数递推的基本关系式,然后从带有随机噪声的辨识参数最少的状态模型典型型出发,提出一种简化的参数在线辨识方法。这种方法与最小二乘自适应算法比较,要辨识的参数和运算量都大为减少。修改算式中的遗忘因子使参数的变化不致过于频繁,提高了模型的稳定性,适用于状态模型结构和初始参数已辨识完毕,但随着时间的推移,参数缓慢变化的系统。对于电力系统负荷预报过程中出现的季节模型的老化问题^[1],用这种方法进行模型参数的在线修改。本文使用了某电网1983年全年(除节日外)的实际负荷数据进行验证,收到了很好的效果。

二、简化的状态模型参数在线辨识法

任何一个可观、可控的多变量线性系统状态空间模型,无论有噪声与否,都可通以非奇异的线性变换化为等价的典型型结构,这就使得状态模型参数的在线辨识成为可能。假设随机序列 $\{Z(k)\}$ 来源于线性离散时间系统

$$X(k+1) = A(k)X(k) + BV(k), \quad Z(k) = CX(k) + V(k), \quad (2.1)$$

1 期

其中 $X(k)$ 是 n 维状态向量; $V(k)$ 是 m 维的零均值白色噪声向量; 且

$$E\{V(i)V^T(j)\} = Q\delta_{ij}, \quad E\{V(k)X^T(0)\} = 0;$$

(A, B) 可控; (A, C) 可观; A, B, C, Q 是具有相应维数、参数初值已辨识完毕的矩阵; k 是离散的时间; $Z(k)$ 是 m 维输出向量。

选用文献[1]采用的 SSF3^[2] 典型型, 将不变参数的状态转移矩阵 A , 在本文中作为时变参数矩阵 $A(k)$ 。

$$A(k) = \begin{array}{c|c|c} \begin{array}{c} 0 \\ 0 \\ \vdots \\ 0 \\ a_{11}(k) \cdots a_{1n_1}(k) \\ \vdots \\ 0 \\ 0 \\ \vdots \\ 0 \\ a_{21}(k) \cdots a_{2n_1}(k) \\ \vdots \\ a_{m-1,1}(k) \cdots a_{m-1,n_1}(k) \\ 0 \\ \vdots \\ a_{m1}(k) \cdots a_{m,1}(k) \end{array} & \begin{array}{c} \vdots \\ \vdots \\ \vdots \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 1 \\ \vdots \\ \vdots \\ 1 \end{array} & \begin{array}{c} \vdots \\ \vdots \\ \vdots \\ a_{2,n_1+1}(k) \cdots a_{2,n_1+n_2}(k) \\ \vdots \\ a_{m-1,n_1+n_2+1} \cdots a_{m-1,n_1+n_2+n_{m-1}}(k) \\ \vdots \\ a_{m,n_1+n_2+1} \cdots a_{m,n_1+n_2+n_{m-1}+1}(k) \end{array} \\ \hline \begin{array}{c} a_{m-1,n_1+n_2+1} \cdots a_{m-1,n_1+n_2+n_{m-1}}(k) \\ \vdots \\ a_{mn_1}(k) \end{array} & \begin{array}{c} \vdots \\ \vdots \\ \vdots \\ 0 \\ 1 \\ \vdots \\ \vdots \\ 1 \end{array} & \begin{array}{c} \vdots \\ \vdots \\ \vdots \\ a_{mn_1}(k) \end{array} \end{array}$$

$$\sum_{i=1}^m n_i = n$$

$$C = \begin{bmatrix} \underbrace{1 \ 0 \ \cdots \ 0}_{n_1} & \underbrace{0 \ \cdots \ 0}_{n_2} & \cdots & \underbrace{0 \ \cdots \ 0}_{n_m} \end{bmatrix}_{m \times n},$$

$$B = [b_1 \ b_2 \ \cdots \ b_n]^T.$$

令

$$X^T(k) = [x_1(k) \ x_2(k) \ \cdots \ x_n(k)],$$

$$\theta_j^T(k) = [a_{j1}(k) \ \cdots \ a_{j, n_1+1}(k) \ \cdots \ a_{j, \Sigma_j}(k) \ 0 \ \cdots \ 0],$$

其中 $\Sigma_j = n_1 + n_2 + \cdots + n_j$, $\Sigma_0 = 0$. 下同.

如果采用最小二乘自适应递推算法, 每一个参数向量 $\theta_j(k)$ 可分别用下式估计^[5]:

$$\hat{\theta}_j(k+1) = \theta_j(k) + \frac{P_j(k)X(k)[z_j(k+n_j) - X^T(k)\hat{\theta}_j(k)]}{1 + X^T(k)P_j(k)X(k)}, \quad (2.2)$$

$$P_j(k+1) = P_j(k) - \frac{P_j(k)X(k)[P_j(k)X(k)]^T}{1 + X^T(k)P_j(k)X(k)}. \quad (2.3)$$

可以看出, 这种方法比较复杂, 每次运算除了估计系统参数——所有的 θ_j 以外, 还要估计辅助参数 P_j , 计算量较大. 对于一些参数随时间变化缓慢的系统, 有必要寻找一种简单、适用、模型参数保持相对稳定的算法.

由 (2.1) 式和 $A(k)$ 、 C 矩阵的典范型构造, 可以证明^{[5][6]}:

对于 $j = 1, 2, \dots, m$,

$$z_j(k+n_j) = X^T(k)\hat{\theta}_j(k) + \sum_{i=1}^{n_j} b_{\Sigma_{j-1}+i} V(k+n_j-i) + v_j(k+n_j).$$

由此得到误差估计式

$$v_j(k+n_j) = z_j(k+n_j) - X^T(k)\hat{\theta}_j(k) - \sum_{i=1}^{n_j} b_{\Sigma_{j-1}+i} V(k+n_j-i). \quad (2.4)$$

比如, 当 $j=1$ 时,

$$v_1(k+n_1) = z_1(k+n_1) - X^T(k)\hat{\theta}_1(k) - \sum_{i=1}^{n_1} b_i V(k+n_1-i),$$

$$\hat{\theta}_1^T(k) = [\hat{a}_{11}(k) \cdots \hat{a}_{1n_1}(k) \ 0 \cdots 0].$$

当 $j = 2$,

$$v_2(k+n_2) = z_2(k+n_2) - X^T(k) \hat{\theta}_2(k) - \sum_{i=1}^{n_2} b_{n_1+i} V(k+n_2-i),$$

$$\hat{\theta}_2^T(k) = [\hat{a}_{21}(k) \cdots \hat{a}_{2n_1}(k) \hat{a}_{2,n_1+1}(k) \cdots \hat{a}_{2,n_1+n_2}(k) \ 0 \cdots 0].$$

当 $j = 3, 4, \cdots, m$, 以此类推.

参数估计式 (2.2) 可以简写为

$$\hat{\theta}_j(k+1) = \hat{\theta}_j(k) + \lambda(k) X(k) \frac{v_j(k+n_j)}{\|X(k)\|^2}. \quad (2.5)$$

序列 $\{\lambda(k)\}$ 满足下列条件:

$$\lim_{k \rightarrow \infty} \lambda(k) = 0; \quad \sum_{k=1}^{\infty} \lambda(k) = \infty; \quad \sum_{k=1}^{\infty} \lambda^2(k) < \infty.$$

与 (2.2)、(2.3) 式相比, 此式省略了最小二乘自适应算法中关于辅助参数的估计, 参数变化幅度根据不同的系统特点选择一个合适的序列 $\{\lambda(k)\}$ 便可以圆满解决. 这个算法的收敛性与最小二乘自适应算法是一致的, 本文不详述.

四、在电网负荷预报中的应用

文献[1]曾为东北电网建立了两个不同季节的负荷模型. 用1982年11月的数据建立的模型对当月负荷进行预报, 月平均均方差为2.2%. 用同样的模型预报了1983年11月份负荷, 月平均均方差2.4%. 用此模型又对1984年11月的负荷做了预报, 月平均均方差为2.1%. 和当年当月人工预报做了一次比较, 人工预报误差为2.3%. 这个结果说明预报效果达到并超过了人工预报水平, 也证明了季节模型是可靠的. 但这种模型的季节性限制了它的应用. 如果我们选一年中具有代表性的模型作为负荷模型, 则随着时间的推移, 模型的老化问题将使全年大部分时期负荷预报不准, 失去了模型的意义. 另外, 一年中不同时期的负荷需求规律不同, 图1示出冬、夏季典型日负荷曲线. 但这个变化是日积月累而来, 即使我们建立了若干个适于不同季节的负荷模型, 切换日期也难以确定. 并且模型过多也造成程序复杂, 不易操作, 还容易引起混乱.

本文提供的简化状态模型参数递推方法便能有效地提高模型的适应性. 只需要较少的数据建立一个季节负荷模型, 在预报本期负荷的同时进行模型的在线修改, 用于修改模型参数的数据是当前电网的最新数据, 这就使模型有根据电力系统近期运行特性修改本身参数的能力, 克服模型的季节性, 收到长期连续负荷预报的较好效果.

仍采用模型 (2.1), 在对全网负荷预测中, $m = 1$, 故误差估计式 (2.4) 和参数




图 1 冬、夏季典型负荷曲线

递推式 (2.5) 分别写为

$$v(k+n) = z(k+n) - X^T(k) \hat{\theta}(k) - \sum_{i=1}^n b_i V(k+n-i),$$

$$\hat{\theta}(k+1) = \hat{\theta}(k) + \lambda(k) X(k) \frac{v(k+n)}{\|X(k)\|^2},$$

$$\hat{\theta}(k) = [\alpha_1(k) \quad \alpha_2(k) \cdots \alpha_n(k)]^T.$$

为了证明上述算法, 取了某电网1983年全年(除节日外)的实际数据进行负荷预报和误差分析。

初始模型取自1982年11月数据所建^[1], 采用1983年全年实际数据进行模型修改和日负荷预报。预报所用 Kalman 滤波算法的流程图示于图2。预报的结果列于表1。这个结




图 2 Kalman滤波算法流程图

表 1 1983 年 预 报 结 果

月 份	预 报 日 期	预报天数	均方根误差大于 4 % 的 天 数	相对误差小于 4 % 的点所占百分比	全 月 平 均 均 方根误差(%)
1	4~31	28	0	95	2.3
2	2~11, 18~28	21	2	84	3.0
3	2~31	30	0	95	2.3
4	2~29	28	5	80	3.5
5	6~31	26	0	94	2.5
6	2~30	29	2	92	2.5
7	5~31	27	1	90	2.6
8	2~31	30	1	89	2.6
9	2~29	28	0	90	2.6
10	5~31	27	1	88	2.8
11	2~30	29	0	93	2.4
12	2~30	29	0	96	2.2

表明,应用模型参数在线辨识算法的次日负荷预报满足电网经济调度要求,最大的月平均均方根误差不大于3.5%。结果还表明,采用本文算法的预报精度不低于用季节模型的预报效果。

五、结 论

本文提出的简化的随机系统状态空间模型参数在线递推算法,比最小二乘自适应算法和时间序列模型算法需要辨识的参数少,计算量也小,并可以针对不同系统的特点来调节模型参数变化的剧烈程度。对电力系统季节负荷模型的修改,完成负荷预测取得了很好的效果。

致谢 作者感谢东北电力调度局的大力支持和协助。

参 考 文 献

- [1] 李洪心、易允文,随机系统辨识技术在电力系统负荷预报中的应用,信息与控制,3,(1985)30—34.
- [2] Goodwin G. C, and R. L. Payne, Dynamic System Identification, Experiment Design and Data Analysis, Academic Press. Inc., New York, (1977).
- [3] M. A. Abu-El-Magd and N. K. Sinha, Two New Algorithm for On-line Modelling and Forecasting of the Load Demand of a Multinode Power System, IEEE Trans. Power Appar. and System, PAS- 100, (1981), 3246-3253.

- [4] Singh G., K. K. Biswas and A. K. Mahalanabis, Load Modelling for Real Time Monitoring of Power System, IEEE Trans. Power Appar. and Systems PAS-96, (1977), 1908-1914.
- [5] H. El-Sherief and N. K. Sinha, Bootstrap Estimation of Parameters and States of Linear Multivariable Systems, IEEE Trans. on Automatic Control, AC-24, 2, (1979), 340-343.
- [6] H. El-Sherief and N. K. Sinha, Convergence and Unbiasedness of Stochastic Approximation Algorithm for the Identification of Linear Multivariable Systems, IEEE Trans. Auto. Cont., AC- 4, (1979), 493-495,

AN ALGORITHM FOR ON-LINE IDENTIFICATION OF STOCHASTIC SYSTEM MODEL PARAMETERS AND APPLICATION IN POWER LOAD FORECASTING

Yi Yunwen, Li Hongxin

(Shenyang Institute of Automation, Academia Sinica)

Abstract

A simplified on-line multivariable stochastic system state model parameters estimation algorithm is developed. We choose a particular canonical form for estimation purpose. Proposed algorithm is compared with extended least-squares algorithm. It reduces equation parameters, memory requirements and execution per iteration, and also suits for slowly changing systems. In the application to load forecasting in electric system, the seasonal model is updated by properly selecting the forgetting factors, thus a long-term continuous load forecasting is achieved.