

动态神经网络在液体火箭发动机故障检测与分离中的应用

国防科技大学 黄敏超* 张育林 陈启智

【摘要】 应用动态神经网络在线辨识方法, 提出了一种液体火箭发动机故障实时检测与分离基本系统。检测逻辑通过度量包含发动机故障信息的辨识残差信号实现火箭发动机故障检测, 故障分离通过分析辨识误差相关函数的不同空间特征来实现。仿真研究表明动态神经网络可成功地应用于泵压式液体火箭发动机故障检测与分离。

主题词: 火箭发动机 故障检测 神经网络 分离

分类号: V 434

1 引言

Iseman 强调了估计方法在故障检测应用中的重要性^[1]。文献 [2] 考虑用故障参数估计实现推进系统故障检测, 文中基于发动机数学模型得到一些检测结果, 但数学模型的不精确性影响了检测性能。Narendra 等人^[3]提出了用静态反推神经网络实现系统的动态辨识过程, 但反推神经网络的学习算法存在局部极小问题, 在线学习收敛速度比较慢, 不易满足工程上实时性要求。动态神经网络直接用李雅诺夫方法推出神经网络的权值修改公式, 得到稳定的学习规则, 并且学习收敛到全局最优, 因此本文用动态神经网络来辨识液体火箭发动机的动态响应过程, 估计发动机传感器测量信号。基于发动机测量信号与动态神经网络辨识信号得到的残差信号, 实现动态神经网络的故障检测策略。

2 系统描述

一种用于液体火箭发动机故障检测与分离的动态神经网络系统见图 1。 u 和 x 分别是液

体火箭发动机的输入和输出向量。 u 和 x 输入动态神经网络得到的辨识向量 $\hat{x}$, 辨识向量 $\hat{x}$ 与发动机输出向量 x 比较得到辨识误差向量 e 。神经网络辨识误差向量的范数 $\|e\|_2$ 输入检测逻辑, 得到发动机故障检测结果, 同时接通开关 K , 让辨识误差向量的相关矩阵 $E\{ee^T\}$ 输入分离逻辑




图 1 故障检测与分离原理图

辑, 分离出液体火箭发动机的故障类型。故障设置模块根据预先设置, 通过外部控制向液体火箭发动机传递故障信息, 得到发动机的故障行为。

假定液体火箭发动机飞行过程的某一时刻, 涡轮泵发生故障, 这将引起泵的出口压力、燃烧室压力以及泵的转数等性能参数发生明显变化。即液体火箭发动机系统发生故障之后很快将引起状态变量测量值与动态神经网络辨识值不相匹配, 如果引起的动态神经网络估计误差变大超过一给定阈值 (考虑到误报警), 可以认为液体火箭发动机出现故障, 因此动态神经网络在线辨识方法是液体火箭发动机故障检测的一种非常有效的方法。

3 动态神经网络辨识器

假定非线性发动机动态系统可由以下方程描述

$$\dot{x} = f(x) + g(x)u' \quad (1)$$

式中, $x = [x_1, x_2, \dots, x_n]^T$ 是状态变量, $f(x)$ 是 x 的 $n \times 1$ 维转移函数, $u' = [u_1, u_2, \dots, u_m]^T$ 是输入向量或控制变量, $g(x)$ 是一个 $n \times m$ 矩阵, $x(0) = x_0$ 是初始状态。在分析方程 (1) 的辨识问题之前, 假定对于任意有限初始状态 x_0 和控制变量 u' , 方程 (1) 的解存在且唯一。

图 2 给出了一种动态神经网络的方块示意图, 神经网络的每一个神经元包含有动态元素, 并且神经元之间是互联的。动态神经网络可由微分方程表示为

$$\dot{\hat{x}} = A\hat{x} + BW S(x) + BW_{n+1} S'(x)u \quad (2)$$

式中 $\hat{x} \in R^n$, W 是 $n \times n$ 维权值矩阵, A 、 B 是 $n \times n$ 维对角矩阵, $n+1$ 是 $n \times n$ 维对角矩阵, $u = [u_1, u_2, \dots, u_m, 0, \dots, 0]^T$, $S(x)$ 和 $S'(x)$ 也是 $n \times n$ 维对角矩阵, 它们的每一个元素具有以下形式 $S(x_i) = k/(1 + e^{-lx_i})$, $S'(x_i) = k/(1 + e^{-lx_i}) + \lambda$, ($i = 1, 2, 3, \dots, n$)。其中 k 、 l 分别是 S 型函数的饱和值和斜率, 若选 $\lambda > 0$, 则有 $S'(x_i) > 0$, $i = 1, 2, \dots, n$ 。

假定可以得到一个精确发动机数学模型 (例如没有模型误差), 即只有神经网络的权值参数不确定, 那么可以假定存在权值 W^* , W_{n+1}^* 使动态神经网络能完全描述液体火箭发动机动态方程 (1), 即

$$\dot{\hat{x}} = A\hat{x} + BW^* S(x) + BW_{n+1}^* S'(x)u \quad (3)$$

式中所有矩阵与前面定义相同。辨识状态变量与实际系统变量之间误差 $e = \hat{x} - x$, 由方程 (2) 减去方程 (3) 得到误差方程

$$\dot{e} = Ae + B\tilde{W}S(x) + B\tilde{W}_{n+1}S'(x)u, \quad \tilde{W} = W - W^*, \quad \tilde{W}_{n+1} = W_{n+1} - W_{n+1}^* \quad (4)$$

引用李雅普诺夫方法来分析动态神经网络学习算法的稳定性, 定义李雅普诺夫函数为

$$V(e, \tilde{W}, \tilde{W}_{n+1}) = (1/2)e^T P e + (1/2)\text{tr}\{\tilde{W}^T \tilde{W}\} + (1/2)\{\tilde{W}_{n+1}^T \tilde{W}_{n+1}\} \quad (5)$$

式中矩阵 P 正定且满足李雅普诺夫方程 $PA + A^T P = -I_0$ 。由于 A 是对角矩阵, 为了简化计算




图 2 动态神经网络系统原理图

方法, 矩阵 P 也选定为对角矩阵。

若选择 $w_{ij} = -b_i p_{is}(x_j) e_i$, $w_{in+1} = -b_i s'(x_i) p_{iu} e_i$, $i, j = 1, 2, 3, \dots, n$, 由方程 (4) 和 (5) 得到

$$\dot{V} = - (1/2) \|e\|^2 \quad (6)$$

考虑误差微分方程 (4), 对于学习规则 $w_{in+1} = -b_i s'(x_i) p_{iu} e_i$, $w_{ij} = -b_i s'(x_i) p_{is}(x_j) e_i$, $i, j = 1, 2, 3, \dots, n$, 可证以下结论 $e, x, \tilde{W}, \tilde{W}_{n+1}^T \in L_\infty$, $e \in L_2$, $\lim_{t \rightarrow \infty} e(t) = 0$, $\lim_{t \rightarrow \infty} \tilde{W}(t) = 0$, $\lim_{t \rightarrow \infty} \tilde{W}_{n+1}^T(t) = 0$ 。

4 发动机故障检测与分离数值仿真

考虑到上天时的限制, 测点有限仅用燃烧室压力 (p_c)、燃气发生器压力 (p_b)、泵的转数 (N)、燃烧室氧化剂喷前压力 (p_o) 和燃料主导管分支处压力 (p_f) 构成液体火箭发动机系统的传感器测量向量 x , 输入向量 u 由氧化剂泵入口压力 (p_{io}) 和燃料泵入口压力 (p_{if}) 构成, 即测量向量 x 和输入向量 u 分别表示为 $\hat{x} = [\hat{p}_c, \hat{p}_b, \hat{N}, \hat{p}_o, \hat{p}_f]^T$, $u = [p_{io}, p_{if}]^T$ 。

动态神经网络辨识输出向量 $\hat{x}$ 相应为 $\hat{x} = [p_c, p_b, N, p_o, p_f]^T$, 由此动态神经网络辨识系统

的残差定义为 $\text{ERROR} = \sqrt{(p_c - \hat{p}_c)^2 + (p_b - \hat{p}_b)^2 + (N - \hat{N})^2 + (p_o - \hat{p}_o)^2 + (p_f - \hat{p}_f)^2}$

用于故障检测与分离的传感器数据通过随机模拟泵压式液体火箭发动机系统获得, 设置的故障发生时间是 1 s 时刻, 采样时间间隔是 0.01 s, 考虑的发动机故障有氧化剂泵汽蚀、燃料泵汽蚀、氧化剂主活门未完全打开、燃料主活门未完全打开以及两主活门都未完全打开。动态神经网络结构参数 $k = 1.5$, $l = 1.0$, $\lambda = 0.5$, $b_i = 65$ ($i = 1, 2, \dots, n$)。转移矩阵 A 的元素 a_i 的绝对值取得太小, 动态神经网络容易发散, 取得太大, 动态神经网络对故障响应不敏感。大量的数值仿真表明: $a_i = -20$ ($i = 1, 2, \dots, n$) 时, 动态神经网络很稳定且对故障响应敏感。液体火箭发动机故障检测的仿真结果见图 3、图 4, 从图中知在 1 s 时刻, 辨识残差 ERROR 明显增大, 当定义检测阈值 $\tau = 0.08$ 时, 检测逻辑可以正确检测出发动机 5 种故障。从图 3、图 4 知, 在开




图 3 氧化剂泵汽蚀残差变化趋势




图 4 燃料主活门未完全打开对残差变化趋势

始时刻附近, 残差 ERROR 比较大, 这是由于开始时动态神经网络权值是随机选择所致, 不过残差 ERROR 在 0.2 s 之后又降到正常范围之内, 因此液体火箭发动机在 0.2 s 以后发生故障, 动态神经网络才能正确检测出来。仿真发动机工作 2 s 神经网络故障检测系统本身占用的

高级微型计算机 CPU 时间为 0.303 s, 完全满足工程上对故障检测系统的实时性要求。

通过分析神经网络辨识残差 ERROR 的变化趋势, 已完成了液体火箭发动机的故障检测。一种用于故障分离的方法是用辨识误差的相关函数来进行, 在发动机工作正常时, 动态神经网络的辨识误差接近 0, 辨识误差相互之间没有关联; 发动机发生故障之后, 辨识误差发生变化, 辨识误差之间存在一定的相关性。对于不同类型的发动机故障发生之后, 误差相关函数 $R = E \{ ee^T \}$ 的空间结构是不同的。表 1 中反映的是在发动机发生故障以后误差相关函数的空间结构, 只列出了有变化的关键误差相关函数的元素 R_{ij} 。

表 1 误差相关函数变化趋势及分离结果

设置故障类型	关键误差相关函数变化特征						分离结果
氧化剂泵汽蚀	R_{11} 上升	R_{14} 上升	R_{41} 上升	R_{44} 上升			氧化剂泵汽蚀 或氧化剂主活门未完全打开
燃料泵汽蚀	R_{11} 上升	R_{55} 上升	R_{51} 略上升	R_{52} 略上升	R_{54} 略上升		燃烧泵汽蚀
氧化剂主活门 未完全打开	R_{11} 上升	R_{14} 上升	R_{41} 上升	R_{44} 上升			氧化剂泵汽蚀 或氧化剂主活门未完全打开
燃料主活门 未完全打开	R_{11} 上升	R_{55} 上升	R_{12} 略上升	R_{15} 略上升	R_{21} 略上升		燃料主活门未完全打开
两主活门都 未完全打开	R_{11} 上升	R_{14} 上升	R_{41} 上升	R_{44} 上升	R_{45} 略上升	R_{54} 略上升	两主活门都未完全打开

参照表 1 中关键误差相关函数变化特征, 由内限度量可以实现简单的故障分离逻辑, 只是这种分离逻辑不能把发动机氧化剂泵汽蚀故障与氧化剂主活门未完全打开故障分开, 这是由于两种故障引起的误差相关函数变化趋势相近似, 不过两种故障引起的关键误差相关函数的变化波形是不同的, 若采用更高级的分离方法 (如反推神经网络和模糊神经网络等) 来实现分离逻辑, 氧化剂泵汽蚀故障和氧化剂主活门未完全打开故障也是可以分开的。仿真发动机工作 2 s, 故障分离系统占用 CPU 时间为 0.45 s, 同样满足工程上对故障分离系统实时性要求。

5 结 论

提出了用于液体火箭发动机故障检测与分离的动态神经网络实现结构。数值仿真表明, 基于发动机传感器数据在线训练的动态神经网络故障辨识方法可成功地应用于泵压式液体火箭发动机系统的故障检测与分离, 并可用微型计算机达到工程上的实时性要求。动态神经网络虽然是一种有教师神经网络, 但它在用于发动机故障检测时, 无需发动机系统模型, 只是基于发动机传感器测量数据, 通过状态辨识产生残差来检测故障, 因此, 基于动态神经网络可以设计液体火箭发动机通用故障检测系统。

参 考 文 献

1 Ise mann R. Process Fault Detection Based on Modeling and Estimation Methods Automatica, 1984, 20: 387- 404

2 Duyar A, Elden V, Merrill W, Guo T. Fault Detection and Diagnosis in Propulsion System: A Fault Parameter Estimation Approach Journal of Guidance, Control and Dynamics, 1994, 17 (1)

3 Narendra K S, Parthasarathy K. Identification and Control of Dynamical Systems Using Neural Networks IEEE Trans Neural Networks, 1990, 1 (1) 4- 27

(责任编辑 杨再荣)