

文章编号: 1000-8055 (2009) 05-1035-05

# 基于过程神经网络的航空发动机排气温度预测

丁 刚<sup>1,2</sup>, 徐敏强<sup>2</sup>, 侯立国<sup>3</sup>

- (1. 哈尔滨工业大学 机电工程学院, 哈尔滨 150001;
2. 哈尔滨工业大学 航天学院, 哈尔滨 150001;
3. 北京飞机维修工程有限公司, 北京 100621)

**摘 要:** 从泛函分析的角度出发, 将航空发动机排气温度预测问题转换为一种泛函逼近问题. 利用过程神经网络对任意连续泛函的逼近能力, 提出了一种基于过程神经网络的航空发动机排气温度预测方法. 为克服过程神经网络学习速度慢的问题, 为其开发了一种基于正交基函数展开的 Levenberg-Marquardt 学习算法. 将所提出的预测方法应用到某型航空发动机的排气温度预测中, 取得了满意的结果.

**关 键 词:** 航空发动机排气温度; 预测; 泛函逼近; 过程神经网络; 学习算法

**中图分类号:** V263. 6; TP183

**文献标识码:** A

## Prediction of aeroengine exhaust gas temperature using process neural network

DING Gang<sup>1,2</sup>, XU Min-qiang<sup>2</sup>, HOU Li-guo<sup>3</sup>

- (1. School of Mechatronics Engineering, Harbin Institute of Technology, Harbin 150001, China;
2. School of Astronautics, Harbin Institute of Technology, Harbin 150001, China;
3. Beijing Aircraft Maintenance and Engineering Corporation, Beijing 100621, China)

**Abstract:** From the perspective of functional analysis, the prediction of the aeroengine exhaust gas temperature could be seen as a functional approximation problem in nature. Utilizing the functional approximation capability of the process neural network, an aeroengine exhaust gas temperature prediction method was proposed based on the process neural network. In order to overcome the problem that the learning speed of the existing learning algorithm for process neural network is slow, a Levenberg-Marquardt learning algorithm based on the expansion of the orthogonal basis functions was developed. Finally, the proposed prediction method with the corresponding learning algorithm was used to predict the exhaust gas temperature of some aeroengine, and the results were satisfactory.

**Key words:** aeroengine exhaust gas temperature; prediction; functional approximation; process neural network; learning algorithm

航空发动机是飞机的心脏, 其健康状态不仅会影响飞行安全, 还会影响航空公司的成本和收益<sup>[1-2]</sup>. 为在保证飞行安全的前提下降低发动机的

维护/维修成本, 世界各大航空公司自 20 世纪 70 年代起逐渐摒弃了定时维修和预防性维修等传统维修方式, 开始广泛采用视情维修方式<sup>[3-4]</sup>. 以视

收稿日期: 2008-05-16; 修订日期: 2008-09-25

基金项目: 国家自然科学基金(60572174; 50805032); 哈尔滨工业大学优秀青年教师培养计划(HITQJNS. 2007. 010).

作者简介: 丁刚(1976 - ), 男, 山东青岛人, 讲师, 博士, 主要从事人工智能理论与应用、航空发动机状态监控等研究.

情方式维修的航空发动机在时间控制上仅给定了发动机翻修的软时限,未给出发动机大修的硬时间,其目的是在这个软时限上下,以发动机的实际健康状态来判定其是否需要返厂修理以及进行何种修理,从而大大减少维修过剩或维修不足的可能,确保航空运输的安全性和综合运营成本的降低。在此期间,作为视情维修方式施行的基础,航空发动机状态监控技术也应运而生。

气动热力性能参数的监视及其趋势预测是航空发动机状态监控的主要内容。发动机排气温度(Exhaust gas temperature, EGT)是实际监控工作中最常用的气动热力性能参数<sup>[5-6]</sup>。航空发动机常年在高温、高压、高速等恶劣环境下工作,其性能必然会发生衰退,通过监视和预测 EGT 能够掌握航空发动机的健康状态及其性能衰退情况。但在飞机巡航期间 EGT 是一个随时间不断变化的过程,由于受许多复杂非线性时变因素的影响,目前尚无法以确定的数学模型来描述其变化规律。因此,利用航空公司积累的 EGT 历史数据构建时间序列模型 $\{EGT_m\} (m=1, 2, \dots)$ 对 EGT 进行预测就成了一种现实而有效的方法。现有时间序列预测方法(如回归分析、传统人工神经网络等)的理论基础是函数逼近的相关理论和方法<sup>[7-8]</sup>。利用这些方法进行时间序列预测在本质上就是根据时间序列 $\{EGT_m\}$ 的历史观测数据 $EGT_m, EGT_{m-1}, \dots$ 对 $EGT_{m+h} (h>0)$ 进行估计,这种用离散观测值处理连续时变信息的方法,由于忽略了输入对输出的时间累积效应必然会带来较大的误差。

为解决上述问题,可对 $EGT_m, EGT_{m-1}, \dots$ 进行拟合,产生一个时变函数 $EGT_m(t)$ ,则可以认为时间序列 $\{EGT_m\}$ 在 $m+1$ 时刻的取值 $EGT_{m+1}$ 与函数 $EGT_m(t)$ 之间存在某种泛函映射关系 $F: EGT_m(t) \rightarrow EGT_{m+1}$ ,即 $EGT_{m+1} = F(EGT_m(t))$ 。利用该泛函能够更好地反映时间序列 $\{EGT_m\}$ 中实际存在的时间累积效应对 EGT 变化的影响。显然,此时航空发动机排气温度预测问题就转换成了对泛函 $F(\cdot)$ 的逼近问题。已经证明:多层前馈过程神经网络能够以任意精度逼近任意连续泛函<sup>[9-10]</sup>。因此,可以建立基于过程神经网络的航空发动机排气温度预测模型来对发动机的排气温度进行预测。在实际应用的过程中,考虑到过程神经网络现有学习算法普遍存在学习收敛速度慢、易陷于局部极小点等缺点,本文拟开发一种基于正交基函数展开的 Levenberg-Marquardt

(LM)学习算法对基于过程神经网络的航空发动机排气温度预测模型进行训练,以期进一步提高该预测模型解决实际问题的适用性。最后将所提出的预测方法应用到某型航空发动机的排气温度预测中,对该预测方法及其基于正交基函数展开的 LM 学习算法的正确性和有效性进行实际应用验证。

## 1 基于过程神经网络的预测模型

根据上述分析,面向航空发动机排气温度预测的实际需求建立一种基于3层前向过程神经网络的时间序列预测模型。与实际问题相适应,该预测模型的输入层有1个单元;隐层由 $n$ 个过程神经元组成;输出层只有1个单元,其拓扑结构可定为 $1-n-1$ ,如图1所示。




图1 基于过程神经网络的时间序列预测模型

Fig 1 Time series prediction model based on process neural network

令 $x(t) = EGT_m(t)$ ,则基于过程神经网络的时间序列预测模型对 $EGT_{m+1}$ 的预测可由预测模型的输出 $y$ 表达为

$$y = \sum_{i=1}^n v_i f \left[ \int_0^T \omega_i(t) EGT_m(t) dt - \theta \right] - \theta \quad (1)$$

其中 $x(t) = EGT_m(t)$ 为图1所示预测模型的输入函数; $\omega_i(t)$ 为隐层第 $i$ 个过程神经元与输入层单元的连接权函数; $v_i$ 为隐层第 $i$ 个过程神经元与输出层单元的连接权值; $\theta$ 为隐层第 $i$ 个过程神经元的阈值; $\theta$ 为输出层单元的阈值; $f(\cdot)$ 为隐层过程神经元的激励函数,一般可取为 Sigmoid 函数; $g(\cdot)$ 为输出层单元的激励函数,在本文中 $g(\cdot)$ 取为线性函数 $g(x) = x$ 。

## 2 基于正交基函数展开的 LM 学习算法

根据航空发动机排气温度时间序列 $\{EGT_m\}$ 构建 $Q$ 个样本 $\{EGT_q(t); d_q\} (q=1, 2, \dots, Q)$ 组成样本集对基于过程神经网络的时间序列预测模型进行训练。其中, $d_q$ 为对应于样本 $EGT_q(t)$ 的期望预测值,设 $y_q$ 为相应的实际预测值,则预测模型的误差函数可定义为

$$E = \sum_q^Q \left[ d_q - \left( \sum_i^n v_i f \left( \int \omega(t) EGT_q(t) dt - \theta \right) - \theta \right) \right]^2 \quad (2)$$

对基于过程神经网络的时间序列预测模型进行训练,实质上就是根据式(2)利用某种算法(如BP算法)对 $\omega(t)$ , $\theta$ , $v_i$ , $\theta$ 等进行调整,以使误差函数 $E$ 最小.为减少调整连接权函数 $\omega(t)$ 的计算量,可考虑在预测模型的输入函数空间中引入一组合适的正交基函数来对其进行展开.

设 $\omega(t)$ 为 $L^2$ 空间上的连续函数,则由Weierstrass逼近定理知,对 $\forall \varepsilon > 0$ ,必存在多项式 $P(t)$ ,使 $|P(t) - \omega(t)| < \varepsilon$ ,即 $\omega(t)$ 可由 $L^2$ 空间上的多项式函数系 $P_k(t)$  ( $k = 1, 2, \dots, K$ )以任意精度逼近,即 $\omega(t)$ 可表示为: $\omega(t) =$

$\sum_k^K c_{ik} P_k(t)$ ,  $c_{ik} \in R$ . 设多项式函数系 $P_k(t)$ 在 $L^2$ 空间上是相互独立的,则可以通过Gram-Schmidt正交化步骤使之正交化,于是可得到 $L^2$ 空间上的一组标准正交基函数 $b_k(t)$ ,从而 $\omega(t)$ 可由该组标准正交基函数展开为: $\omega(t) = \sum_k^K \omega_k b_k(t)$ ,  $\omega_k \in R$ . 为简化式(2)中的时间累积聚合运算,预测模型的输入函数 $EGT_q(t)$ 也可由该组正交基函数展开为: $EGT_q(t) = \sum_k^K a_{qk} b_k(t)$ , 其中 $a_{qk} \in R$ .

$$J(W) = \begin{bmatrix} \frac{\partial e_1}{\partial \omega_1}, \dots, \frac{\partial e_1}{\partial \omega_n}, \dots, \frac{\partial e_1}{\partial \omega_K}, \frac{\partial e_1}{\partial \theta}, \dots, \frac{\partial e_1}{\partial \theta_n}, \frac{\partial e_1}{\partial v_1}, \dots, \frac{\partial e_1}{\partial v_n}, \frac{\partial e_1}{\partial \theta} \\ \frac{\partial e_2}{\partial \omega_1}, \dots, \frac{\partial e_2}{\partial \omega_n}, \dots, \frac{\partial e_2}{\partial \omega_K}, \frac{\partial e_2}{\partial \theta}, \dots, \frac{\partial e_2}{\partial \theta_n}, \frac{\partial e_2}{\partial v_1}, \dots, \frac{\partial e_2}{\partial v_n}, \frac{\partial e_2}{\partial \theta} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \frac{\partial e_Q}{\partial \omega_1}, \dots, \frac{\partial e_Q}{\partial \omega_n}, \dots, \frac{\partial e_Q}{\partial \omega_K}, \frac{\partial e_Q}{\partial \theta}, \dots, \frac{\partial e_Q}{\partial \theta_n}, \frac{\partial e_Q}{\partial v_1}, \dots, \frac{\partial e_Q}{\partial v_n}, \frac{\partial e_Q}{\partial \theta} \end{bmatrix} \quad (5)$$

记 $p_q = \sum_k^K \omega_k a_{qk} - \theta$ , 则Jacobi矩阵 $J(W)$ 中的元素可由下式加以计算

$$\begin{cases} \frac{\partial e_q}{\partial \omega_k} = - \sum_i^n v_i f'(p_q) a_{qk} \\ \frac{\partial e_q}{\partial \theta} = \sum_i^n v_i f'(p_q) \\ \frac{\partial e_q}{\partial v_i} = - f(p_q) \\ \frac{\partial e_q}{\partial \theta} = 1 \end{cases} \quad (6)$$

根据式(6)能够计算出每一次迭代中Jacobi

根据正交基函数的性质,有

$$\int b_k(t) b_l(t) dt = \begin{cases} 1, k = l \\ 0, k \neq l \end{cases}$$

因此,式(2)可简化为

$$E = \sum_q^Q \left[ d_q - \left( \sum_i^n v_i f \left( \sum_k^K \omega_k a_{qk} - \theta \right) - \theta \right) \right]^2 \quad (3)$$

为便于分析,令 $R^T = [e_1, e_2, \dots, e_Q]$ , 其中, $e_q = d_q - y_q$ ,  $R^T$ 表示 $R$ 的转置;令 $W^T = [w_1, w_2, \dots, w_L] = [\omega_1, \dots, \omega_n, \dots, \omega_K, \theta, \dots, \theta_n, v_1, \dots, v_n, \theta]$ , 其中, $L = n \times (K + 2) + 1$ ,  $W^T$ 表示 $W$ 的转置,显然, $W$ 是基于过程神经网络的时间序列预测模型的待调整参数的集合.

根据LM算法<sup>[11]</sup>,  $W$ 的迭代调整规则可定为

$$W(s+1) = W(s) - [J^T(W(s)) \cdot J(W(s)) + \mu(s) \cdot I]^{-1} \cdot J^T(W(s)) \cdot R(W(s)) \quad (4)$$

其中 $s$ 是迭代次数; $I$ 是单位矩阵; $\mu$ 是学习速率,学习开始时 $\mu$ 取小值,如果某一次迭代不能减少 $E$ 值,则令 $\mu = \mu \cdot \lambda$  ( $\lambda > 1$ ) 后再重复这一次迭代,直至 $E$ 值减少,如果在某一次迭代中产生了更小的 $E$ 值,则在下一次迭代中令 $\mu = \mu \cdot \lambda$ ,这意味着LM算法的每一次迭代都能减少 $E$ 值,LM算法的这一特点使其易于克服BP算法学习收敛速度慢、易陷于局部极小点等缺点; $J(W)_{Q \times L}$ 是关于 $W$ 的Jacobi矩阵,其表达式具体可写为如下形式

矩阵 $J(W)$ 的值,从而能够利用LM算法根据式(4)对基于过程神经网络的时间序列预测模型进行训练.

综上,基于正交基函数展开的LM学习算法的学习过程可完整描述如下:

Step1 确定预测模型的结构参数;

Step2 选取合适的正交基函数 $b_k(t)$  ( $k = 1, 2, \dots, K$ ) 将预测模型的输入函数 $EGT_q(t)$ 及相应的连接权函数 $\omega(t)$ 同时展开;

Step3 设定预测模型的学习误差精度 $\varepsilon$ ;学习迭代次数 $s$ ,最大学习迭代次数 $M$ ;初始化网络待训练参数 $\omega_k, v_i, \theta$ 和 $\theta$ ;

Step4 根据式(5),(6)计算 Jacobi 矩阵  $J(W)$ ;

Step5 根据式(4)计算式(3)中的误差函数  $E$ ,若  $E(s+1) > E(s)$ ,则  $\mu = \mu \cdot \lambda$ ,重复执行 Step5;若  $E(s+1) < E(s)$ ,则  $\mu = \mu \lambda, s = s + 1$ ,转 Step6;

Step6 若  $E < \varepsilon$ 或  $s > M$ 则转 Step7;否则转 Step4;

Step7 输出学习结果,结束.

### 3 应用实例

航空发动机热端部件常年在高温、高压、高速等恶劣环境下,为保证其正常工作并尽量延长其使用寿命,需要严格控制发动机燃烧室出口温度.然而,在实际工作中难以直接获得发动机燃烧室出口温度,常可通过监视涡轮排出气体的温度(即  $EGT$ ),并将其控制在红线值以内以实现发动机燃烧室出口温度的间接控制,从而能够保证发动机在未来的使用中不会超温<sup>[12]</sup>.在航空公司的日常监控中,经发动机生产厂家(Original engine manufacturer, OEM)开发的发动机健康状态监控软件(Engine health monitoring, EHM)提供的巡航状态下的  $\Delta EGT$  是衡量发动机是否超温的主要指标.因此,本文对  $EGT$  的预测实际上是对  $\Delta EGT$  的预测.

本文所用的数据来自中国国际航空公司的某型航空发动机,共采集到 75 个数据,数据采集间隔约为 30 个飞行循环,可以认为是等间距采样.利用采集所得的数据构建一个时间序列  $\{\Delta EGT_m\} (m = 1, 2, \dots, 75)$ ,将其中连续的 5 个数据  $(\Delta EGT_j, \Delta EGT_{j+1}, \dots, \Delta EGT_{j+4}) (j = 1, 2, \dots, 70)$  进行拟合,构成 1 个时变函数  $IF_j$  作为预测模型的输入,并以  $\Delta EGT_{j+5}$  作为与之对应的预测模型的期望输出,这样能够得到 1 个包含 70 个样本的训练样本集  $\{IF_j; \Delta EGT_{j+5}\}$ .用前 35 个样本对预测模型进行训练,用后 35 个样本对预测模型的泛化能力进行检验.

由样本的构建过程可知,预测模型的输入输出均各由 1 个神经元组成,由“试探法”确定其隐层神经元的个数为 30 个,则预测模型的拓扑结构最终可定为 1-30-1.将其输入函数及连接权函数用 Legendre 正交基函数展开.学习误差精度设定为  $1 \times 10^{-2}$ ,最大迭代次数为 20 000 次.利用 LM 学习算法对预测模型进行训练,预测模型经 349 次学习迭代后收敛,整个学习过程耗时 47.406 s.

用后 35 个样本对学习完成后的预测模型的泛化能力进行测试,测试结果如图 2 所示,平均相对误差为 4.62%,表明利用 LM 学习算法训练的基于过程神经网络的航空发动机排气温度预测模型对  $\Delta EGT$  的预测满足实际工程要求,能够达到对航空发动机健康状态进行监控的目的.




图2 基于 LM 学习算法的  $\Delta EGT$  预测结果

Fig. 2  $\Delta EGT$  prediction results using LM learning algorithm

为进行对比,在完全相同的条件下利用基于正交基函数展开的 BP 学习算法对预测模型进行训练,预测模型经 11074 次学习迭代后收敛,整个学习过程耗时 284.515 s.用后 35 个样本对学习完成后的预测模型的泛化能力进行测试,测试结果如图 3 所示,平均相对误差为 4.77%.




图3 基于 BP 学习算法的  $\Delta EGT$  预测结果

Fig. 3  $\Delta EGT$  prediction results using BP learning algorithm

通过上述对比可以看出,与 BP 学习算法相比,LM 学习算法的预测精度略有提高,但其学习收敛速度要快得多,这表明 LM 学习算法更适合用来解决实际问题.

### 4 结论

本文从泛函分析的角度出发,将航空发动机排气温度预测问题转换为一种泛函逼近问题,这

有利于在预测过程中充分考虑各种时变因素的时间累积效应对发动机排气温度变化规律的影响.在此基础上,利用过程神经网络能够以任意精度逼近任意连续泛函的特点,提出了一种基于过程神经网络的航空发动机排气温度预测方法.为提高该预测方法解决实际问题的适用性,为其开发了一种基于正交基函数展开的LM学习算法,并以某型航空发动机排气温度预测为例对所提出的预测方法及所开发的学习算法进行了实际应用验证,结果表明该方法能够快速、准确预测发动机的排气温度,从而能够较好地监控发动机的健康状态,进而能够为预防和排除发动机故障提供一定的决策支持.

## 参考文献:

- [1] Vingerhoeds R A, Janssens P, Netten B D, et al. Enhancing off-line and on-line condition monitoring and fault diagnosis [J]. *Control Engineering Practice*, 1995, 3(11): 1515-1528.
- [2] Ding G, Zhong S S. Aircraft engine lubricating oil monitoring by process neural network [J]. *Neural Network World*, 2006, 16(1): 15-24.
- [3] Jaw L C. Recent advancements in aircraft engine health management technologies and recommendations for the next step [R]. ASME GT2005-68625, 2005.
- [4] 左洪福,张海军,戎翔.基于比例风险模型的航空发动机视情维修决策[J].*航空动力学报*, 2006, 21(4): 716-721.  
ZUO Hongfu, ZHANG Haijun, RONG Xiang. Condition based aero-engine maintenance decision method using proportional hazards model [J]. *Journal of Aerospace Power*, 2006, 21(4): 716-721. (in Chinese)
- [5] 陈果.用结构自适应神经网络预测航空发动机性能趋势[J].*航空学报*, 2007, 28(3): 535-539.  
CHEN Guo. Forecasting engine performance trend by using structure self-adaptive neural network [J]. *Acta Aeronautica et Astronautica Sinica*, 2007, 28(3): 535-539. (in Chinese)
- [6] 钟诗胜,李洋.基于小波过程神经网络的飞机民用航空发动机状态监视[J].*航空学报*, 2007, 22(1): 68-71.  
ZHONG Shisheng, LI Yang. Condition monitoring of aeroengine based on wavelet process neural networks [J]. *Acta Aeronautica et Astronautica Sinica*, 2007, 22(1): 68-71. (in Chinese)
- [7] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators [J]. *Neural Networks*, 1989, 2(5): 359-366.
- [8] Zhang G P, Qi M. Neural network forecasting for seasonal and trend time series [J]. *European Journal of Operational Research*, 2005, 160(2): 501-514.
- [9] 何新贵,梁久祯.过程神经网络的若干理论问题[J].*中国工程科学*, 2000, 2(12): 40-44.  
HE Xingui, LIANG Jiuzhen. Some theoretical issues on process neural networks [J]. *Engineering Sciences*, 2000, 2(12): 40-44. (in Chinese)
- [10] Ding G, Zhong S S. Approximation capability analysis of parallel process neural network with application to aircraft engine health condition monitoring [J]. *Lecture Notes in Computer Science*, 2007, 4493(3): 66-72.
- [11] Hagan M T, Menhaj M. Training feedforward networks with the Marquardt algorithm [J]. *IEEE Transactions on Neural Networks*, 1994, 5(6): 989-993.
- [12] 钟诗胜,栾圣罡,丁刚.基于过程神经网络与气动热力参数的民用航空发动机状态监视[J].*南京理工大学学报(自然科学版)*, 2006, 30(5): 533-536.  
ZHONG Shisheng, LUAN Shenggang, DING Gang. Aeroengine condition monitoring based on process neural networks and aerothermo-parameters [J]. *Journal of Nanjing University of Science and Technology (Natural Science)*, 2006, 30(5): 533-536. (in Chinese)