

文章编号: 1000-8055(2006)04-0759-0

航空发动机约简遗传规划起动非线性动态模型

尉询楷, 李应红

(空军工程大学 工程学院, 陕西 西安 710038)

摘 要: 提出了一种新的用于航空发动机最优化起动过程数据驱动动态建模的约简遗传规划(PGP)算法。这种模型采用遗传规划产生航空发动机辨识模型的输入输出非线性模型集,并以二叉树结构表征函数项,运用正交最小二乘算法(OLS)估计二叉树分支对于模型精度的贡献并据此去除复杂、冗余的函数项,从而加快遗传规划的收敛速度,最后通过 GP 进化可获得简单、可靠、准确的线参数非线性参数动态模型。实际发动机起动过程建模应用案例证明,这种思路对于具有非线性输入输出关系特征的数据可以产生鲁棒性好、解析性强的线参数非线性模型。

关 键 词: 航空、航天推进系统; 航空发动机; 起动; 约简遗传规划; 正交最小二乘; 非线性动态模型

中图分类号: V233.7

文献标识码: A

Aero engine nonlinear dynamic starting model based on parsimonious genetic programming

WEI Xun-kai, LI Ying hong

(School of Engineering, Air Force Engineering University, Xi'an 710038, China)

Abstract: A novel Parsimonious Genetic Programming (PGP) algorithm for aero engine starting process optimum data-driven nonlinear dynamic modeling was proposed. First, the method used the traditional GP to generate nonlinear input-output models that were represented in a binary tree structure. Then, Orthogonal Least Squares algorithm (OLS) was applied to estimate the contribution of the tree branches to the accuracy of the model. On this basis, the complex redundant subtrees can be eliminated and the GP's convergence speed is enhanced. Finally, the simple, reliable and accurate linear parameters nonlinear dynamic model can be obtained via GP evolution. Applications to real aeroengine starting process modeling validate that the proposed method can generate more robust and interpretable models.

Key words: aerospace propulsion system; aero engine; starting; Parsimonious Genetic Programming (PGP); Orthogonal Least Squares algorithm (OLS); nonlinear dynamic model

在航空发动机运行或使用中,起动过程是非常重要的一个工作阶段,是发动机能够顺利进入正常工作的前提。发动机可靠、快速的起动过程

对保证军用飞机的作战效能至关重要,起动性能的好坏是衡量发动机综合性能的一项重要指标。但是,由于实际的发动机起动过程极其复杂,且发

收稿日期: 2005-09-15; 修订日期: 2006-05-31

基金项目: 本文受空军工程大学工程学院优秀博士论文创新基金(BC0501)和国防预研基金(4132030103)资助

作者简介: 尉询楷(1981-),男,空军工程大学工程学院航空宇航推进理论与工程专业在读博士研究生,主要从事覆盖机器学习、推进系统智能控制与智能诊断的研究工作。E-mail: xunkai.wei@ieee.org, yinghong_li@126.com

动机低转速下的部件特性由于缺少数据而失效,这使得传统的气动热力学模型应用困难。

数据驱动辨识技术由于不需要考虑复杂的物理、化学过程,仅依靠试验获得的输入输出数据,就可以获得一个能够表征复杂过程的模型,因而成为解决非线性动态过程建模的有效办法。近些年来,航空发动机的非线性辨识建模研究取得了一定的研究成果。一种是以非线性逼近器作为工具的神经网络、支持向量机等建模方法,这种建模方法精度高,但存在模型物理意义不明确的缺点。文献[1]将 BP 神经网络应用于航空发动机飞行过程的建模,获得了较好的效果,但是 BP 网络存在很多无法克服的缺陷,获得的网络模型很难具有通用性。文献[2]将 RBF 网络应用于航空发动机的起动过程建模,这种方法矢量化特征较好,总体性能比 BP 神经网络要好,但是同样存在局部极值和中心节点的选择问题。文献[3,4]将支持向量机成功应用于发动机飞行过程建模,这种方法优于神经网络方法,获得的模型具有很好的推广性,非常适合复杂过程建模,但是这种方法很难实现在线建模,对于自身核参数的选择也存在困难。文献[5]将遗传规划用于复杂过程的建模,但是经典遗传规划产生的模型十分复杂,很难走向工程应用。另外一种是非线性核参数(Linear in Parameter)非线性模型为代表的非线性建模方法,这种辨识模型物理意义明确,精度高。文献[6]将 Volterra 级数模型应用到一种航空发动机简单动态模型的建模,获得了较好的应用效果,但是这种方法同样存在非线性核的选择难题,随着辨识参数的增加,需要的核呈几何级数增长,模型复杂度高,实用性较差。另外,NAARX(Nonlinear Additive AutoRegressive models with exogenous inputs models,简称 NAARX)模型^[7],多项式 ARMA 模型^[8],在复杂过程的建模中也取得了成功的应用。

在上述所有建模方法中,模型结构选择是一项十分重要且没有严格理论指导的工作。线性模型在应用过程中模型结构可由先验确定的或者由一些信息准则例如 AIC 准则(Akaike Information Criterion,简称 AIC),最终预报误差(Final Prediction Error,简称 FPE),最小描述长度(Minimum Description Length,简称 MDL)确定,基本能够获得满意的工程应用结果。而对于

非线性模型结构选择的研究工作很少^[9,10]。传统的模型结构选择方法对于问题的适用性较窄,且对使用人员的经验要求较高,在进行了结构选择之后往往还要再对模型结构参数进行估计。因此,方法的自动化程度和实用性都受到很大限制。

为了克服一般方法结构选择和参数估计的困难,本文利用遗传规划^[11]的符号回归优化功能,结合正交最小二乘(Orthogonal Least Squares algorithm,简称 OLS)技术^[12],提出了一种约简 GP 算法(Parsimonious Genetic Programming,简称 PGP)和一种新的模型结构自动选择方法,并成功给出了一种新的航空发动机起动过程建模方法,起动过程试验数据仿真验证了该方法的有效性。

1 航空发动机线参数非线性模型

1.1 航空发动机起动过程线参数非线性模型及其机理

对发动机地面起动而言,数学模型的核心是发动机的气动热力特性,模型的输入量为大气条件(大气温度和大气压力)、起动机特性、负载特性和供油系统特性(在正常起动的情况下,点火特性可以与供油特性一起考虑)。实际中,低转速情形下的气动热力特性由于缺乏有效的特性数据而无法应用。采用数据辨识模型可以较好的满足低转速特性下的过程建模问题。常规的状态空间模型仅仅作了一阶近似,而实际情形要复杂的多。因此,如果能够找到一种可以更加合理的、能够自动确定模型阶数以获得更贴近发动机起动过程非线性本质的方法十分有意义。

首先,确定发动机起动过程的输入状态变量和输出变量。在起动过程中,由于发动机转子的惯性,需要考虑低压转子转速 n_L 和高压转子转速 n_H 两个量;由于燃烧特性及热损失对起动过程有重要影响,需要考虑涡轮前燃气温度 T_4 ,但其测量困难,根据经验可采用涡轮后燃气温度 T_5 替代。对于起动过程还需要考虑起动机的扭矩特性 T_{qs} ,负载阻力矩特性 T_q ,主燃烧室供油规律 m_f ,大气条件(T_0, p_0)等因素。

确定了输入、输出和影响因素之后,就可以建立发动机起动过程非线性动态模型:

$$\begin{cases} n_L(k+1) = f_1(\mathbf{x}(k)) \\ n_H(k+1) = f_2(\mathbf{x}(k)), \mathbf{x}(k) = \\ T_5^*(k+1) = f_3(\mathbf{x}(k)) \end{cases}$$

$$\begin{bmatrix} u_1(k-n_d-1) & \dots & \dots & u_1(k-n_d-n_b) \\ u_2(k-n_d-1) & \dots & \dots & u_2(k-n_d-n_b) \\ \vdots & \dots & \dots & \vdots \\ u_m(k-n_d-1) & \dots & \dots & u_m(k-n_d-n_b) \\ y(k-n_d-1) & \dots & \dots & y(k-n_d-n_a) \\ e(k-n_d-1) & \dots & \dots & e(k-n_d-n_e) \end{bmatrix}$$

$$\begin{matrix} T_0 & p_0 \end{matrix}$$

$$(1)$$

其中, f_1, f_2, f_3 为理想的非线性映射函数。 n_d 为时间延迟, $\mathbf{x}(k)$ 表示模型输入量, 其中的 $u_1, \dots, u_m$ 表示状态输入量, 例如: 低、高压转子转速 n_L, n_H , 涡轮后燃气温度 T_5 , 起动机扭矩特性 T_{qs} , 负载阻力矩特性 T_q , 主燃烧室供油规律 m_t ; y 表示模型输出量, 例如低、高压转子转速 n_L, n_H , 涡轮后燃气温度 T_5 ; (T_0, p_0) 为大气条件; n_b, n_a, n_e 分别对应输入、输出和误差的阶数。

采用线参数非线性模型实际就是通过建立一种具有非线性内核的线性叠加模型来逼近理想的非线性映射函数。由一般非线性函数的 Gabor-Kolmogorov 方差分析(ANOV A)可知, 任一非线性函数都可以由线参数模型得到精度的近似。因此, 对于发动机起动过程中的每个映射函数 f , 都可以转化为如下的一般线参数非线性模型进行求解:

$$\hat{y}(k) = \sum_{i=1}^M p_i F_i(\mathbf{x}(k))$$

$$\mathbf{x}(k) = [u_1(k-n_d-1), \dots, u_1(k-n_d-n_b), \\ u_2(k-n_d-1), \dots, u_2(k-n_d-n_b), \\ \vdots \\ u_m(k-n_d-1), \dots, u_m(k-n_d-n_b), \\ y(k-n_d-1), \dots, y(k-n_d-n_a), \\ e(k-n_d-1), \dots, e(k-n_d-n_e)]$$

$$(2)$$

其中, $u_1, \dots, u_m$ 表示的是输入状态变量。 $F_1, \dots, F_M$ 为非线性内核函数, $p_1, \dots, p_M$ 表示模型参数。

1.2 参数估计和简化

线参数模型一个十分重要的优点是可以将式 (2) 的参数估计转化为如下极值问题:

$$\min_p X^2 = \sum_{k=1}^N (y(k) - \sum_{i=1}^M p_i F_i(\mathbf{x}(k)))^2$$

$$(3)$$

其中, N 表示数据点数, $\mathbf{p} = [p_1, p_2, \dots, p_M]$ 表示待估计的参数, 利用最小二乘方法可以方便的得到最优参数:

$$\mathbf{p} = (\mathbf{F}^T \mathbf{F})^{-1} \mathbf{F}^T \mathbf{y}$$

$$(4)$$

其中, $\mathbf{y} = [y(1), y(2), \dots, y(N)]$ 表示观测输出向量, $\mathbf{F}$ 表示回归矩阵:

$$\mathbf{F} = \begin{bmatrix} F_1(\mathbf{x}(1)) & \dots & F_M(\mathbf{x}(1)) \\ \vdots & & \vdots \\ F_1(\mathbf{x}(N)) & \dots & F_M(\mathbf{x}(N)) \end{bmatrix}$$

$$(5)$$

在实际中, 由于输入输出变量之间的相互作用系统通常有冗余, 从而使得模型复杂度随着变量数目的增多而急剧上升, 且由于模型中函数项对于模型精度贡献的不同, 上述模型仍可通过适当的手段进行简化。正交最小二乘算法是一种可用来确定线参数模型各组成函数项重要度的有效方法。正交最小二乘算法引入误差减少率(Error reduction ratio) 表征各项对于降低模型输出误差的贡献。这样在获得了各函数项的贡献之后就可以去除一些不必要的项, 从而可对模型做进一步简化。式 (2) 可以写成如下矩阵形式:

$$\mathbf{y} = \mathbf{F}\mathbf{p} + \mathbf{e}$$

$$(6)$$

正交最小二乘算法将回归矩阵的列向量变换到正交基空间, 获得函数项的贡献。设回归矩阵 $\mathbf{F}$ 可以正交分解为: $\mathbf{F} = \mathbf{W}\mathbf{A}$, 其中 $\mathbf{W}$ 是一 $N \times M$ 矩阵, 且满足 $\mathbf{W}^T \mathbf{W} = \mathbf{D}$ 为对角阵, $\mathbf{A}$ 是一 $M \times M$ 单位三角阵, N 是输出向量 $\mathbf{y}$ 的个数, M 是回归量的个数。则正交最小二乘辅助参数向量为:

$$\mathbf{g} = \mathbf{D}^{-1} \mathbf{W}^T \mathbf{y}$$

$$(7)$$

g_i 为正交最小二乘解向量的对应元素。 $(\mathbf{y}^T \mathbf{y})/N$ 输出方差可以解析为:

$$\mathbf{y}^T \mathbf{y} = \sum_{i=1}^M g_i^2 w_i^T w_i + \mathbf{e}^T \mathbf{e}$$

$$(8)$$

则, 对应 F_i 项的误差减少率可以表示为:

$$[\text{err}]_i = \frac{g_i^2 w_i^T w_i}{\mathbf{y}^T \mathbf{y}}$$

$$(9)$$

1.3 模型结构选择

对于线参数模型而言, 结构选择就是要寻找合适的非线性函数集 F_i , 结构选择是当前学术界尚未解决的热点研究问题。对应的主要有两种思路。一种是产生所有的可能模型结构然后选择误差最小的模型集。另一种是将结构选择问题转化为最优化问题, 通过启发式搜索算法获得最优模型集。相比较, 第一种方法计算量大, 第二种方法将结构选择问题转换成为一个优化问题, 通过

启发式算法搜索可行解,有效降低了算法的复杂度,因此,本文着重考虑采用遗传规划解决模型结构选择难题。

2 约简 PGP 算法

2.1 线参数模型的 GP 表征

遗传规划是由 Koza 教授提出的符号优化技术,这种技术采用树结构表征可能解,在遗传规划中的每一个个体都由运算符和终止符组成,最常用的树结构表征表示方法是采用二叉树分解方法。运算符和终止符分别从运算符集 F 和终止符集 T 中选取。运算符集 F 可能为 $\{+, -, *, /, \sqrt{}, \log, \dots\}$ 等等,而终止符集通常由变量和常量组成,为了保证产生的模型具有线参数,必须将终止符集中的常量去掉,而只包含变量,例如 $T = \{x_1(k), \dots, x_m(k)\}$,其中 $x_i(k)$ 表示第 i 个回归变量。在进行运算之前,需要将模型进行恰当分解,从而构造合理的二叉树,本文采用一种简单有效的构造方法,即从根节点开始,遇到非线性节点(运算符不是“+”或者“-”)终止。

以线参数模型 $y = p_0 + p_1(x_3 + x_2)/x_1 + p_2x_1 + p_3x_3$ 为例简要说明构造过程。根节点为“+”,这样就可以将模型分成两棵子树 A 和 B ,子树 A 的根节点为“+”,还可以将其分解成子树 C 和 D ,而对于子树 B 由于根节点为“/”,按照规则不能继续分解,最终将模型分解为子树 B, C 和 D 三项,这三项称为三个基本函数项,如图 1 所示。后续仿真实验证明这样产生的二叉树结构均衡,合理,非常适合采用 OLS 评价基本函数项的精度贡献。




图 1 模型的二叉树结构表征和基本函数项分解

Fig. 1 Model representation tree and basic function term decomposition

3.2 遗传操作符

遗传规划是进化算法的一种,首先算法会产生一组个体形成初始种群,然后在每个迭代过程中,计算个体的适应度,根据适应度选择个体配对

进行重组,实施直接复制,交叉,变异等遗传操作产生新个体,实施精英策略进行替换,最终产生新一代种群。GP 的一般步骤详细如下:

第一步,设置 GP 算法参数,随机产生初始种群;

第二步,计算适应度,采用轮盘赌选择重组配对个体,选择概率为 $P_i = \frac{f_i}{\sum f_i}$;

第三步,对选定的配对个体实施直接复制,交叉,变异三种操作。设定变异概率为 p_m ,交叉概率为 p_c ,则直接复制的概率为 $1 - p_m - p_c$ 。直接复制将选定个体直接保留到下一代。变异则在选定的树结构随机选定部位产生支树随机替换。交叉在选定的两个父个体间进行,先随机确定交叉点并将各自的树结构分隔开,然后进行交换,从而产生两个新个体。常用的交叉方式一般有两种,一种是采用单点交叉,另外一种是采用两点交叉;

第四步,设定一定的代沟(Generation Gap),实施精英替换策略,最终生成新种群。例如设定代沟 $P_{gap} = 0.9$,则表示有 90% 的老个体将被新产生的优良个体替换,只有 10% 的优良老个体被保留到新种群,这样有利于保持种群的多样性。

2.3 适应度函数

适应度函数直接反映了模型的好坏。通常在模型辨识中,适应度函数可以根据模型输出和观测输出之间的均方差确定,另外根据计算输出和观测输出的关联系数 r 确定的适应度也是常用的方法。一个好的模型不但要准确,也要简单,明晰,解析性好,具有推广性,由于经典 GP 经常产生十分复杂的模型,因此需要在模型精度和复杂度上权衡。这里采用一种具有惩罚项的适应度函数:

$$f_i = \frac{r_i}{1 + \exp(a_1(L_i - a_2))} \tag{10}$$

其中, f_i 是适应度值, r_i 是关联系数, L_i 是树的节点数, a_1, a_2 是惩罚函数的参数。实际应用中,获得的模型经常会过参数化,包含不必要的复杂项。采用式 (10) 可以获得较为理想的模型,当模型具有复杂项的时候,适应度会减少。但是,对惩罚函数参数的选择通常难确定,使用时可做多次实验统计后确定。

2.4 PGP 算法

为改善 GP 算法,去除 GP 可能产生的结构复杂又对误差减少率影响不大的项,提高 GP 收敛速度,得到简化、准确的线参数模型,结合正交

最小二乘便于评价函数项贡献的特点, 本文给出了将正交最小二乘算法与 GP 相结合的 PGP 约简遗传规划算法。PGP 算法描述如下:

- 第一步, 设置 GP 参数, 产生初始种群;
- 第二步, 对当前种群实施 OLS 简化策略, 包括: ①将种群个体分解成为子树, 得到基本函数项; ②根据 OLS 计算函数项错误下降率; ③根据 OLS 域值, 去除冗余函数项;
- 第三步, 执行 3.2 节给出的 GP 操作;
- 第四步, 判断是否满足停机准则, 若满足转到第五步, 否则转到第二步;
- 第五步, 输出最优模型集, 结束。

3 航空发动机 PGP 起动过程建模应用案例

某型发动机在同一机场条件下分别在起动供油量不调整、起动供油量调整螺钉顺调一圈以及调整螺钉反调一圈三种情况下采集起动过程数据见图 2~ 图 4。并且假定供油量调整基本不会影响到发动机起动过程中负载的阻力矩特性, 因此可以不考虑大气条件和负载阻力矩特性的影响, 而主要侧重于检验模型在不同供油规律条件下的推广能力。另外, 由于直接采集到起动过程中的供油量信息十分困难(慢车转速以下采集的供油量信号波动较大, 信号失真严重), 考虑用副油路油压信号 p_f 替代实际供油量信号。

由前述分析可以确定起动过程 GP 模型的终止符集 $T = \{p_f, T_{gst}, n_L, n_H, T_5\}$, 考虑到起动过程的复杂性, 供油量不调整情况下本文考虑了两种运算符集: $F_1 = \{+, *\}$, $F_2 = \{+, *, \sqrt{\quad}\}$, 对应的模型分别记为模型 1 和模型 2。

$$n_L(k) = \begin{cases} 1.85n_H(k-1)T_5(k-1) + 0.91n_L^2(k-2)T_5(k-1) + 0.24n_L(k-1) \\ + 1.28n_L(k-2) - 0.44n_L^2(k-1)n_L^2(k-2) - 2.55T_5(k-1)n_L(k-2) \\ - 0.38n_H(k-1) - 0.12T_5(k-1) + 0.02 \end{cases}$$
$$n_H(k) = \begin{cases} 0.23n_L(k-2)n_H(k-2) + 0.01p_f^2(k-1) + 0.01T_5(k-2) \\ + 0.66n_H(k-2) - 0.38n_H(k-1) - 0.08n_L^2(k-1)n_L(k-2)T_5(k-2) \\ - 0.18n_H(k-1)n_H(k-2) - 0.01p_f(k-1) - 0.05n_L(k-2) \end{cases} \quad (12)$$
$$T_5(k) = \begin{cases} 1.28T_5(k-1)p_f(k-2) + 0.51p_f(k-2)T_5(k-2) + 0.49T_5^2(k-1) \\ + 0.14p_f^2(k-2) - 1.72p_f^2(k-2)T_5^2(k-1) - 0.41p_f(k-2) \\ - 0.01n_L(k-1) - 0.12T_5(k-1) + 0.18 \end{cases}$$

为了尽可能消除由于数据物理量或数量级引起的误差, 本文采用的一种典型数据处理变换方法, 通过变换将数据变换到区间[0.2, 0.8]之间。

$$x'_k = \frac{0.6(x_k - \min(x_k))}{\max(x_k) - \min(x_k)} + 0.2$$
$$y'_k = \frac{0.6(y_k - \min(y_k))}{\max(y_k) - \min(y_k)} + 0.2 \quad (11)$$

PGP 参数经多次实验统计, 如表 1 所示的设置可以取得满意的结果。为了证明该方法的适用性, 本文采用同一工作条件下供油量调整的两组数据进行测试, 一组将供油螺栓反拧一圈(见图 3), 一组将供油螺栓顺拧一圈(见图 4)。为说明 PGP 模型的优越性、推广性以及对于非线性动力特征的辨识能力, 本文还支持向量机起动过程非线性模型(参数设置采用 10 层交叉验证获得, 如表 3 所示)进行了对比, 得到的两组 PGP 动态模型如式(12)、式(13)所示, 误差结果如表 2、表 3 所示。

表 1 GP 算法设置
Table 1 GP settings

GP 参数	设定值
种群大小	50
进化代数	5000
代沟	0.8
交叉概率	0.8
变异概率	0.2
最大树深度	3
OLS 域值	0.0001
惩罚因子 (a_1, a_2)	(0.5, 45)

PGP 模型 1:




图 2 供油螺栓不调整 PGP 训练结果

Fig.2 PGP Training result without screwing




图 3 反拧供油螺栓 PGP 模型测试结果

Fig.3 Screw anticlockwise PGP model testing result

PGP 模型 2:

$$\begin{aligned} n_L(k) &= \begin{cases} 2.82n_H(k-1)T_5(k-1) + 0.20T_5(k-1)\sqrt{T_5(k-1)} + 0.24n_L(k-1) \\ + 0.55n_L(k-2) + 0.01p_f(k-1) - 0.77T_5^3(k-1)n_L(k-2) \\ - 0.43n_L(k-2)n_L(k-1) - 1.82T_5(k-1)\sqrt{n_H(k-1)} \\ - 0.20n_H(k-1) + 0.13 \end{cases} \\ n_H(k) &= \begin{cases} 0.10n_L^2(k-2) + 0.10p_f(k-1)n_H(k-2) + 0.01T_5(k-1) \\ + 0.60n_H(k-2) + 0.05n_L(k-2) + 0.60n_H(k-1) - 0.01p_f(k-1) \\ - 0.27n_H(k-1)\sqrt{n_H(k-1)} - 0.13n_L(k-2)\sqrt{p_f(k-1)} - 0.02 \end{cases} \\ T_5(k) &= \begin{cases} 0.79T_5^3(k-2)p_f(k-2)\sqrt{T_5(k-2)} + 6.56\sqrt{T_5(k-1)}p_f(k-2) \\ + 7.92T_5(k-2)\sqrt{T_5(k-1)} - 5.75p_f(k-2)T_5(k-1) - 1.72T_5(k-1) \\ - 2.02T_5(k-2) - 3.45T_5^2(k-2) - 1.79p_f(k-2) - 0.01n_L(k-1) + 0.38 \end{cases} \end{aligned} \quad (13)$$

表 2 PGP 模型误差

Table 2 PGP Model error

训练/测试 误差	PGP 模型 1			PGP 模型 2		
	n_L (%)	n_H (%)	T_5 (℃)	n_L (%)	n_H (%)	T_5 (℃)
不调整	0.28	0.81	1.2	0.25	0.80	0.8
顺拧	5.87	1.96	0.8	5.46	1.19	0.2
反拧	5.98	1.97	1.1	5.56	1.16	0.7

表 3 支持向量机模型误差

Table 3 SVM Model error

训练/测试 误差	$(\sigma, C, \epsilon) =$ (2.8, 100, 0.008)			$(\sigma, C, \epsilon) =$ (2.8, 50, 0.01)		
	n_L (%)	n_H (%)	T_5 (℃)	n_L (%)	n_H (%)	T_5 (℃)
不调整	0.30	1.01	6.9	0.32	0.98	7.8
顺拧	4.66	1.20	7.8	4.05	0.98	7.2
反拧	4.68	1.26	1.8	4.03	1.05	0.9




图4 顺时针供油螺栓 PGP 模型测试结果

Fig.4 Screw clockwise PGP testing result

从表2、表3可见,PGP模型1、PGP模型2,两组SVM模型的训练精度都十分满意,但PGP模型与支持向量机相比拟合精度较高。而且,由于PGP模型2在操作符集中考虑了 $\sqrt{\quad}$ 非线性函数操作符,所得结果又要优于PGP模型1,但是相应的运算量增大。本文获得的经验是:在工程应用时,操作符集的选择可根据实际需求确定,如果模型具有明显非线性特征,建议选取相应的非线性操作符($\sqrt{\quad}$, $\log$, $\exp$),实验证明这样可获得更好的应用效果。

另外,同支持向量机起动过程模型比较,一方面,PGP模型对于 m 转速的推广误差略大,这有可能是由于GP参数设置不合理,或者陷入局部极值,这种现象值得进一步研究。另一方面, n_H 转速、 T_5 温度的推广误差同SVM模型相当,甚至优于SVM模型,尤其是PGP模型2的结果更优。综合来看,PGP模型确实适用于非线性动态过程的自动建模,而且对于动态过程非线性特征具有满意的辨识结果。

4 结论

本文提出了一种约简遗传规划(PGP)算法,并将该算法应用于航空发动机起动过程的建模研究中,提出了一种新的航空发动机起动过程自动建模方法,这种研究思路综合进行系统结构辨识与参数估计,避免了传统的结构辨识与参数估计独立的缺陷,利用实际的发动机起动过程数据进行了分析和验证。实验结果表明,在缺乏系统结构信息的情况下,遗传规划可以获得较为满意的结果,该建模方法具有一般性,对于航空发动机起动过程的建模、控制具有一定的借鉴意义。

值得指出,该算法所得的初步结果具有一定的随机特性,因此如何促进遗传规划在建模过程中的收敛、提高效率和求解质量是建模过程中需要着重考虑的重点。下一步研究中,将着重考虑先验知识引入、GP参数合理确定以及并行分布式PGP快速算法三方面的研究内容,以进一步提高PGP模型的稳定性和快速性。

参考文献:

- [1] 刘小勇,樊思齐.采用BP网络辨识航空发动机数学模型[J].航空动力学报,1996,11(2):153-156.
Liu X Y, Fan S Q. Aeorengine model identification with back-propagation neural networks [J]. *Journal of Aerospace Power*, 1996, 11(2): 153-156.
- [2] 姜涛,李应红.基于动态RBF网络的发动机起动过程模型辨识[J].航空动力学报,2002,17(3):381-384.
Jiang T, Li Y H. A dynamic identification model of aerorengine starting progress based on the RBF network [J]. *Journal of Aerospace Power*, 2002, 17(3): 381-384.
- [3] 李应红,刘建勋.基于支持向量机的航空发动机起动性能估算研究[J].航空学报,2005,26(1):32-35.
Li Y H, Liu J X. Turbofan engine starting characteristics estimation based on Support Vector Machines [J]. *Acta Aeronautica et Astronautica Sinica*, 2005, 26(1): 32-35.
- [4] 尉询楷,李应红,王剑影,等.基于支持向量机的航空发动机辨识模型[J].航空动力学报,2004,19(5):684-688.
Wei X K, Li Y H, Wang J Y, et al. A novel aerorengine identification model based on Support Vector Machines [J]. *Journal of Aerospace Power*, 2004, 19(5): 684-688.
- [5] Stephan Winkler, Michael Affenzeller, Stefan Wagner. New methods for the identification of nonlinear model structures based upon Genetic Programming techniques [Z]. <http://citeseer.ist.psu.edu/634350.html>, 2005.
- [6] 宋志平,程礼,魏瑞轩.航空发动机的一种Volterra级数非线性动态模型[J].航空动力学报,2004,19(4):577-580.
Song Z P, Cheng L, Wei R X. A volterra progression model

- el of nonlinearity dynamic response of aerσ engine[J]. *Journal of Aerospace Power*, 2004, 19(4): 577-580.
- [7] Pearson R, Ogunnaikē B. Nonlinear process identification [A]. In Henson M A, Seborg D E ed. Nonlinear process control [C]. *PrenticeHall: Englewood Cliffs, NJ*, 1997: 10-38.
- [8] Hernandez E, Arkun Y. Control of nonlinear systems using polynomial ARMA models [J]. *AIChE Journal*, 1993, 39(3): 446-460.
- [9] Feil B, Abonyi J, Szeifert F. Model order selection of nonlinear input-output models using a clustering based approach[J]. *Journal of Process Control*, 2004, 14(6): 593-602.
- [10] Pearson R. Selecting nonlinear model structures for computer control [J]. *Journal of Process Control*, 2003, 13(1): F26.
- [11] Koza J. Genetic programming: on the programming of computers by means of natural selection [M]. *MIT Press: Cambridge*, 1992.
- [12] Chen S, Billings S, Luo W. Orthogonal least squares methods and their application to nonlinear system identification [J]. *International Journal of Control*, 1989, 50: 1873-1896.

JALSP