

基于 NN-ELM 的航空发动机燃油系统 执行机构故障诊断

姜 洁, 李秋红, 张高钱, 李业波
(南京航空航天大学 能源与动力学院
江苏省航空动力系统重点实验室, 南京 210016)

摘 要: 提出了一种航空发动机执行机构及其传感器单一故障诊断及定位方法. 首先通过执行机构模型判断是否发生故障, 然后运用发动机逆模型对故障进行定位. 基于离线训练 BP(back propagation)神经网络建立执行机构模型, 根据某半物理仿真试验台的测试数据训练网络参数. 提出离线训练和在线训练相结合的极端学习机(ELM)算法建立发动机逆模型, 使网络在初始时刻就具有诊断能力, 工作过程中具有适应能力, 且在线训练过程采用阈值判别法筛选训练样本, 减小了在线训练时间, 提高了逆模型的实时性. 以某型发动机燃油系统执行机构为例的设计和仿真结果表明: 该诊断系统能够准确地对发动机在稳态和动态工况以及蜕化状态下的执行机构及其传感器单一故障进行准确诊断和定位, 具有很好的实时性.

关 键 词: 航空发动机; 执行机构; 故障诊断; 神经网络; 极端学习机
中图分类号: V233.7 **文献标志码:** A

Fault diagnosis for actuators of aero-engine fuel system based on NN-ELM

JIANG Jie, LI Qiu-hong, ZHANG Gao-qian, LI Ye-bo
(Jiangsu Province Key Laboratory of Aerospace Power System,
College of Energy and Power Engineering,
Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: A single fault diagnosis and location method of aero-engine actuator and its sensor was proposed. Fault of actuator was diagnosed according to the actuator model and located according to the inverse engine model. The actuator model was built based on offline training BP (back propagation) neural network(NN). The network parameters were trained according to the test data of a semi-physical simulation test bed. The inverse engine model based on offline and online extreme learning machine (ELM) had original diagnosis ability and adaptability during operation. The training samples were selected using the threshold discrimination, which can reduce the online training time and improve the real-time property of inverse model during the online training process. Design and simulation results of a certain engine fuel system actuator show that, the proposed system can diagnose and locate the single faults of engine actuator or its sensor accurately in steady state, dynamic state and degradation state. The real-time property can be satisfied.

Key words: aero-engine; actuator; fault diagnosis; neural network(NN); extreme learning machine

现代航空发动机控制系统是一个多回路、多变量、非线性的复杂系统. 其执行机构及传感器在高温、高压、高振动的环境下工作,是故障多发元件之一^[1-3]. 为提高发动机的可靠性,对执行机构及其传感器故障进行及时检测、辨识和定位显得尤为重要. 目前,国内外在航空发动机传感器故障诊断技术上的研究工作较多^[4-6],其中大多数算法基于人工智能技术. 如:文献[4]研究了基于自适应模型的传感器故障诊断方法;文献[5]提出了基于人工神经网络的涡喷发动机在线传感器故障诊断方案;文献[6]基于自联想神经网络建立了故障诊断与信号重构系统. 对于以航空发动机执行机构为对象的故障诊断,国内外的披露较少,但在其他领域研究较为广泛. 文献[7]针对离散形式的非线性系统研究了执行机构偏置故障和漂移故障的诊断问题;文献[8]采用增广卡尔曼滤波器组对潜水艇执行机构进行状态参数估计,并对其进行了故障诊断;文献[9]提出了针对闭环控制的电动机转向执行机构,采用动态自适应阈值的方法对其进行鲁棒故障诊断. 针对航空发动机这一类特定的对象,本文研究了执行机构或其传感器发生单一故障时的故障的诊断和区分定位问题,一定程度上解决了误判或错判问题. 以燃油系统执行机构为例,提出了基于离线训练执行机构模型和在线训练发动机逆模型的故障诊断以及定位方法并

进行了仿真验证.

1 执行机构故障诊断及定位系统设计

航空发动机燃油系统执行机构故障诊断和定位系统原理如图 1 所示,图中 AD 是指模拟-数字信号转换,DA 是指数字-模拟信号转换. 该系统以执行机构模型输出和传感器测量值之间的偏差来判断执行机构和执行机构传感器是否发生故障,以发动机逆模型输出和传感器测量输出之间的偏差故障进行定位,实现执行机构或其传感器单一故障的诊断和定位,具体步骤如下:

步骤 1 基于离线训练 BP 神经网络,建立执行机构模型,并将其用于执行机构输出量的在线预测,记为 W_{f1} ;

步骤 2 基于离线训练和在线训练相结合的极端学习机算法,建立航空发动机逆模型,预测发动机输入的燃油流量值 W_{f2} ;

步骤 3 将执行机构模型预测燃油流量 W_{f1} 与传感器(LVDT)测得的燃油流量 W_{f0} 进行比较,偏差记为 e_1 ;将航空发动机逆映射预测模型预测燃油流量 W_{f2} 与 W_{f0} 进行比较,偏差记为 e_2 ;

步骤 4 故障诊断. 根据执行机构和执行机构传感器的故障阈值 D_1, D_2 进行故障判别. ①当 $|e_1| < D_1$ 时,执行机构模型预测输出与传感器测




图 1 执行机构故障诊断系统

Fig. 1 Failure diagnosis system of actuator

量值输出之间偏差小于故障阈值,即判断执行机构和执行机构传感器无故障,转步骤 1;②当 $|e_1| \geq D_1$ 时,执行机构模型的预测输出和传感器测量值之间偏差大于故障阈值,则执行机构或其传感器发生了故障,转步骤 5;

步骤 5 故障定位. 当 $|e_2| < D_2$ 时,发动机的逆模型预测输出与传感器测量值之间偏差小于故障阈值,传感器信号真实的反映了燃油流量输出,报告为执行机构故障;若 $|e_2| \geq D_2$,发动机的逆模型预测输出与传感器测量值之间偏差大于故障阈值,报告为执行机构传感器故障.

为实现该诊断及定位系统,本文将分别建立执行机构的预测模型和发动机逆映射预测模型.

2 基于 BP 神经网络的执行机构模型

在控制系统设计过程中,执行机构模型通常用 1 阶惯性环节来模拟.其建模误差可以通过控制系统的鲁棒性来补偿,闭环控制系统性能基本上不受其影响.但对于故障诊断系统来说,其精度却远远不够,且执行机构中也会存在非线性因素,要建立精确的解析模型比较困难. BP 神经网络拥有高度的非线性映射能力,为此本文采用 3 层 BP 神经网络^[10-12]来模拟图 1 中虚线框内执行机构小闭环的稳态和动态性能.

由于执行机构参数随飞行状态变化较小,所以本文采用离线训练的方法建立执行机构模型.模型结构如图 2 所示,图中 Z 表示延时环节.以当前时刻、前一时刻、前两时刻的燃油指令 $W_{fr}(k), W_{fr}(k-1), W_{fr}(k-2)$ 以及前一时刻、前两时刻的燃油流量预测信号 $W_{fi}(k-1), W_{fi}(k-2)$ 作为 BP 神经网络输入,对当前时刻的燃油流量测量信号进行预测. 本文选取 13 个隐含层神经元.




图 2 执行机构模型结构图
Fig. 2 Sketch of actuator model

隐含层激励函数 $f_1(x)$ 、输出层激励函数 $f_2(x)$ 分别设为

$$f_1(x) = \frac{2}{1 + \sqrt{e^{-2x}}} - 1 \tag{1}$$

$$f_2(x) = x \tag{2}$$

根据某半物理仿真试验台的测试数据进行动态网络的训练,训练误差和测试误差如图 3 所示,横坐标分别为试验训练、测试数据个数.从图 3 中可以看出,在包线范围内建立的神经网络模型能够对主燃油流量进行准确的预测,输出误差控制在 0.7% 以内.




图 3 执行机构模型输出误差
Fig. 3 Error of actuator model output

3 基于 ELM 的发动机逆模型

逆模型与常规意义下的发动机模型不同,目的是映射执行机构的输出燃油流量.因此,与以燃油流量、尾喷口面积等作为输入量,以各截面的温度、压力以及转子转速等作为输出的常规模型相反,本文建立的逆模型是以燃油流量为输出量,而各可测参数作为输入.由于发动机具有参数变化范围大,强非线性的特征,采用离线训练方法建立的网络难以覆盖发动机全部工作状态,对发动机

的性能蜕化不具有适应能力. 因此本文提出离线训练和在线训练相结合的极端学习算法来建立发动机逆模型, 通过离线训练使网络获得初始诊断能力, 通过在线训练使得网络获得对发动机工作状态和蜕化程度的适应能力.

极端学习机 (extreme learning machine, ELM) 算法^[13]是由 Huang 等提出的一种新颖的单隐层前馈神经网络. ELM 用求解线性方程组替代传统的神经网络参数优化的迭代过程, 解得具有最小范数的最小二乘解作为输出层网络权值, 其网络训练过程可一次完成无需迭代. 与传统的网络训练算法相比, ELM 的训练速度获得了显著提升, 可以实现实时的在线训练.

在线贯序极端学习机 (online sequential extreme learning machine, OS-ELM)^[14]算法通过迭代的方式计算出当前的网络权值, 能够实现数据的在线训练. 通过迭代将所有的样本都用来训练, 虽然提高了预测模型的精度, 但会影响系统的实时性. 因此, 本文采用阈值判别法对训练数据进行筛选^[15-16], 只有在数据测试误差超过阈值时, 才将数据作为训练样本, 来更新预测模型.

给定一个训练数据集 $S = \{\mathbf{x}_i, \mathbf{t}_i\}_{i=1}^N$, 其中 $\mathbf{x}_i = [x_{i1}, \dots, x_{in}]$ 为输入量, $\mathbf{t}_i = [t_{i1}, \dots, t_{im}]^T$ 为输出量, 并设激励函数为 $g(x)$, ELM 的回归数学模型为

$$\sum_{i=1}^{\tilde{N}} \beta_i g(\mathbf{w}_i \mathbf{x}_j + b_i) = t_j \quad j = 1, \dots, N \quad (3)$$

其中 $\mathbf{w}_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{in}]^T$ 是连接第 i 个隐含层神经元与输入层的权值, b_i 是第 i 个隐含层神经元的偏差, $\beta_i = [\beta_{i1}, \dots, \beta_{im}]^T$ 是连接第 i 个隐含层神经元和输出层的权值, $\tilde{N}$ 为隐含层节点个数.

将式(3)中的方程写为矩阵形式

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (4)$$

$$\left\{ \begin{aligned} & \mathbf{H}(\mathbf{w}_1, \dots, \mathbf{w}_{\tilde{N}}; b_1, \dots, b_{\tilde{N}}; \mathbf{x}_1, \dots, \mathbf{x}_N) = \\ & \begin{bmatrix} g(\mathbf{w}_1 \mathbf{x}_1 + b_1) & \cdots & g(\mathbf{w}_{\tilde{N}} \mathbf{x}_1 + b_{\tilde{N}}) \\ \vdots & \ddots & \vdots \\ g(\mathbf{w}_1 \mathbf{x}_N + b_1) & \cdots & g(\mathbf{w}_{\tilde{N}} \mathbf{x}_N + b_{\tilde{N}}) \end{bmatrix} \\ & \boldsymbol{\beta} = \begin{bmatrix} \boldsymbol{\beta}_1^T \\ \vdots \\ \boldsymbol{\beta}_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m} \\ & \mathbf{T} = \begin{bmatrix} \mathbf{t}_1^T \\ \vdots \\ \mathbf{t}_N^T \end{bmatrix}_{N \times m} \end{aligned} \right.$$

式中 $\mathbf{H}$ 为输出层矩阵, $\mathbf{H} = [\mathbf{h}_1 \quad \mathbf{h}_2 \quad \cdots \quad \mathbf{h}_{\tilde{N}}]^T$.

为寻求最优的网络权值 $\mathbf{w}, \boldsymbol{\beta}$, 使得网络输出值与对应的实际值误差最小, 寻优问题的最优解可以表示为

$$\boldsymbol{\beta}^* = (\mathbf{H}^T \mathbf{H} + \lambda \mathbf{I})^{-1} \mathbf{H}^T \mathbf{T} = \mathbf{L} \mathbf{H}^T \mathbf{T} \quad (5)$$

式中 $\mathbf{L} = (\mathbf{H}^T \mathbf{H} + \lambda \mathbf{I})^{-1}$.

采用在线训练方法通过递推来更新模型参数, 第 $k+1$ 组输入数据经阈值判别需参与训练过程时, 输出权值矩阵 $\boldsymbol{\beta}_{k+1}$ 可由下式求得:

$$\mathbf{L}_{k+1}^{-1} = \mathbf{L}_k^{-1} - \mathbf{L}_k^{-1} \mathbf{h}_{k+1} (\mathbf{I} + \mathbf{h}_{k+1}^T \mathbf{L}_k^{-1} \mathbf{h}_{k+1})^{-1} \mathbf{h}_{k+1}^T \mathbf{L}_k^{-1} \quad (6)$$

$$\boldsymbol{\beta}_{k+1} = \boldsymbol{\beta}_k + \mathbf{L}_{k+1}^{-1} \mathbf{h}_{k+1} (\mathbf{t}_{k+1}^T - \mathbf{h}_{k+1}^T \boldsymbol{\beta}_k) \quad (7)$$

令 $\mathbf{M}_{k+1} = \mathbf{L}_{k+1}^{-1}$ 并代入式(7)得

$$\left\{ \begin{aligned} \mathbf{M}_{k+1} &= \mathbf{M}_k - \mathbf{M}_k \mathbf{h}_{k+1} (\mathbf{I} + \mathbf{h}_{k+1}^T \mathbf{M}_k \mathbf{h}_{k+1})^{-1} \mathbf{h}_{k+1}^T \mathbf{M}_k \\ \boldsymbol{\beta}_{k+1} &= \boldsymbol{\beta}_k + \mathbf{M}_{k+1} \mathbf{h}_{k+1} (\mathbf{t}_{k+1}^T - \mathbf{h}_{k+1}^T \boldsymbol{\beta}_k) \end{aligned} \right. \quad (8)$$

由式(8)递推求解输出权值矩阵 $\boldsymbol{\beta}$ 的过程中, 通过阈值对参与网络训练的数据进行选择, 提高算法在线使用的实时性.

基于 ELM 的发动机逆映射模型以风扇转速 (PNF)、压气机转速 (PNC)、低压涡轮出口总压 (p_{46})、压气机出口总压 (p_3)、低压涡轮出口总温 (T_{46}) 5 个传感器作为输入, 主燃油流量作为输出. 通过极端学习机逆映射得到执行机构燃油流量的估计值 W_{f2} , 为了充分利用传感器信息, 获得更高的动态预测精度, 将传感器前 q 步的数据也作为 ELM 预测模块的输入. ELM 逆模型估计燃油流量的表达式描述如下:

$$W_{f2}(k) = f(\mathbf{y}_{(k-q)}^i, \dots, \mathbf{y}_{(k)}^i) \quad i = 1, \dots, 5 \quad (9)$$

其中 $\mathbf{y}^i$ 为传感器 PNF, PNC, p_{46} , p_3 , T_{46} 信号产生的输入向量. 逆模型中, 隐含层节点个数为 30, 隐含层激励函数为 sigmoid, 更新阈值为 0.15%, 输入数据前选步数 $q=2$.

由于常规 ELM 初始阶段权值、偏置值为随机产生, 导致初始阶段逆映射得到执行机构燃油流量预测不准确. 为了提高逆模型的初始精度, 在高度为 0~5 km 的飞行包线范围内, 油门杆角度 (PLA, 量符号记为 A_{pl}) 为 $30^\circ \sim 70^\circ$ 内, 通过遍历采集包线内的稳态工作点数据, 对网络参数进行初始化训练, 其训练误差如图 4 所示, 横坐标为训练数据个数. 从图 4 中可以看出, 经过训练的 ELM 初始参数, 能够对稳定工作状态下的主燃油流量进行准确地预测, 误差控制在 0.7% 以内. 以此组参数作为在线训练的起始值, 可以避免完全

在线训练算法在初始化时的随机性引起的预测偏差过大问题,有效结合了离线训练和在线训练方法的优点,使得网络在初始阶段就具有预测能力,并且能够随发动机工作状态变化更新网络参数,具有自适应能力.




图 4 离线逆模型输出误差
Fig. 4 Error of offline inverse model output

为仿真验证发动机逆映射模型预测的精度,以某型涡扇发动机部件级模型为对象,仿真过程中,将图 1 的执行机构小闭环的电液伺服阀视为 2 阶环节,计量活门视为积分环节,校正装置为比例积分环节,建立 4 阶的执行机构数学模型,用于在仿真过程中代替真实的执行机构,其输出记为 W_f . 设其传递函数为

$$\frac{W_f(s)}{W_{fr}(s)} = \frac{(\tau s + 1)}{(T_1 s + 1)(T_2 s + 1)(T_3 s + 1)(T_4 s + 1)} \tag{10}$$

式中 τ, T_1, T_2, T_3, T_4 为模型的待定参数.

以某半物理仿真试验台的测试数据进行参数辨识,获得燃油流量执行机构小闭环数学模型

$$\frac{W_f(s)}{W_{fr}(s)} = \frac{(0.0378s + 1)}{(0.012s + 1)(0.014s + 1)(0.017s + 1)(0.025s + 1)} \tag{11}$$

以式(11)中的数学模型作为仿真中的执行机构,以高度 $H=0\text{ km}$,马赫数 $Ma=0$ 为例,在 $t=6\text{ s}$ 时,将油门杆角度从 30° 增加至 70° ,可得发动机逆映射模型预测精度如图 5 所示. 从图 5 中可以看出,建立的逆模型能够对主燃油流量进行准确的预测,输出误差控制在 1% 以内.

为了进一步说明逆模型的精度,在表 1 中列出发动机在加速、减速、飞机爬升、飞机平飞加速




图 5 在线逆模型输出误差
Fig. 5 Error of online inverse model output

工况下预测偏差的最大值. 表 1 中的测试状态和结果为:① $H=1\text{ km}$, $Ma=0.2$, 油门杆角度从 30° 至 70° 的加速过程,逆模型的最大预测误差为 0.91% ;② $H=1\text{ km}$, $Ma=0.5$, 油门杆角度从 70° 至 30° 的减速过程,逆模型的最大预测误差为 0.92% ;③在 $Ma=0.5$, 油门杆角度为 60° , 高度从地面升高到 5 km 的动态过程逆模型的最大预测误差为 0.48% ;④ $H=3\text{ km}$, 油门杆角度为 50° , 马赫数从 0 增至 1.3 的动态过程,逆模型的最大预测误差为 0.45% ;可见在线逆模型的预测精度满足故障诊断的需求.

表 1 在线逆模型预测误差			
Table 1 Predicting error of online inverse model			
H/km	Ma	$A_{pl}/(^{\circ})$	最大误差/ $\%$
1	0.2	30~70	0.9152
1	0.5	70~30	0.9246
0~5	0.5	60	0.4885
3	0~1.3	50	0.4562

4 仿真实验

为验证该系统对发动机执行机构进行故障诊断和定位的有效性,以某型涡扇发动机部件级模型为对象,以式(11)中的数学模型作为仿真中的执行机构,开展仿真验证研究. 仿真过程中模拟发动机的真实工作环境,在各传感器输出中添加幅值为 0.2% 的测量噪声. 参考文献[17]并结合执行机构模型和发动机逆模型的预测精度,设置 D_1 偏置故障阈值为 2.2% ,漂移故障阈值为 1.0% ; D_2 偏置故障阈值为 2.2% ,漂移故障阈值为 1.0% . 由 $e_n = \left| \frac{V_t - V_p}{V_t} \right|$, $n=1,2$, 得到偏差 e_1, e_2

与阈值比较,判断并区分故障, V_t 表示目标值, V_p 表示预测值。

在 Core(TM)2 Duo CPU(central processing unit)主频为 2.93 GHz,内存为 2 GB,Microsoft Visual C++ 6.0 的环境下,对基于离线训练和在线训练相结合的极端学习机算法的发动机逆模型模块运行时间进行测试,仿真结果表明其单次运行时间远小于 1 ms,完全满足实时性的要求。

以高度 $H=0\text{ km}$,马赫数 $Ma=0$,油门杆角度 A_{pl} 在 $30^\circ\sim70^\circ$ 之间变化为例,模拟执行机构偏置故障和执行机构传感器漂移故障,仿真结果如图 6~图 9 所示。图中,均在 $t=6\text{ s}$ 时,将油门杆角度从 30° 增加至 70° ,在 $t=26\text{ s}$ 时,将油门杆角度从 70° 减小至 30° 。

图 6 在 $t=16\text{ s}$ 时添加执行机构 3% 偏置故障;图 7 在 $16\text{ s}\leq t<19\text{ s}$ 处执行机构传感器每 20 ms 添加 0.01% 的随时间漂移故障;模拟稳态情况下的故障诊断效果。从图 6、图 7 可以看出,16 s 之前执行机构模型 W_{f1} 输出和发动机逆模型输出 W_{f2} ,与传感器输出 W_{f0} 始终一致,验证了本文执





图 6 $H=0\text{ km}$, $Ma=0$ 稳态工况下执行机构偏置故障诊断效果

Fig. 6 Fault diagnosis result of actuator failure at $H=0\text{ km}$, $Ma=0$ steady state






图 7 $H=0\text{ km}$, $Ma=0$ 稳态工况下执行机构传感器漂移故障诊断效果

Fig. 7 Fault diagnosis result of actuator sensor drift at $H=0\text{ km}$, $Ma=0$ steady state

行机构模型和发动机逆模型的精度满足要求,根据诊断逻辑可以判断此时执行机构及其传感器无故障。16 s 后,图 6 中, W_{f1} 偏离 W_{f0} 说明有故障出现,而 W_{f2} 仍然跟随 W_{f0} , 因此判断为执行机构故障。而图 7 中, W_{f1} 和 W_{f2} 都偏离 W_{f0} , 因此判断为执行机构的传感器故障。

图 8、图 9 中,在 $t=8\text{ s}$ 时发动机还处于加速阶段工况时模拟相同的执行机构偏置和执行机构传感器漂移故障。从图中可以看出,8 s 之前模型输出始终跟随传感器测量值,因此执行机构及其






图 8 $H=0\text{ km}, Ma=0$ 动态工况下执行机构偏置故障诊断效果

Fig.8 Fault diagnosis result of actuator failure at $H=0\text{ km}, Ma=0$ dynamic state




图 9 $H=0\text{ km}, Ma=0$ 动态工况下执行机构传感器漂移故障诊断效果

Fig.9 Fault diagnosis result of actuator sensor drift at $H=0\text{ km}, Ma=0$ dynamic state

不同使用程度的发动机上进行故障诊断的测试. 限于篇幅,这里仅给出在 $H=2\text{ km}$, 马赫数 $Ma=0.5$ 条件下的仿真结果. 仿真过程中模拟发动机发生性能蜕化情况为:风扇流通能力蜕化 1%,压气机流通能力蜕化 2%,高压涡轮效率蜕化 3%,低压涡轮效率蜕化 2%,油门杆角度 A_{pl} 在 $30^\circ\sim 70^\circ$ 之间变化,模拟执行机构漂移故障和执行机构传感器偏置故障,仿真结果如图 10~图 13 所示. 图中,均在 $t=6\text{ s}$ 时,将油门杆角度从 30° 增加至 70° ,在 $t=26\text{ s}$ 时,将油门杆角度从 70° 减小至 30° . 图 10 在 $16\text{ s}<t<19\text{ s}$ 处每 20 ms 内施加 0.01% 的随时间漂移的执行机构故障;图 11 在 $t=16\text{ s}$ 时添加执行机构传感器 3%偏置故障;模拟稳态情况下的故障诊断效果;图 12、图 13 中,在 $t=8\text{ s}$ 时模拟相同的漂移和偏置故障. 从仿真图中可以看出,该系统仍能对故障准确判断和定位.




图 10 $H=2\text{ km}, Ma=0.5$ 稳态工况下执行机构故障漂移诊断效果

Fig.10 Fault diagnosis result of actuator drift at $H=2\text{ km}, Ma=0.5$ steady state

该系统在包线内其他工作点的仿真也能得到相同的结论. 因此无论发动机处于稳态工况、动态工况还是发动机蜕化状态,本文的诊断系统都能够对执行机构及其传感器故障进行准确诊断和定位.

传感器无故障. 8s 后,图 8 中,执行机构模型输出偏离传感器测量值,说明有故障出现,而发动机逆模型输出仍然跟随传感器测量值,因此判断为执行机构故障;而图 9 中,模型输出都偏离传感器值,判断为执行机构传感器故障.

为进一步验证该诊断系统的自适应能力,在




图 11 $H=2\text{ km}, Ma=0.5$ 稳态工况下执行机构传感器偏置故障诊断效果

Fig. 11 Fault diagnosis result of actuator sensor failure at $H=2\text{ km}, Ma=0.5$ steady state




图 12 $H=2\text{ km}, Ma=0.5$ 动态工况下执行机构漂移故障诊断效果

Fig. 12 Fault diagnosis result of actuator drift at $H=2\text{ km}, Ma=0.5$ dynamic state




图 13 $H=2\text{ km}, Ma=0.5$ 动态工况下执行机构传感器偏置故障诊断效果

Fig. 13 Fault diagnosis result of actuator sensor failure at $H=2\text{ km}, Ma=0.5$ dynamic state

5 结 论

- 1) 基于执行机构模型和发动机逆模型的故障诊断方法可以实现对传感器及其执行机构单一故障的有效区分和定位。
- 2) 基于离线训练和在线训练相结合的 ELM

算法建立的发动机逆模型,有效利用了两者优先,使得逆模型在初始时刻即具有诊断能力,在动态过程中及发动机蜕化状态下,诊断系统具有适应能力。

3) 以神经网络建立执行机构模型可以满足故障诊断需求,以离线训练和在线训练相结合方

法建立的发动机逆模型具有良好的实时性,满足故障诊断需求。

参考文献:

[1] Garg S. Controls and health management technologies for intelligent aerospace propulsion systems[R]. AIAA-2004-0949,2004.

[2] Chen R H, Speyer J L. Sensor and actuator fault reconstruction[J]. Journal of Guidance, Control and Dynamics, 2004,27(2):186-196.

[3] Garg S, Schadow K, Horn W, et al. Sensor and actuator needs for more intelligent gas turbine engines[R]. NASA/TM-2010-216746,2010.

[4] Kobayashi T, Simon D L. A hybrid neural network-genetic algorithm technique for aircraft engine performance diagnostics[R]. AIAA-2001-3763,2001.

[5] Dewallef P, Leonard O. On-line validation of measurements on jet engines using automatic learning methods[R]. International Society for Air Breathing Engines, ISABE Paper 2001-1031,2001.

[6] HUANG Xianghua. Sensor fault diagnosis and reconstruction of engine control system based on auto-associative neural network[J]. Chinese Journal of Aeronautics,2004,17(1):23-27.

[7] Zhou D H, Frank P M. Actuator fault diagnosis of a class of nonlinear systems in closed-loops: a case study[C]//United Kingdom Automatic Control Council International Conference. Duisburg, Germany: Institution of Engineering and Technology,1996:311-316.

[8] Alessandri A, Caccia M, Veruggio G. Fault detection of actuator faults in unmanned underwater vehicles[J]. Control Engineering Practice,1999,7(3):357-368.

[9] Ho L M. Application of adaptive thresholds in robust fault detection of an electro-mechanical single-wheel steering actuator[J]. Fault Detection, Supervision and Safety of Technical Processes,2012,8(1):259-264.

[10] Napolitano M R, Silvestri G. Sensor validation using hardware-based on-line learning neural networks[J]. IEEE Transactions on Aerospace and Electronic Systems,1998,34(2):56-66.

[11] 尹俊,郭迎清. 神经网络和卡尔曼滤波器融合的航空发动

机传感器故障诊断[J]. 计算机测量与控制,2011,19(8):1936-1942.

YIN Jun, GUO Yingqing. Neural network and Kalman filter based fusion fault diagnosis for aero-engine sensor[J]. Computer Measurement and Control, 2011, 19(8): 1936-1942. (in Chinese)

[12] 刘艳春,杨德辉,刘艳丽,等. 基于神经网络的某型飞机发动机故障诊断研究[J]. 电子设计工程,2012,20(11):89-92.

LIU Yanchun, YANG Dehui, LIU Yanli, et al. Failure diagnose research for the plane engine of basic neural network[J]. Electronic Design Engineering,2012,20(11):89-92. (in Chinese)

[13] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine; theory and applications[J]. Neurocomputing, 2006, 70(1/2/3):489-501.

[14] 张弦,王宏力. 基于贯序正则极端学习机的时间序列预测及其应用[J]. 航空学报,2011,32(7):1302-1308.

ZHANG Xian, WANG Hongli. Time series prediction based on sequential regularized extreme learning machine and its application[J]. Acta Aeronautica et Astronautica Sinica,2011,32(7):1302-1308. (in Chinese)

[15] Huang G B, Liang N Y, Rong H J, et al. Online sequential extreme learning machine[R]. Calgary, Canada: the International Association of Science and Technology for Development International Conference on Computational Intelligence,2005.

[16] 李业波,李秋红,王健康,等. 基于 ImOS-ELM 的航空发动机传感器故障自适应诊断技术[J]. 航空学报,2013,34(10):2316-2324.

LI Yebo, LI Qihong, WANG Jiankang, et al. Sensor fault adaptive diagnosis of aero-engine based on ImOS-ELM[J]. Acta Aeronautica et Astronautica Sinica, 2013, 34(10): 2316-2324. (in Chinese)

[17] 程月华,姜斌,杨明凯,等. 应用自组织模糊神经网络估计卫星姿态系统执行机构故障[J]. 应用科技学报,2010,28(1):72-76.

CHENG Yuehua, JIANG Bin, YANG Mingkai, et al. Self-organizing fuzzy neural network-based actuator fault estimation for satellite attitude systems[J]. Journal of Applied Sciences,2010,28(1):72-76. (in Chinese)

(编辑:王碧珺)