

基于动力学特性聚类多维泰勒网的 非线性系统辨识与预测

周 博, 严洪森

(东南大学 a. 自动化学院, b. 复杂工程系统测量与控制教育部重点实验室, 南京 210096)

摘 要: 针对时变非线性系统难以建模的问题, 提出了基于动力学特性聚类的多维泰勒网模型, 对系统进行辨识与预测. 首先讨论了多维泰勒网模型构造方法和非线性系统动力学特性聚类的定义; 然后给出基于动力学特性聚类的多维泰勒网自重构算法; 最后通过实例说明基于动力学特性聚类多维泰勒网在实际中应用的方法, 实例结果验证了该方法的有效性.

关键词: 多维泰勒网; 动力学特性; 聚类; 非线性系统辨识; 预测

中图分类号: TP391

文献标志码: A

Nonlinear system identification and prediction based on dynamics cluster multi-dimensional Taylor network model

ZHOU Bo, YAN Hong-sen

(a. School of Automation, b. Key Laboratory of Measurement and Control of Complex Systems of Engineering, Ministry of Education, Southeast University, Nanjing 210096, China. Correspondent: ZHOU Bo, E-mail: ai_haibara@126.com)

Abstract: For the problem of difficulty in modeling of time-varying nonlinear system, an approach to identification and prediction of system based on dynamics cluster multi-dimensional Taylor network model is proposed. Firstly, the method of construction of multi-dimensional Taylor network model is discussed, whereby the dynamics cluster is defined. Then, the self-reconfiguration algorithm of the dynamics cluster multi-dimensional Taylor network is given. Finally, an example is given to illustrate the method of the dynamics cluster multi-dimensional Taylor network how to work in the practical applications, and the results show the effectiveness of the proposed method.

Key words: multi-dimensional Taylor network; dynamics; cluster; identification of nonlinear system; prediction

0 引 言

现实世界是一个复杂而又庞大的系统, 它由无数或大或小的子系统组成. 每个系统都有自身的规律, 人类探寻这些规律的过程促进了人类文明的发展和科技的进步. 很多已知构造的复杂非线性系统, 当按其机理进行建模时, 由于内部要素过多而难以实现^[1]. 当把复杂的系统分解成子系统分别建模再组合时, 又会因为子系统误差的逐层向上传递而使得建模失败^[2]. 事实上, 现实存在的大多数非线性系统自身机理只知道其中一部分或根本未知, 因此单从机理出发解决问题是不够的, 建立可以描述系统的等效模型成为一个思路^[3].

等效模型是指通过还原系统对外表征来设计其内部构造的模型, 是解决未知机理系统建模的有效方法. 许多机理未知非线性系统对外表征以时间序列形式存在, 建立其等效模型的常用方法有: 自回归移动平均模型方法, 神经网络模型方法, 支持向量回归模型方法等. 文献[4]提出了一类用于非线性时间序列建模的混合自回归移动平均模型, 该模型分布形式富于变化的特征使其能够对具有多峰分布以及条件异方差的序列进行建模. 文献[5]提出了由自回归移动平均模型和神经网络模型集成的GDP时间序列预测模型与算法, 发挥两种模型在线性空间和非线性空间的预测优势. 文献[6]提出了一种基于二进正交小波

收稿日期: 2012-10-09; 修回日期: 2013-03-13.

基金项目: 国家自然科学基金重点项目(60934008); 国家自然科学基金项目(50875046).

作者简介: 周博(1983-), 男, 博士生, 从事系统辨识、时间序列预测的研究; 严洪森(1957-), 男, 教授, 博士生导师, 从事生产计划与调度、预测、知识化制造等研究.

变换和自回归最小二乘支持向量机方法的非平稳时间序列预测方案,该方法能充分拟合低频信息,同时避免对高频信息的过拟合。

实际上,自回归移动平均模型一般更适合时不变系统的建模;神经网络模型存在初始值设定困难、易陷入局部极值、Sigmoid 函数使得模型难以逼近不稳定系统等问题;支持向量回归模型源于支持向量机模型,更适合分类,且存在核函数选择困难、参数调整对模型性能影响较大等问题。而且以上模型大多建立的出发点是整合数据间的内在非线性关系,而没有着眼于模型的动力学特性。

在现实生活中,很多系统并不是单纯的有固定结构的机械装置,其自身的动力学特性往往随着时间的变化而改变。本文提出一种基于动力学特性聚类多维泰勒网模型(DCMTN),它针对动力学特性进行聚类,提高了聚类针对性,以动力学特性为建立多维泰勒网模型的准则,可以适应时变系统的建模。

1 动力学特性聚类多维泰勒网

1.1 多维泰勒网

系统动力学方程具有如下一般形式:

$$\begin{cases} \mathbf{x}(k+1) = \mathbf{x}(k) + \mathbf{f}(\mathbf{x}(k), k), \\ \mathbf{y}(k) = \mathbf{C}\mathbf{x}(k). \end{cases} \quad (1)$$

其中: \mathbf{x} 为系统状态向量, \mathbf{y} 为系统输出向量, \mathbf{C} 为状态-输出权重矩阵。

对于 n 维系统,将式(1)第一行写成标量形式为

$$\begin{cases} x_1(k+1) = x_1(k) + f_1(x_1(k), x_2(k), \dots, x_n(k)), \\ x_2(k+1) = x_2(k) + f_2(x_1(k), x_2(k), \dots, x_n(k)), \\ \vdots \\ x_n(k+1) = x_n(k) + f_n(x_1(k), x_2(k), \dots, x_n(k)). \end{cases} \quad (2)$$

式(2)中非线性函数 f 等效于 x 的动力学映射关系。对于如何构造 f ,用简单函数逼近复杂函数是数学中的一种基本思想方法。由泰勒公式可知,如果某函数在某点邻域处处 $m+1$ 阶可导,则该函数在该点展开式为变量幂级数不大于 m 次的形式。因此可以构造多维泰勒网模型如图 1 所示,其中 $\mathbf{w}_l = \{w_{l,1}, w_{l,2}, \dots, w_{l,N(n,m)}\}$ 为连接线上的权值集合, $l = 1, 2, \dots, n$ 。

f 可以构造为如下形式:

$$f(x_1, x_2, \dots, x_n) = \sum_{t=1}^{N(n,m)} w_t \prod_{i=1}^n x_i^{\lambda_{t,i}} + R_m(x_1, x_2, \dots, x_n), \quad (3)$$

$$\text{s.t.} \quad \sum_{t=1}^n \lambda_{t,i} \leq m. \quad (4)$$

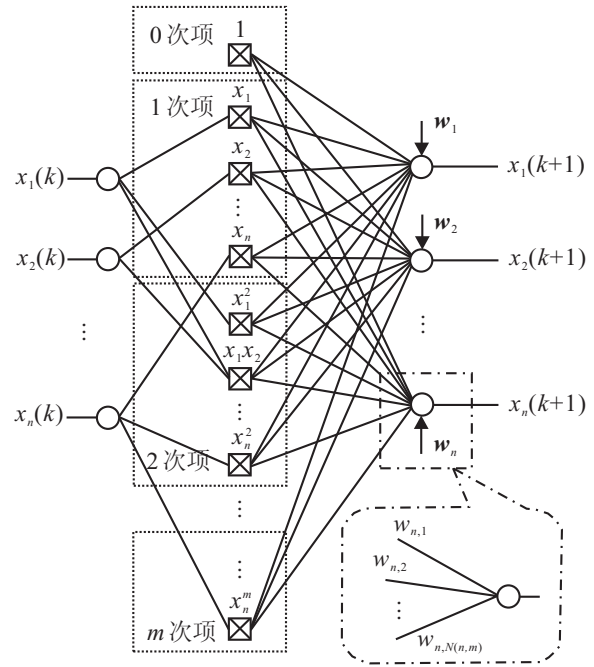


图 1 多维泰勒网模型图

其中: R_m 为其变量乘积项中各变量的幂次之和大于 m 的余项, w_t 为第 t 个变量乘积项之前的权值, $N(n, m)$ 为该展开式的总项数, $\lambda_{t,i}$ 为第 t 个变量乘积项中变量 x_i 的幂次。即 f 是由其各变量的幂次之和小于等于 m 的变量乘积项加权之和与其变量乘积项中各变量的幂次之和大于 m 的余项组成的。

对照式(2)和(3),因为 f_l 必然包括 x_l 的 1 次项,所以可将式(2)所有方程等号右边第 1 项归入 f_l 中,对于最高次展开到 m 次的 n 维系统,舍去余项,有如下形式:

$$x_l(k+1) = \sum_{t=1}^{N(n,m)} w_{l,t} \prod_{i=1}^n x_i^{\lambda_{t,i}}(k). \quad (5)$$

x_i 乘积项按照其各变量的幂次之和递增次序排列。 $N(n, m)$ 和 $\lambda_{t,i}$ 的表达式用递归的方法推出。令 $P(n, m)$ 表示展开式中其各变量的幂次之和为 m 的乘积项项数,则 $N(n, m)$ 可表示为

$$N(n, m) = N(n, m-1) + P(n, m) = \sum_{j=0}^m P(n, j). \quad (6)$$

其中 $P(n, 0)$ 为 0 次项(即常数项)个数,即为 1。 m 每增加 1,变量个数从 1 至 n 的组合形式均可形成相应次数新项,新项的项数是其之前所有项的项数总和,表示为

$$P(n, m) = \sum_{i=0}^n P(i, m-1). \quad (7)$$

将式(7)代入(6)可得

$$N(n, m) = \sum_{j=0}^m \sum_{i=1}^n P(i, j-1). \quad (8)$$

令 $t(r, h)$ 表示其各变量的幂次之和为 h 的第 r 组乘积项集合起始序号, 则有

$$\begin{aligned} t(r, h) = & \\ N(n, h-1) + P(n, h) - P(n+1-r, h) = & \\ N(n, h) - P(n+1-r, h). & \quad (9) \end{aligned}$$

其中: $r = 1, 2, \dots, n; h = 1, 2, \dots, m; N(n, h-1)$ 为幂次之和小于 h 的项数; $P(n, h)$ 为幂次之和为 h 的全部 n 组集合项数; $P(n+1-r, h)$ 为幂次之和为 h 的后 $n-(r-1)$ 组集合项数; $N(n, h)$ 为幂次之和小于 $h+1$ 的项数.

$\lambda_{t,i}$ 的递归公式为

$$\lambda_{t(r,h)+j,i} = \begin{cases} \lambda_{t(r,h-1)+j,i} + 1, & i = r; \\ \lambda_{t(r,h-1)+j,i}, & i \neq r. \end{cases} \quad (10)$$

其中: $i = 1, 2, \dots, n; j = 1, 2, \dots, P(n-r+1, h-1)$. 初始值为

$$\lambda_{N(n,0)+j,i} = \begin{cases} 1, & i = j; \\ 0, & i \neq j. \end{cases} \quad (11)$$

其中: $i = 1, 2, \dots, n; j = 1, 2, \dots, n; N(n, 0) = 1$.

1.2 动力学特性聚类

许多非线性系统内部机理复杂或未知, 难以建立微分方程来精确描述系统内部构造和规律, 因此, 针对系统对外表征的实时测量数据分析便成为评估和重建系统的最佳途径. 由 Grassberger 等^[7] 提出的 GP 法, 即是利用系统对外表征的数据形成的时间序列来重建非线性动力学系统的方法.

时间序列具有动力学特性, 相邻时间点的数据变化隐含系统发生变化的趋势. 通过多维泰勒网对时间序列进行辨识可获得系统的等效模型.

对于时变系统而言, 其动力学特性随时间不断变化. 对系统建模的目的是预测系统未来的输出趋势, 如果对未来时间点的预测没有针对性的建模, 则会导致系统描述不准确, 最终建模失败. 因此, 应针对性地选取动力学特性相似的数据区间进行辨识和建模.

定义 1 针对系统动力学变化趋势, 定义动力学特性为

$$\begin{cases} \text{dyn}_0(E) = x(k_E), \\ \text{dyn}_1(E) = x(k_E) - x(k_E - 1) = \Delta x(k_E), \\ \text{dyn}_2(E) = \Delta x(k_E) - \Delta x(k_E - 1) = \Delta^2 x(k_E), \\ \vdots \\ \text{dyn}_\eta(E) = \\ \Delta^{\eta-1} x(k_E) - \Delta^{\eta-1} x(k_E - 1) = \Delta^\eta x(k_E). \end{cases} \quad (12)$$

其中: dyn_η 为 η 阶动力学特性变量, E 为数据点, k_E 为点 E 在时间序列中的序号. 物理意义上 dyn_1 相当

于状态速度变量, dyn_2 相当于状态加速度变量, 依此类推.

定理 1 对于 η 为非负整数, 根据定义 1, 系统动力学特性有如下关系式:

$$\text{dyn}_\eta(E) = \sum_{i=0}^{\eta} (-1)^i C_\eta^i x(k_E - i), \quad (13)$$

其中 C 为排列组合符号.

证明 由数学归纳法:

1) 当 $\eta = 0$ 时, 由式 (12) 可得

$$\text{dyn}_0(E) = \sum_{i=0}^0 (-1)^i C_0^i x(k_E - i),$$

因为 $C_0^0 = 1$, 所以 $\text{dyn}_0(E) = x(k_E)$. 式 (13) 成立.

2) 设 $\eta = k$ 时, 式 (13) 成立, 即

$$\text{dyn}_k(E) = \sum_{i=0}^k (-1)^i C_k^i x(k_E - i).$$

当 $\eta = k+1$ 时, 由式 (12) 可得

$$\begin{aligned} \text{dyn}_{k+1}(E) = & \\ \sum_{i=0}^k (-1)^i C_k^i x(k_E - i) - & \\ \sum_{i=0}^k (-1)^i C_k^i x(k_E - 1 - i) = & \\ \sum_{i=0}^{k+1} (-1)^i C_{k+1}^i x(k_E - i). & \end{aligned}$$

式 (13) 成立.

综合 1) 和 2), 对于所有 $\eta \geq 0$ 的情况, 定理 1 都成立. \square

对系统未来状态的预测, 需要建立有针对性的系统模型, 模型辨识选取的数据点应与目标数据点动力学特性相似.

定义 2 对于时间序列中的两个数据点 E_1 和 E_2 , 有如下相似性定义:

$$\begin{aligned} \text{sim}(E_1, E_2) = & \\ \exp\left(\frac{-1}{\eta+1} \sum_{i=0}^{\eta} (\text{dyn}_i(E_1) - \text{dyn}_i(E_2))^2\right). & \quad (14) \end{aligned}$$

该相似性定义有如下性质:

性质 1 $\text{sim}(E_1, E_2) \in (0, 1]$.

性质 2 $\text{sim}(E_1, E_2) = 1$, 当且仅当 $\text{dyn}_\eta(E_1) = \text{dyn}_\eta(E_2)$.

性质 3 当 $\|\text{dyn}_\eta(E_1) - \text{dyn}_\eta(E_2)\| \rightarrow +\infty$ 时, $\text{sim}(E_1, E_2) \rightarrow 0$.

性质 4 $\text{sim}(E_1, E_2) = \text{sim}(E_2, E_1)$.

性质 5 以下不等式成立:

$$\sqrt{-\ln(\text{sim}(E_1, E_3))} \leq$$

$$\sqrt{-\ln(\text{sim}(E_1, E_2))} + \sqrt{-\ln(\text{sim}(E_2, E_3))}.$$

证明 这里仅证明性质 5, 其余性质易证. 由式 (14) 可得

$$\begin{aligned} & \sqrt{-\ln(\text{sim}(E_1, E_3))} = \\ & \sqrt{\frac{-1}{\eta+1} \sum_{i=0}^{\eta} (\text{dyn}_i(E_1) - \text{dyn}_i(E_3))^2} = \\ & \sqrt{\frac{1}{\eta+1} \|(\text{dyn}_i(E_1) - \text{dyn}_i(E_3))\|^2} = \\ & \sqrt{\frac{1}{\eta+1} \|(\text{dyn}_i(E_1) - \text{dyn}_i(E_2)) + \\ & (\text{dyn}_i(E_2) - \text{dyn}_i(E_3))\|^2} \leq \\ & \sqrt{\frac{1}{\eta+1} \|(\text{dyn}_i(E_1) - \text{dyn}_i(E_2))\|^2} + \\ & \sqrt{\frac{1}{\eta+1} \|(\text{dyn}_i(E_2) - \text{dyn}_i(E_3))\|^2} = \\ & \sqrt{-\ln(\text{sim}(E_1, E_2))} + \sqrt{-\ln(\text{sim}(E_2, E_3))}. \quad \square \end{aligned}$$

1.3 动力学特性聚类多维泰勒网

动力学特性聚类多维泰勒网 (DCMTN) 的参数可以通过样本学习获得, 下面将给出建立和运用最小二乘法求解 DCMTN 模型参数 \mathbf{w} 的具体方法.

设样本集 $T = \{(\mathbf{x}(k), y(k+1))\}_{k=1}^d$, $\mathbf{x}(k) \in R^n$, $y(k) \in R$, 则该 d 个样本点分别为 $\{E_k\}_{k=1}^d$, 其动力学特性向量集合

$$\{\text{dyn}_\eta(E_k)\}_{k=1}^d =$$

$$\{(\text{dyn}_0(E_k), (\text{dyn}_1(E_k), \dots, (\text{dyn}_\eta(E_k)))\}_{k=1}^d.$$

设目标点为 E_a , 将集合 $\{\text{sim}(E_k, E_a)\}_{k=1}^d$ 中的元素按从大到小顺序排列, 返回相应排序序列号, 即

$$\begin{aligned} \rho &= (\rho(1), \rho(2), \dots, \rho(d)) = \\ & \text{Sort}(\{\text{sim}(E_k, E_a)\}_{k=1}^d), \end{aligned} \quad (15)$$

其中 $\text{Sort}(\cdot)$ 为排序函数. 这样每选取一个新的目标点, 就以该点动力学特性为聚类中心点, 按相似程度从样本点中选取与目标点动力学特性更相似的点参与建模. 设参与建立动力学特性聚类多维泰勒网模型的样本点个数为 d_c , 其与样本总数之比 $\gamma = d_c/d$, 则聚类数据集为 $T_{\text{clu}} = \{(\mathbf{x}(\rho(k)), y(\rho(k)+1))\}_{k=1}^{d_c}$.

假设样本集合的输出为 1 维, 并设 $y(k) = x_1(k)$, 则式 (1) 中取 $C = (1, 0, \dots, 0)$; 多维输出类推. 因此, 动力学特性聚类多维泰勒网模型的数学描述为

$$\hat{y}(\rho(k)+1) = \sum_{t=1}^{N(n,m)} w_{1,t} \prod_{i=1}^n x_i^{\lambda_{t,i}}(\rho(k)). \quad (16)$$

将式 (16) 代入误差平方和函数, 有

$$\begin{aligned} E_{\text{clu}} &= \sum_{k=1}^{d_c} (y(\rho(k)+1) - \hat{y}(\rho(k)+1))^2 = \\ & \sum_{k=1}^{d_c} \left(y(\rho(k)+1) - \right. \\ & \left. \sum_{t=1}^{N(n,m)} w_{1,t} \prod_{i=1}^n x_i^{\lambda_{t,i}}(\rho(k)) \right)^2. \end{aligned} \quad (17)$$

令

$$\begin{aligned} \alpha_{\rho(k)} &= \left(\prod_{i=1}^n x_i^{\lambda_{1,i}}(\rho(k)), \prod_{i=1}^n x_i^{\lambda_{2,i}}(\rho(k)), \right. \\ & \left. \dots, \prod_{i=1}^n x_i^{\lambda_{N(n,m),i}}(\rho(k)) \right)^T, \end{aligned}$$

$$\mathbf{A} = (\alpha_{\rho(1)}, \alpha_{\rho(2)}, \dots, \alpha_{\rho(d_c)}),$$

$$\mathbf{w} = (w_{1,1}, w_{1,2}, \dots, w_{1,N(n,m)})^T,$$

$$\mathbf{y} = (y(2), y(3), \dots, y(d_c+1))^T,$$

则式 (17) 变为如下向量形式:

$$\begin{aligned} E_{\text{clu}} &= \sum_{k=1}^{d_c} (y(\rho(k)+1) - \mathbf{w}^T \alpha_{\rho(k)})^2 = \\ & \mathbf{w}^T \sum_{k=1}^{d_c} \alpha_{\rho(k)} \alpha_{\rho(k)}^T \mathbf{w} + \\ & \sum_{k=1}^{d_c} y^2(\rho(k)+1) - \\ & 2 \sum_{k=1}^{d_c} y(\rho(k)+1) \alpha_{\rho(k)}^T \mathbf{w} = \\ & \mathbf{w}^T \mathbf{A} \mathbf{A}^T \mathbf{w} - 2 \mathbf{y}^T \mathbf{A}^T \mathbf{w} + \mathbf{y}^T \mathbf{y}. \end{aligned} \quad (18)$$

参数 \mathbf{w} 的估计值 $\hat{\mathbf{w}}$ 可由最小二乘估计获得, 即

$$\hat{\mathbf{w}} = (\mathbf{A} \mathbf{A}^T)^{-1} \mathbf{A} \mathbf{y}. \quad (19)$$

1.4 多维泰勒网自重构算法

算法 1 动力学特性相似度算法.

Step 1: 读取输入数据, 即参加计算的两个数据点 E_1 和 E_2 ;

Step 2: 按式 (13) 分别计算 E_1 和 E_2 的动力学特性向量 $\text{dyn}_\eta(E_1)$ 和 $\text{dyn}_\eta(E_2)$;

Step 3: 按式 (14) 计算 E_1 和 E_2 的动力学特性相似度 $\text{sim}(E_1, E_2)$;

Step 4: 返回 $\text{sim}(E_1, E_2)$ 值.

算法 2 排序递归算法.

Step 1: 读取参加排序的数据集合 $\{\text{data}_k\}_{k=1}^d$, 初始化 $\rho = (\rho(1), \rho(2), \dots, \rho(d)) = (1, 2, \dots, d)$;

Step 2: 判断是否 $d = 1$, 如果是, 则转 **Step 7**;

Step 3: 将 $\{\text{data}_{\rho(k)}\}_{k=1}^{d-1}$ 作为输入, 调用算法 2, 获得返回值 $\rho_{d-1} = (\rho_{d-1}(1), \rho_{d-1}(2), \dots, \rho_{d-1}(d-1))$, 令 $\{\rho(k) = \rho_{d-1}(k)\}_{k=1}^{d-1}$;

Step 4: 初始化序号变量 $i_sort = 1$;

Step 5: 判断是否 $data_d > data_{\rho(i_sort)}$, 如果是, 则令 $\{\rho(k+1) = \rho(k)\}_{k=i_sort}^{d-1}$, $\rho(i_sort) = d$, 转 Step 7;

Step 6: $i_sort = i_sort + 1$, 如果 $i_sort < d$, 则转 Step 5;

Step 7: 返回 ρ 值.

算法 3 多维泰勒网自重构算法.

Step 1: 读取所要进行建模的目标非线性系统数据集;

Step 2: 判断数据集的结构是否是多维数据, 如果是, 则确定状态的维数, 按多维泰勒网模型模式生成样本数据集 $T = \{(\mathbf{x}(k), y(k+1))\}_{k=1}^d$, 并转 Step 4;

Step 3: 将一维数据 $\{x(k)\}_{k=1}^{d+1}$ 重构多维数据空间, 令

$$\begin{cases} \mathbf{x}(k) = (x(k), x(k-\tau), \dots, x(k-(n-1)\tau)), \\ y(k) = x(k), \end{cases} \quad (20)$$

其中 τ 为延迟时间, 并按多维泰勒网模型模式转化数据为 $T = \{(\mathbf{x}(k), y(k+1))\}_{k=1}^d$;

Step 4: 由样本数据确定 d 个数据点 $\{E_k\}_{k=1}^d$, 并读取目标点 E_a 数据;

Step 5: 初始化 $i_k = 1$;

Step 6: 将 E_{i_k} 和 E_a 作为输入, 调用算法 1, 获得返回值 $\text{sim}(E_{i_k}, E_a)$;

Step 7: 若 $i_k < d$, 则令 $i_k = i_k + 1$, 转 Step 6;

Step 8: 将 $\{\text{sim}(E_{i_k}, E_a)\}_{k=1}^d$ 作为输入, 调用算法 2, 获得返回值 ρ ;

Step 9: 读取参数 γ , 按 $d_c = \gamma d$ 计算聚类样本点个数 d_c , 确定聚类数据集 T_{clu} ;

Step 10: 按式 (16)~(19) 计算, 获得模型参数 \mathbf{w} .

2 应用实例

经济系统是典型的非线性动力学系统, 其结构复杂, 内部要素多, 难以按照机理建立模型. 金融被称作是国民经济的晴雨表, 股票市场的波动是金融市场的对外直观表现, 并且其数据量丰富, 对其进行辨识和建模可以为维持宏观经济健康稳定运行的决策提供帮助. 以中国股票市场 A 股上海证券交易所大盘指数预测为例, 取上证指数 (1A0001) 2009 年 10 月 20 日至 2011 年 1 月 10 日 300 个日收盘数据, 其中前 270 个作为样本数据, 后 30 个作为测试验证数据.

利用 Matlab 7.7 编制动力学特性聚类多维泰勒网模型 (DCMTN) 程序, 运行环境为 core(TM)2 Quad CPU Q8400、主频 2.66 GHz、内存 2G 的微机. 模型系统状态向量的维数 n 在系统机理已知的情况下应与

原系统维数相符. 当系统机理未知时应保证 \mathbf{w} 的维数小于参与系统辨识的样本个数, 否则将会过拟合, 取 \mathbf{w} 的维数等于 $N(n, m)$. 本例动力学特性向量最高阶取到加速度向量, 即 $\eta = 2$. 因此程序设定 DCMTN 模型规模参数 $n = 3, m = 3$. 动力学特性聚类样本与总样本数之比 γ 设为 50%. 计算结果如表 1 所示.

表 1 预测值与实际值比较

序号	实际值	预测值	相对误差/%
1	2820.18	2878.22	-2.0581
2	2823.45	2820.43	0.1068
3	2843.61	2826.56	0.5998
4	2842.43	2843.90	-0.0517
5	2857.18	2841.03	0.5651
6	2875.86	2851.64	0.8423
7	2848.55	2872.38	-0.8365
8	2810.95	2844.15	-1.1812
9	2841.04	2814.63	0.9297
10	2922.95	2851.93	2.4296
11	2927.08	2927.24	-0.0054
12	2911.41	2930.37	-0.6512
13	2898.14	2932.79	-1.1955
14	2893.74	2885.66	0.2793
15	2852.92	2870.04	-0.5999
16	2904.11	2847.15	1.9613
17	2877.90	2920.61	-1.4839
18	2855.22	2849.22	0.2103
19	2835.16	2861.18	-0.9177
20	2781.40	2811.57	-1.0847
21	2732.99	2760.74	-1.0152
22	2751.53	2722.60	1.0514
23	2759.57	2755.86	0.1343
24	2808.08	2764.99	1.5344
25	2852.65	2804.17	1.6994
26	2838.59	2864.46	-0.9115
27	2824.20	2840.09	-0.5625
28	2838.80	2834.25	0.1603
29	2791.81	2824.17	-1.1592
30	2804.05	2788.46	0.5559

为了比较动力学特性聚类多维泰勒网模型 (DCMTN) 的预测能力优劣, 选取自回归移动平均模型 (ARIMA) 和 BP 神经网络模型 (BPNN) 对上述数据进行系统建模和预测, 对各个模型的预测结果进行误差指标计算. 其中: 自回归移动平均模型参数选取 (3, 1, 3); BP 神经网络选取层数为 3, 节点数为 (3, 3, 1), 迭代次数为 1000, 停止阈值为 $1e-4$. 指标均方根误差 RMSE、平均绝对误差 MAE 以及平均绝对误差率 MAPE 用来评价预测的精度. 每一种指标所求得的数值越低, 表示其预测绩效越高. 计算结果如表 2 所示. 从表 2 可以看出, 本文提出的 DCMTN 模型方法的 3 种指标预测效果均好于 ARIMA 和 BPNN 模型.

表 2 3 种模型预测结果比较

模型	RMSE	MAE	MAPE/%
ARIMA	33.69	28.32	0.9978
BPNN	33.00	27.12	0.9554
DCMTN	30.88	25.38	0.8925

参数 γ 的选取也影响着最终的预测准确度. 分别取 γ 从 20% ~ 100%, 每两个取值间隔 10%, 生成相应拟合和预测 MAPE 对比曲线, 如图 2 所示.




图 2 拟合和预测 MAPE 对比曲线

由图 2 可见, 当 γ 取值较小时, 易产生过拟合现象, 即模型拟样本数据较好, 但模型预测泛性较差. 这是由于原始数据也受其他噪声和扰动的影响, 拟合度过高, 模型反而不能反映原系统的特性. 随着 γ 取值增长, 模型拟样本数据能力下降, 同时模型预测能力呈先上升后下降的特点. 拟合能力逐步下降是由于随 γ 取值增长, 模型规模不变, 而样本数据点增多, 模型无法完全拟合多样性的动力学特性, 且系统本身特性也受噪声和扰动影响; 预测精度先上升的原因是参与聚类的样本数据与目标数据动力学相似度较高, 且有一定容错性, 降低了扰动和噪声对预测的影响; 预测精度后下降的原因是参与辨识的样本数据过多, 动力学特性没有起到聚类的作用. 因此参数 γ 应选择 30% ~ 50% 为宜.

3 结 论

本文提出了动力学特性聚类多维泰勒网模型, 通过对非线性时变系统不同时刻的动力学特性进行聚类和多维泰勒网建模及辨识, 最后得出系统模型, 并

讨论了模型参数选择范围. 从实例的结果来看, 本文方法是可行和有效的, 同时, 本文方法为解决实际问题中一般非线性系统辨识提供了新的途径. 该模型也可以应用于经济金融、气候气象、水文监测、化工过程等诸多领域.

参考文献(References)

- [1] Annakkage U D, Nair N K C, Liang Y F, et al. Dynamic system equivalents: A survey of available techniques[J]. IEEE Trans on Power Delivery, 2012, 27(1): 411-420.
- [2] Cholette M E, Liu J B, Djurdjanovic D, et al. Monitoring of complex systems of interacting dynamic systems[J]. Applied Intelligence, 2012, 37(1): 60-79.
- [3] Ourari M L, Dessaint L A, Do V Q. Dynamic equivalent modeling of large power systems using structure preservation technique[J]. IEEE Trans on Power Systems, 2006, 21(3): 1284-1295.
- [4] 王红军, 田铮. 非线性时间序列建模的混合自回归滑动平均模型[J]. 控制理论与应用, 2005, 22(6): 875-881.
(Wang H J, Tian Z. Mixed autoregressive moving average model for modeling nonlinear time series[J]. Control Theory & Applications, 2005, 22(6): 875-881.)
- [5] 熊志斌. 基于 ARIMA 与神经网络集成的 GDP 时间序列预测研究[J]. 数理统计与管理, 2011, 30(2): 306-314.
(Xiong Z B. Research on GDP time series forecasting based on integrating ARIMA with neural networks[J]. Application of Statistics and Management, 2011, 30(2): 306-314.)
- [6] 王晓兰, 张万宏, 王慧中. 基于小波变换和 AR-LSSVM 的非平稳时间序列预测[J]. 控制与决策, 2008, 23(3): 357-360.
(Wang X L, Zhang W H, Wang H Z. Non-stationary time series prediction based on wavelet analysis and AR-LSSVM[J]. Control and Decision, 2008, 23(3): 357-360.)
- [7] Grassberger P, Procaccia I. Characterization of strange attractors[J]. Physical Review Letters, 1983, 50(5): 346-349.

(责任编辑: 李君玲)