

文章编号:1000-8055(2013)06-1420-09

基于 RVM 回归误差补偿的航空发动机 分布式控制系统多步预测控制

王 磊^{1,2}, 谢寿生¹, 苗卓广¹, 任立通¹, 余 坚¹

(1. 空军工程大学 航空航天工程学院, 西安 710038;

2. 中国人民解放军 93704 部队, 北京 101100)

摘 要: 针对具有随机有界双侧时延的航空发动机分布式控制系统, 提出了一种基于多步预测和关联向量机(RVM)回归误差补偿的控制方案. 首先建立航空发动机分布式控制系统(DCS)的神经网络非线性自回归滑动平均(NARMA)模型, 利用当前的系统输出和控制量对 N 步之后的系统输出进行预测; 其次用改进的 RVM 回归多步预测算法估计 NARMA 模型的预测误差, 并对预测结果进行误差补偿; 最后利用补偿之后的预测值和设定值对控制参数进行滚动优化, 设计系统的神经网络逆控制器实现系统的自适应控制. 仿真结果证明该控制策略能够避免随机有界双侧时延对控制系统的影响, 实现对设定值的稳定跟踪, 且控制器具有较好的实时性和鲁棒性. 低压转子转速阶跃响应的稳态绝对误差小于 0.04%, 响应时间小于 0.3 s.

关 键 词: 航空发动机; 分布式控制系统; 非线性自回归滑动平均(NARMA)模型; 多步预测控制; 误差时间序列; 关联向量机(RVM)

中图分类号: V233.7

文献标志码: A

Multi-step predictive control for aero-engine distributed control system based on RVM regression error compensation

WANG Lei^{1,2}, XIE Shou-sheng¹, MIAO Zhuo-guang¹,
REN Li-tong¹, YU Jian¹(1. Aeronautics and Astronautics Engineering Institute,
Air Force Engineering University, Xi'an 710038, China;

2. Unit 93704 of Chinese People's Liberation Army, Beijing 101100, China)

Abstract: A multi-step predictive control method based on relevance vector machine (RVM) regression error compensation was put forward to control aero-engine distributed control system (DCS) with stochastic and bounded time-delay. The neural network nonlinear auto regressive moving average (NARMA) model of the aero-engine DCS was established to predict the future output. An improved multi-step prognostic algorithm based on RVM regression was presented to estimate prognostic error series which were compensated for the NARMA model. Finally, a neural network inverse controller was designed, and rolling optimization of the parameters was conducted by prognostic output and the expectations. Simulation results illustrate the control strategy avoids the effect of stochastic and

收稿日期:2012-11-03

网络出版地址: http://www.cnki.net/kcms/detail/11.2297.V.20130617.0940.201306.1420_028.html

作者简介: 王磊(1983—), 男, 河南济源人, 博士生, 研究领域为航空发动机综合数字控制.

bounded time-delay on the control system. The controller has favorable dynamic tracking and robust performance. The absolute steady error of low-pressure rotor speed step response is less than 0.04%, and the response time is less than 0.3 s.

Key words: aero-engine; distributed control system; nonlinear auto regressive moving average (NARMA) model; multi-step predictive control; time series error; relevance vector machine (RVM)

时延是影响航空发动机分布式控制系统(DCS)性能的主要因素之一,由于时延的存在,依据当前时刻发动机输出信号产生的控制量到达执行机构时已失去了它的时效性^[1].另外航空发动机的分布式控制系统具有输出和控制双侧时延,且其控制参数是非线性时变的,所以不能近似地将双侧时延合并考虑^[2],因此如何减小双侧时延对控制系统的影响是航空发动机分布式系统在进行控制器设计时需要考虑的问题.近年来,国内外学者针对该问题开展了一系列有益的研究^[3-4],目前有效的方法是根据当前时刻的系统输出和控制量预测未来的系统输出,并根据预测值和设定值对控制参数进行滚动优化,以使两者尽可能逼近^[5-7].

然而目前的研究成果均对系统进行了过多的假设,使得所设计的控制器具有较大的局限性.如文献[8]以最小二乘支持向量机(LS-SVM)模型作为辨识器预测未来的发动机输出量,并用 proportional integration differential(PID)神经网络设计控制器实现了系统的自适应控制.但文中的LS-SVM辨识器仅对输出量进行了一步预测,并不适用于存在随机有界时延的情况.文献[7,9]分别采用非线性自回归滑动平均(NARMA)和神经网络建模思想对时滞系统的输出进行了多步预测,但文中考虑的系统都只存在单一时延,并未考虑输出时延和控制时延并存的情况.另外也有学者采用LS-SVM和神经网络方法进行多步预测^[10],但这种由一步到多步的推广过程忽略了单步预测的不确定性,将单步预测结果作为一个确定值来看待,因此预测过程存在较大的误差.

考虑以上不足,本文针对具有随机有界双侧时延的航空发动机分布式控制系统,提出了一种基于多步预测和关联向量机(RVM)回归误差补偿的控制方案.首先,在传统NARMA模型基础上加入了双侧时延的控制关系,建立航空发动机分布式系统的神经网络NARMA模型,利用当前的系统输出量和控制量对 N 步之后的系统输出

进行预测;其次对RVM回归多步预测方法进行改进,使其克服单步预测的不确定性,并能够加速收敛,用改进后的方法估计神经网络NARMA模型的多步预测误差,并对预测结果进行补偿;最后利用补偿之后的预测值和系统设定值对控制参数进行滚动优化,设计系统的神经网络逆控制器实现系统的自适应控制.

1 发动机输出量多步预测

1.1 神经网络NARMA模型建立

航空发动机的分布式控制系统如图1所示, τ_{sc}^i 为系统的输出时延,即从第 i 个传感器得到输出数据时刻起至该数据开始被控制器处理的这段时间; τ_{ca}^i 为系统的控制时延,即从控制器产生第 i 个执行机构的控制信号时刻起至该控制信号使对应的执行机构产生相应动作的这段时间.



图1 航空发动机分布式控制系统结构图

Fig.1 Structure chart of aero-engine DCS

假设1 传感器、中央控制器和执行机构三者时钟同步.

假设2 数据带有时间戳并为单包传输,且无时序错乱.

假设3 控制时延 $\tau_{ca}^1, \dots, \tau_{ca}^n$ 和输出时延 $\tau_{sc}^1, \dots, \tau_{sc}^m$ 均随机有上界.各传感器输出量在网络中传递的优先级相同.因此可近似认为各传感器输出量到中央控制器的输出时延相等,用 τ_{sc} 表示.同理从中央控制器到各执行机构的控制时延也近似相等,记为 τ_{ca} .

系统方程可以描述为

$$\begin{cases} x(k+1) = f\{x(k), u[k - \bar{\tau}_{ca}(k)] \\ u[k - \bar{\tau}_{ca}(k) - 1]\} + \xi(k) \\ y(k) = h[x(k)] \end{cases} \quad (1)$$

其中 $\bar{\tau}_{ca}(k) = [\tau_{ca}(k)/T]$, T 为传感器的采样周期, $[\cdot]$ 为取整运算. 舍弃 τ_{ca} 的小数部分, 控制量输入 $u(k) = [u_1(k), u_2(k), \dots, u_r(k)]^T$, 系统输出 $y(k) = [y_1(k), y_2(k), \dots, y_m(k)]^T$, 系统噪声为 $\xi(k)$.

定义 1^[11] 对于形如 $\Psi: x(k+1) = f[x(k), u(k)]; y(k) = h[x(k)]$ 的非线性多输入多输出 (MIMO) 系统, $(x, u) \in \Omega$, 其中 $\Omega \subset R^{n+m}$ 为开紧集, 如果满足 $\frac{\partial y_i(k+p_j)}{\partial u_j(k)} \equiv 0$ ($i = 1, 2, \dots, m; j = 1, 2, \dots, r; p_j = 0, 1, \dots, d_j - 1$), 同时至少存在一个 j 使得 $\frac{\partial y_i(k+d_j)}{\partial u_j(k)}$ 不恒为 0, 则称系统 Ψ 具有相对阶 $\{d_1, d_2, \dots, d_r\}$, d_i 为正整数.

引理 1^[12] 若系统 Ψ 具有时滞特性, 在定义域范围内相对阶 $\{d_1, d_2, \dots, d_r\}$ 存在, 且 Ψ 可观测, 则系统 Ψ 可以用 NARMA 模型表示.

$$y[k + \bar{\tau}(k)] = \begin{cases} y_1[k + \bar{\tau}(k)] \\ y_2[k + \bar{\tau}(k)] \\ \vdots \\ y_m[k + \bar{\tau}(k)] \end{cases} = \begin{cases} g_1[y(k), u(k + \bar{\tau}_{sc}(k) - 1), u(k + \bar{\tau}_{sc}(k) - 2)] \\ g_2[y(k), u(k + \bar{\tau}_{sc}(k) - 1), u(k + \bar{\tau}_{sc}(k) - 2)] \\ \vdots \\ g_m[y(k), u(k + \bar{\tau}_{sc}(k) - 1), u(k + \bar{\tau}_{sc}(k) - 2)] \end{cases} \quad (2)$$

其中 $\bar{\tau}(k) = \{[\tau_{sc}(k) + \tau_{ca}(k)]/T\}$, $[y_1(k), \dots, y_m(k)]^T$ 为 k 时刻传感器的输出量, $u[k + \bar{\tau}_{sc}(k)]$ 为 $k + \bar{\tau}_{sc}(k)$ 时刻中央控制器产生的控制量.

$$\hat{y}[k + \bar{\tau}(k)] = \begin{cases} \hat{y}_1[k + \bar{\tau}(k)] \\ \hat{y}_2[k + \bar{\tau}(k)] \\ \vdots \\ \hat{y}_m[k + \bar{\tau}(k)] \end{cases} = \begin{cases} I_{nn1}[y(k), u(k + \bar{\tau}_{sc}(k) - 1), u(k + \bar{\tau}_{sc}(k) - 2)] \\ I_{nn2}[y(k), u(k + \bar{\tau}_{sc}(k) - 1), u(k + \bar{\tau}_{sc}(k) - 2)] \\ \vdots \\ I_{nnm}[y(k), u(k + \bar{\tau}_{sc}(k) - 1), u(k + \bar{\tau}_{sc}(k) - 2)] \end{cases} \quad (3)$$

用 k 时刻系统的实际输出与神经网络模型输出之差的二次型函数(式(4))作为优化的指标函数, RBF 神经网络辨识参数(权值 ω 、阈值 θ 等)均通过离线训练方法获得, 辨识参数的更新采用梯度下降法.

$$J_{li} = \frac{1}{2} [y_i(k) - \hat{y}_i(k)]^2 \quad (4)$$

1.2 时延获得

对于图 1 所示的航空发动机分布式控制系统, 时延由输出时延 τ_{sc} 、控制时延 τ_{ca} 和计算时延 τ_c 三部分组成, 输出时延 τ_{sc} 、控制时延 τ_{ca} 在 1.1 节已经给出定义, τ_c 为控制器节点算法执行所产

分布式控制系统由于控制时延 $\bar{\tau}_{ca}(k)$ 的存在, k 时刻由中央控制器得到的控制量到达执行机构的时刻为 $k + \bar{\tau}_{ca}(k)$, 因此 $u(k)$ 只能影响 $k + \bar{\tau}_{ca}(k) + 1$ 及其以后时刻的系统输出 $y(k+p)$, 其中 $p \geq \bar{\tau}_{ca}(k) + 1$, 而与 $y(k+p)$ 无关, 其中 $p < \bar{\tau}_{ca}(k) + 1$, 即 $\frac{\partial y(k+p)}{\partial u(k)} \equiv 0$ ($p < \bar{\tau}_{ca}(k) + 1$) 且 $\frac{\partial y[k + \bar{\tau}_{ca}(k) + 1]}{\partial u(k)}$ 不恒等于 0. 由定义 1 可知系统方程(1)具有相对阶 $\{\bar{\tau}_{ca}(k) + 1, \bar{\tau}_{ca}(k) + 1, \dots, \bar{\tau}_{ca}(k) + 1\}$.

根据引理 1, 航空发动机分布式系统可用 NARMA 模型表示, 与一般 NARMA 模型不同的是, 本文的研究对象中央控制器结构不是固定的, 因此并不能将输出时延 $\bar{\tau}_{ca}(k)$ 和控制时延 $\bar{\tau}_{sc}(k)$ 合并考虑, 需要在建模的过程中将两者区分对待, $u(k)$ 与 $k + \bar{\tau}(k)$ 时刻的系统输出量 $y[k + \bar{\tau}(k)]$ 并无直接关系, 直接作用于该时刻的控制量为 $u[k + \bar{\tau}_{sc}(k) - 1]$ 和 $u[k + \bar{\tau}_{sc}(k) - 2]$. 故系统方程(1)的 NARMA 模型可以表示为

利用径向基函数(RBF)神经网络逼近函数 $g_1(x), g_2(x), \dots, g_m(x)$ 可得

生的时间, 由于 τ_{sc} 和 τ_{ca} 远大于 τ_c , 所以计算时延 τ_c 可忽略不计. 故只需要设法获得 τ_{sc} 和 τ_{ca} 即可. 由于传感器和控制器时钟同步, τ_{sc} 可以通过在传感器数据中加入时间戳的方法直接获得.

在实际中 τ_{ca} 信息可以通过相关硬件设备的支持获得, 比如 controller area network(CAN)控制器 SJA1000 提供一个中断信号, 用于指示数据发送完成. 但控制量的计算在先, τ_{ca} 的获得在后, 因此当前时刻的 τ_{ca} 值需根据历史时延数据进行推断. 本文采用平均时延窗口方法^[13]对当前时刻的控制时延 τ_{ca} 进行估计

$$\tau_{ca}(k) = \begin{cases} \sum_{i=k-M}^{k-1} \tau_{ca}(i)/M & k \geq M+1 \\ \sum_{i=1}^{k-1} \tau_{ca}(i)/(k-1) & 1 < k \leq M \\ \tau_{sc}(k) & k = 1 \end{cases} \quad (5)$$

其中 M 为时延窗口的大小,即用于估计的历史时延数据的个数。

2 神经网络逆控制器设计

系统 NARMA 模型(2)的逆模型为

$$u[k + \bar{\tau}_{sc}(k)] = f_c^{-1}\{y(k), y[k + \bar{\tau}(k)], u[k + \bar{\tau}_{sc}(k) - 1], u[k + \bar{\tau}_{sc}(k) - 2]\} \quad (6)$$

由于 $y[k + \bar{\tau}(k)]$ 是未来时刻的系统输出,是未知量,这里用 $k + \bar{\tau}(k)$ 时刻的设定值 $y_r[k + \bar{\tau}(k)]$ 代替,采用 3 层前向神经网络对 f_c^{-1} 函数逼近可得神经网络控制器逆模型

$$u[k + \bar{\tau}_{sc}(k)] = C_{nn}\{y(k), y_r[k + \bar{\tau}(k)], u[k + \bar{\tau}_{sc}(k) - 1], u[k + \bar{\tau}_{sc}(k) - 2]\} \quad (7)$$

由图 1 我们知道 $u[k + \bar{\tau}_{sc}(k)]$ 的控制目标是

使 $k + \bar{\tau}(k)$ 时刻的系统输出 $y[k + \bar{\tau}(k)]$ 与 $y_r[k + \bar{\tau}(k)]$ 尽可能接近,同时保证控制增量最小。 $y[k + \bar{\tau}(k)]$ 是未知量,而 1.1 节给出的神经网络 NARMA 预测模型与实际输出 $y[k + \bar{\tau}(k)]$ 之间存在预测误差,它包括噪声 $\xi(k)$ 的递推误差和预测模型的建模误差,该误差与预测步数成正比。对于多步预测控制,若只依靠当前时刻的预测偏差进行校正,即用一个时刻的误差校正多步输出预测值,在递推过程中会严重影响预测精度^[7],且本文的多步预测模型通过离线辨识得到,并不包含训练结束后的更新信息,因此必须对神经网络 NARMA 模型的预测输出进行在线误差补偿,即

$$\hat{y}^*[k + \bar{\tau}(k)] = \hat{y}[k + \bar{\tau}(k)] + e_y[k + \bar{\tau}(k)] \quad (8)$$

其中 $\hat{y}^*[k + \bar{\tau}(k)]$ 为补偿后的系统 $k + \bar{\tau}(k)$ 时刻输出预测值, $e_y[k + \bar{\tau}(k)]$ 为 $k + \bar{\tau}(k)$ 时刻模型的预测误差,关于补偿量 $e_y[k + \bar{\tau}(k)]$ 的求取,本文在第 3 节给出。基于输出预测和误差补偿思想的神经网络逆控制系统结构图如图 2 所示,时延线表示当前时刻的数据向前递推若干个采样周期。




图2 航空发动机分布式控制系统控制方案结构图

Fig. 2 Structure chart of control scheme for aero-engine DCS

根据控制目标设计神经网络控制器逆模型的在线优化性能指标为

$$J_c = \{y_r[k + \bar{\tau}(k)] - \hat{y}^*[k + \bar{\tau}(k)]\}^T Q \{y_r[k + \bar{\tau}(k)] - \hat{y}^*[k + \bar{\tau}(k)]\} + \{u[k + \bar{\tau}_{sc}(k) - 1] - u[k + \bar{\tau}_{sc}(k) - 2]\}^T R \{u[k + \bar{\tau}_{sc}(k) - 1] - u[k + \bar{\tau}_{sc}(k) - 2]\} \quad (9)$$

神经网络辨识参数通过在线训练方法获得,辨识参数的更新采用自适应变步长学习算法,该算法可以改善 back propagation(BP)算法收敛速度慢的问题^[9]。

3 多步预测误差补偿

k 时刻的误差指征用 $e_y(k) = y(k) - \hat{y}(k)$ 来表示, $y(k)$ 为 k 时刻发动机的实际输出, $\hat{y}(k)$ 为由 1.1 节方法得到的 k 时刻输出量的估计值。由于预测模型是由离线训练得到的,不会随着新样本的到来而改变结构参数,因此对误差指征 $e_y(k)$ 的估计就变成了对时间序列 $\{e_y(k) | k = 1, 2, \dots, l\}$ 的多步预测,根据系统时延可知预测步数为 $\bar{\tau}(k)$, $k + \bar{\tau}(k)$ 时刻的误差指征与 k 时刻之前的误差指征数据存在如下的非线性关系:

$$e_y[k + \tau(k)] = f[e_y(k), e_y(k-1), \dots, e_y(k-l+1)] \quad (10)$$

本文采用 RVM 回归的方法对误差时间序列进行预测,该方法在预测精度、计算复杂程度、约束条件上优于神经网络和支持向量机^[14-15]. 但 RVM 回归方法大多用于对时间序列的单步预测. 而航空发动机分布式控制系统的时延是随机有界的,可能大于一个采样周期,因此需要将 RVM 回归方法扩展到多步预测.

3.1 RVM 回归一步预测建模^[14]

给定训练样本集 $\Omega = \{x_i, y_i\}_{i=1}^N$, N 为样本个数, $x_i \in R^d$, $y_i \in R$, RVM 模型输出定义为

$$f(x) = \sum_{i=1}^N \omega_i K(x, x_i) + \omega_0 = \boldsymbol{\varphi}^T(x_i) \boldsymbol{\omega} \quad (11)$$

其中 $\boldsymbol{\omega} = [\omega_0, \omega_1, \dots, \omega_N]^T$ 为系统权值, $K(x, x_i)$ 为核函数, $\boldsymbol{\varphi}(x_i) = [1, K(x_i, x_1), \dots, K(x_i, x_N)]^T$, 样本集 Ω 隐含误差 $\xi \sim N(0, \sigma^2)$. 由于本节关心的是对超参数优化方法改进,因此这里只给出与迭代过程相关的系统权值的后验概率分布和超参数的似然分布.

根据贝叶斯准则计算权值的后验概率分布为

$$p(\boldsymbol{\omega} | y, \alpha, \sigma^2) = \frac{p(y | \boldsymbol{\omega}, \sigma^2) p(\boldsymbol{\omega} | \alpha)}{p(y | \alpha, \sigma^2)} = \frac{N(\boldsymbol{\mu}, \boldsymbol{\Sigma})}{p(y | \alpha, \sigma^2)} \quad (12)$$

其中 $\boldsymbol{\mu} = \sigma^{-2} \boldsymbol{\Sigma} \boldsymbol{\varphi}^T y$, $\boldsymbol{\Sigma} = (\sigma^{-2} \boldsymbol{\varphi}^T \boldsymbol{\varphi} + \mathbf{A})^{-1}$, $\boldsymbol{\varphi}_{N \times N+1} = [\boldsymbol{\varphi}(x_1), \boldsymbol{\varphi}(x_2), \dots, \boldsymbol{\varphi}(x_N)]$, $\mathbf{A} = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$ 为超参数.

超参数的似然分布为

$$p(y | \alpha, \sigma^2) = \int p(y | \boldsymbol{\omega}, \sigma^2) p(\boldsymbol{\omega} | \alpha) d\boldsymbol{\omega} = \frac{N(0, \mathbf{C})}{p(y | \alpha, \sigma^2)} \quad (13)$$

其中 $\mathbf{C} = \sigma^2 \mathbf{I} + \boldsymbol{\varphi} \mathbf{A}^{-1} \boldsymbol{\varphi}$.

通过最大超参数似然分布找到其最优值 α_{mp} 和 σ_{mp}^2 , 并对新观测数据 x_* 作预测时, 预测分布为

$$p(y_* | y, \alpha_{mp}, \sigma_{mp}^2) = \int p(y_* | \boldsymbol{\omega}, \sigma_{mp}^2) p(\boldsymbol{\omega} | y, \alpha_{mp}, \sigma_{mp}^2) d\boldsymbol{\omega} = \frac{N(u, v)}{p(y_* | y, \alpha_{mp}, \sigma_{mp}^2)} \quad (14)$$

其中 $u = \boldsymbol{\mu}^T \boldsymbol{\varphi}(x_*)$, $v = \sigma_{mp}^2 + \boldsymbol{\varphi}(x_*)^T \boldsymbol{\Sigma} \boldsymbol{\varphi}(x_*)$.

3.2 RVM 多步预测的不确定性传递

RVM 回归算法在进行时间序列的一步预测时, 输入量为确定的值 x , 但对于时间序列的多步预测, 输入量为前时刻的输出量, 该量服从式(14)的 Gauss 分布, 是不确定量, 因此将 RVM 回

归算法扩展到多步预测时, 需要将前一步的预测不确定性加入当前时刻的预测当中. 这种不确定性来源于两个方面^[16]: 一是前 m 步预测输出本身的不确定性(用随机变量的方差刻画); 二是当前步的预测输出与前 $m-1$ 步预测输出之间的不确定性(用随机变量之间的协方差刻画). 假设预测步数为 h , 则第 $k+h$ 时刻的预测输出服从如下分布:

$$p[y(k+h) | y(k)] = N\{m[y(k+h)], s[y(k+h)]\} \quad (15)$$

其中

$$\begin{aligned} m[y(k+h)] &= \{u[y(k+h-1)], \dots, u[y(k+1)], \\ &\quad y(k), \dots, y(k+h-l)\}^T \\ s[y(k+h)] &= \{v[y(k+h-1)] \\ &\quad \text{Cov}[y(k+h-1), \tilde{y}(k+h-1)] \\ &\quad \text{Cov}[y(k+h-1), \tilde{y}(k+h-1)]^T s_{k+h-1}\} \\ &\quad \text{Cov}[y(k+h-1), \tilde{y}(k+h-1)] = \\ &\quad \left\{ \begin{array}{c} \text{Cov}[y(k+h-1), y(k+h-2)] \\ \vdots \\ \text{Cov}[y(k+h-1), y(k+h-l)] \end{array} \right\} \end{aligned}$$

$u[y(k)]$ 是 k 时刻输出量的均值, $v[y(k)]$ 是 k 时刻输出量的方差, $\text{Cov}[y(p), y(q)]$ 表示 p, q 时刻输出量的协方差.

这样在每一步迭代预测中, 只需要求出 $u[y(k+h-1)], v[y(k+h-1)]$ 和 $\text{Cov}[y(k+h-1), \tilde{y}(k+h-1)]$ 即可. 本文采用蒙特卡罗采样思想对以上 3 个量进行求解, 求解过程详见文献^[16].

3.3 误差估计的 RVM 在线优化算法

由于对误差的估计采用超参数的在线优化算法, 对算法的收敛速度要求较高, 以往的 RVM 回归算法都是在求得超参数 $\alpha_i = 0$ 时, 才判定该超参数对应的样本点与优化目标无关, 并将其剔除从而获得该步的关联向量, 但超参数收敛于零点需要耗费大量的计算机资源, 导致收敛速度较慢. 本文通过设定样本与优化目标无关的超参数最小值 $\alpha^{\min}$, 放宽了对关联向量的筛选条件, 当 $\alpha_i^{\text{new}} \leq \alpha^{\min}$ 时提前将对应样本剔除迭代过程, 减小了每一次迭代的时间消耗. 具体优化步骤如下:

Step 1 设定超参数 A 和方差 σ^2 的初始值, 设置 α 的更新阈值 $\alpha^{\min}$;

Step 2 根据当前的 A, σ^2 值, 按照式(12)求出均值 μ 和协方差 Σ ;

Step 3 将式(13)分别对 α, σ^2 求导, 并令导数

为0,用MacKay方法,求得 α_i 和 σ^2 的更新值

$$\alpha_i^{\text{new}} = \frac{1 - \alpha_i \Sigma_{ii}}{\mu_i^2}, \sigma^2_{\text{new}} = \frac{\|y - \phi\mu\|^2}{N - \sum_{i=1}^N (1 - \alpha_i \Sigma_{ii})}, \mu_i \text{ 为}$$

μ 的第 i 行, Σ_{ii} 为 Σ 的第 i 个对角线元素,并用 α_i^{new} 和 σ^2_{new} 对 A 和 σ^2 进行更新;

Step 4 判断 α_i^{new} 和 σ^2_{new} 是否满足MacKay迭代的收敛条件,若满足则得到当前步的最优值 α_{mp} 和 σ_{mp}^2 ,转入step 6,反之转入step 5;

Step 5 若 $\alpha_i^{\text{new}} > \alpha^{\text{min}}$,则返回step 2,反之则剔除第 i 对训练样本及其核函数 $K(x, x_i)$,更新 ϕ 值后,返回step 2;

Step 6 将 $\alpha_{\text{mp}}, \sigma_{\text{mp}}^2$ 的值代入式(14)求取 $u[y(k+i)], v[y(k+i)]$,此时 $i=1$;

Step 7 按照式(15)求取 $m[y(k+i)], s[y(k+i)]$;

Step 8 按照蒙特卡罗思想,对分布 $N\{m[y(k+i)], s[y(k+i)]\}$ 进行采样,并计算 $u[y(k+i+1)], v[y(k+i+1)]$ 和 $\text{Cov}[y(k+i+1), \tilde{y}(k+i+1)]$;

Step 9 反复运行step 7, step 8直到 $i=h$, $u[y(k+h)]$ 即为 $k+h$ 时刻的系统输出均值,迭代停止。

4 仿真及结果分析

仿真中用于训练和检测的数据来源于基于CAN总线的航空发动机分布式综合控制半物理仿真系统^[10],该系统以某涡扇发动机为被控对象,其气动热力学模型可以表示为

$$\begin{cases} \dot{n}_1 = f_1(n_1, n_h, m_f, A_e, T_1^*, p_1^*) \\ \dot{n}_h = f_2(n_1, n_h, m_f, A_e, T_1^*, p_1^*) \\ y = h(n_1, n_h, m_f, A_e, T_1^*, p_1^*) \end{cases} \quad (16)$$

其中 $y = [n_1, \pi_t]^T$, $n_1, n_h, m_f, A_e, \pi_t$ 分别为发动机低压转子转速、高压转子转速、主供油量、尾喷管喉部面积和涡轮落压比, T_1^*, p_1^* 分别为发动机进口总温和进口总压, $f_1(\cdot), f_2(\cdot), h(\cdot)$ 为发动机非线性映射关系。

令系统采样周期 $T=10\text{ ms}$,取 $H=0, Ma=0, n_1 \in (85\%, 90\%)$ 情况下,相邻时刻的500组数据 $\{n_1, n_h, m_f, A_e, T_1^*, p_1^*, \tau_{sc}, \tau_{ca}\}_{1}^{500}$,其中前420组对发动机神经网络NARMA模型进行训练,后80组用于检测。由于 n_1 和 π_t 控制效果类似,限于篇幅,此处仅以低压转子转速 n_1 为例给出仿真结果。 n_1 的多步输出预测如图3所示,从图中可以看出,仅用当前一个时刻的输出误差去校正多步预

测的输出值,在递推的过程中会出现较大的误差。




图3 n_1 多步输出预测结果

Fig. 3 Multi-step predicted result of n_1

分别用本文的RVM回归方法、神经网络(NN)多步预测方法和LS-SVM回归方法对神经网络NARMA模型的多步预测误差序列进行估计,结果如图4所示,表1给出了以上3种方法对80组检测数据进行预测的均方误差及预测时间。由于NN方法和LS-SVM回归方法在多步迭代的过程中并没有考虑单步预测的不确定性,仅仅是将前一步预测结果的确定值作为下一步的预测输入,预测效果并不是很理想,预测结果的均方误差分别为0.0356和0.0232,另外NN方法的收敛速度较慢,计算耗时较长。本文提出的改进RVM回归算法考虑了单步输出的不确定性,同时放宽了对关联向量的筛选条件,因此预测结果的均方误差较小,预测时间较短。




图4 n_1 误差量估计效果对比

Fig. 4 Comparison of n_1 error estimation

表1 不同方法预测结果对比


Table 1 Comparison of predicted result of different methods

	RVM	NN	LS-SVM
n_1 均方误差/%	0.0157	0.0356	0.0232
预测时间/s	0.0051	0.0091	0.065

用以上预测方法的误差估计值对神经网络NARMA模型进行误差补偿,得到神经网络逆控制器.仍以低压转子转速 n_1 为例,对其施加1%的阶跃信号,分别设置 $\tau(k) \leq T, \tau(k) \leq 2T, \tau(k) \leq 3T$ 的网络时延




$$\begin{cases} \tau_{sc}(k) = 0.5T \cdot R_{rand} \\ \tau_{ca}(k) = 0.5T \cdot R_{rand} \\ \tau_{sc}(k) = T \cdot R_{rand} \\ \tau_{ca}(k) = T \cdot R_{rand} \\ \tau_{sc}(k) = 1.5T \cdot R_{rand} \\ \tau_{ca}(k) = 1.5T \cdot R_{rand} \end{cases}$$

其中 R_{rand} 为一个 $[0,1]$ 中的随机数.分别对以上3种时延情况进行控制系统仿真,得到阶跃响应如图5~图7所示.从图中可以看出,本文设计的基于RVM回归误差补偿的神经网络逆控制器在存在系统噪声和建模误差情况下,能够较好地实现控制功能,使系统在很短时间内达到稳定,稳态误差较小,且对时延的敏感性不大.而采用NN方法和LS-SVM方法进行误差补偿的神经网络逆控制器,随着时延的增大其控制性能显著下降.

图5 $\tau(k) \leq T$ 时 n_1 阶跃响应曲线Fig. 5 Step response curves of n_1 when $\tau(k) \leq T$

为了说明本文方法在飞行包线其他点和发动机其他工作状态的适应性,选取 $H=10\text{ km}, Ma=1, n_1 \in (90\%, 99\%)$ 范围内相邻时刻的100组数据 $\{n_1, n_h, m_f, A_e, T_1^*, p_1^*, \tau_{sc}, \tau_{ca}\}_1^{100}$ 对RVM误

差补偿器和神经网络逆控制器进行在线训练,得到该情况下控制器的 n_1 阶跃响应如图8所示.可以看出,此时控制系统依然具有较为满意的动态

图6 $\tau(k) \leq 2T$ 时 n_1 阶跃响应曲线Fig. 6 Step response curves of n_1 when $\tau(k) \leq 2T$ 图7 $\tau(k) \leq 3T$ 时 n_1 阶跃响应曲线Fig. 7 Step response curves of n_1 when $\tau(k) \leq 3T$ 图8 $H=10\text{ km}, Ma=1$ 时 n_1 阶跃响应曲线Fig. 8 Step response curves of n_1 when $H=10\text{ km}, Ma=1$

响应.分析原因如下:由于发动机的神经网络模型参数通过离线训练方法获得,当飞行包线点和工作状态发生变化时,训练模型的输出与发动机实际输出之间存在偏差,而这部分偏差将被自动归于预测误差,通过RVM误差补偿器的在线训练,神经网络建模偏差被有效补偿.

5 结 论

本文针对具有随机有界双侧时延的航空发动机分布式控制系统,提出了一种基于多步预测和关联向量机(RVM)回归误差补偿的控制方案.通过仿真对比得出结论如下:

1) 本文根据航空发动机分布式控制系统双侧时延不可合并的特点,在传统NARMA模型中加入了双侧时延的控制关系,并基于该模型的多步预测输出设计了神经网络逆控制器.该控制策略能够很好地避免随机有界双侧时延对控制系统的影响,使系统输出对设定值稳定跟踪.

2) 文中将RVM回归一步预测扩展到多步预测,用于对误差时间序列进行估计.通过设定超参数最小值 $\alpha^{\min}$,放宽了对关联向量的筛选条件,加速了算法的收敛过程,且在每一步的迭代中加入输入参数的不确定性,使迭代过程更符合实际情况.仿真结果证明该方法在预测时间和预测精度方面均优于传统的神经网络多步预测和LS-SVM多步预测方法,且这种优势随时延的增大而更加明显.

3) RVM误差补偿器参数采用在线优化方法,可以对发动机建模偏差进行动态补偿,因此本文方法对于飞行包线其他点及发动机的其他工作状态具有较好的适应性.

参考文献:

[1] 彭靖波, 谢寿生, 武卫, 等. 航空发动机分布式控制系统指数稳定性分析[J]. 航空动力学报, 2009, 24(10): 2362-2367.
PENG Jingbo, XIE Shousheng, WU Wei, et al. Stability analyzation of aero-engine distributed control system[J]. Journal of Aerospace Power, 2009, 24(10): 2362-2367. (in Chinese)

[2] 朱其新, 胡寿松. 网络控制系统的分析与建模[J]. 信息与控制, 2003, 32(1): 5-8.
ZHU Qixin, HU Shousong. Analysis and modeling of network control systems[J]. Information and Control, 2003, 32(1): 5-8. (in Chinese)

[3] 刘涛, 王岩. 基于时延估计组合模型的NCS控制方法研究[J]. 计算机工程与应用, 2010, 46(30): 78-81.

LIU Tao, WANG Yan. Study on control method of NCS based on time delay estimation combined model[J]. Computer Engineering and Applications, 2010, 46(30): 78-81. (in Chinese)

[4] 潘海鹏, 吕勇松. 时滞系统的模糊神经网络补偿控制[J]. 浙江大学学报: 工学版, 2010, 44(7): 1343-1347.
PAN Haipeng, LÜ Yongsong. Fuzzy neural network control method with compensation for time-delay system[J]. Journal of Zhejiang University: Engineering Science, 2010, 44(7): 1343-1347. (in Chinese)

[5] 王瑞敏, 费树岷, 柴琳. 网络控制系统的预测补偿[J]. 控制理论与应用, 2011, 28(10): 1473-1479.
WANG Ruimin, FEI Shumin, CHAI Lin. Predictive compensation for networked control systems[J]. Control Theory & Applications, 2011, 28(10): 1473-1479. (in Chinese)

[6] 付伟, 杨先一, 冯伟, 等. 网络控制系统时延的预测控制补偿方法[J]. 系统工程与电子技术, 2011, 33(9): 2066-2071.
FU Wei, YANG Xianyi, FENG Wei, et al. Predictive control compensation for time delay in networked control systems[J]. Systems Engineering and Electronics, 2011, 33(9): 2066-2071. (in Chinese)

[7] 魏东, 刘熙, 张龙. 神经网络非线性多步预测逆控制方法研究[J]. 计算机应用研究, 2012, 29(1): 211-214.
WEI Dong, LIU Xi, ZHANG Long. Multi-step predictive inverse control based on neural networks[J]. Application Research of Computers, 2012, 29(1): 211-214. (in Chinese)

[8] 赵俊, 陈建军, 王灵刚. 航空发动机的智能神经网络自适应控制研究[J]. 航空动力学报, 2008, 23(10): 1913-1920.
ZHAO Jun, CHEN Jianjun, WANG Linggang. New intelligent neural network adaptive control scheme research for aeroengine[J]. Journal of Aerospace Power, 2008, 23(10): 1913-1920. (in Chinese)

[9] 宗晓萍, 冯贺平. 基于神经网络的时滞系统预测控制[J]. 控制理论与应用, 2005, 24(12): 6-8.
ZONG Xiaoping, FENG Heping. Neural network based predictive control for time delay systems[J]. Control Theory and Application, 2005, 24(12): 6-8. (in Chinese)

[10] 蔡开龙. 航空推进系统分布式综合控制研究与试验[D]. 西安: 空军工程大学, 2008.
CAI Kailong. Research of the aeronautic propulsion distributed control system[D]. Xi'an: Air Force Engineering University, 2008. (in Chinese)

[11] Chen L, Narendra K S. Identification and control of a nonlinear discrete-time system based on its linearization: a unified framework[J]. Transactions on Neural Networks, 2004, 15(3): 663-673.

[12] Cabrera J B D. Nonlinear ARMA models and the general tracking problem for discrete-time dynamical systems[D]. New Haven, Connecticut, US: Yale University, 1997.

[13] 魏震, 李长虹, 谢剑英. 网络控制系统在线时延估计控制[J]. 控制与决策, 2003, 18(5): 545-549.

- WEI Zhen, LI Changhong, XIE Jianying. Online delay-evaluation control for networked control systems[J]. Control and Decision, 2003, 18(5): 545-549. (in Chinese)
- [14] 陈秋霞, 俞立, 黄骅. 基于 RVM 的非线性预测控制及在聚丙烯牌号切换中的应用[J]. 控制与决策, 2010, 25(8): 1241-1245.
- CHEN Qiuxia, YU Li, HUANG Hua. Application of RVM-based nonlinear predictive control to polypropylene grade transition[J]. Control and Decision, 2010, 25(8): 1241-1245. (in Chinese)
- [15] Candela J Q, Girard A, Larsen J, et al. Propagation of uncertainty in Bayesian kernel models-application to multiple-step ahead forecasting[C]// Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing. Lyngby, Danmark: IEEE, 2003: 701-704.
- [16] 张磊, 李行善, 于劲松, 等. 基于关联向量机回归的故障预测算法[J]. 系统工程与电子技术, 2010, 32(7): 1540-1543.
- ZHANG Lei, LI Xingshan, YU Jinsong, et al. Fault prognostic algorithm based on relevance vector machine regression[J]. Systems Engineering and Electronics, 2010, 32(7): 1540-1543. (in Chinese)