

基于飞行试验数据的双转子航空发动机 加减速瞬态模型辨识

潘鹏飞, 马明明, 许艳芝

(中国飞行试验研究院, 西安 710089)

摘要:为辨识航空发动机飞行过程中加减速瞬态模型,通过对某型航空发动机慢车至中间以及中间至慢车过程的飞行试验数据进行分析整理,将发动机上述加、减速过程简化为静态参数预测过程,利用 3 层前向人工神经网络,建立了某型发动机加、减速瞬态过程中的发动机关键参数预测模型,对发动机参数预测模型预测结果与飞行试验记录数据进行了对比分析,同时利用额外的飞行试验数据验证了辨识模型的泛化能力。结果表明:辨识得到的发动机模型在油门杆稳定时参数预测相对误差不超过 3%,在油门杆动作期间参数预测相对误差不超过 5%;验证点上辨识模型参数预测误差不超过 3%。证明该型发动机参数预测模型可以很好地预测发动机瞬态过程中的参数变化情况。该方法为建立发动机其他状态的加、减速过程参数变化模型奠定了基础,也能为建立全包线范围内发动机瞬态参数预测模型提供参考。

关键词:模型辨识;飞行试验;神经网络;加减速瞬态;航空发动机

中图分类号: 235.13

文献标识码:A

doi:10.13477/j.cnki.aeroengine.2016.03.015

Throttling-Transient Model Identification of Twin Spool Aeroengine Based on Flight Test Data

PAN Peng-fei, MA Ming-ming, XU Yan-zhi

(Chinese Flight Test Establishment, Xi'an 710089, China)

Abstract: In order to identify transient process model of an aeroengine during the flight, the flight test data of the aeroengine during the processes from idle state to middle state and from middle state to idle state has been analyzed. The actual throttling-transient process has been simplified as static parameter predicting of the gas turbine engine. The key parameter predicting model of the transient process of turbofan has been built with three-layers feed-forward artificial neural networks. The simulated results of identified model has been compared with actual flight test data, and the generalization of the model was validated using extra flight test data. The results show that the relative error of parameter prediction from the identified model is below 3% in stable throttling period, below 5% in transient throttling period, and the relative error of parameters prediction on verification points is below 3%. It shows that the parameters prediction model of an aeroengine can predict best parameters variation conditions of transient process. The method lay the foundation for building parameters variation model of aeroengine other throttling transient processes, and would provide conferences for aeroengine transient parameter predicting model in global flight envelope.

Key words: model identification; flight test; artificial neural network; throttling-transient process; aeroengine

0 引言

航空发动机工作过程涉及到复杂的热力、机械过程,其数学模型的构建一直是广泛研究的课题^[1-4]。发动机建模方法基本可以划分为基于解析法和基于系

统辨识 2 大类。常用的部件级模型是 1 种基于解析法的发动机模型,主要通过发动机内部部件内气动、热力学等关系式建立发动机的状态控制方程,通过求解控制方程确定发动机模型^[5]。基于系统辨识的建模方法不考虑发动机系统内部的非线性工作过程,将发动

收稿日期:2015-10-23

作者简介:潘鹏飞(1987),男,硕士,从事动力装置工作特性与性能飞行试验研究工作;E-mail:pf_pan@163.com。

引用格式:潘鹏飞,马明明,许艳芝.基于飞行试验数据的双转子航空发动机加减速瞬态模型辨识[J].航空发动机,2016,42(3):78-81. Throttling-transient model identification of twin spool aeroengine based on flight test data [J]. Aeroengine, 2016, 42(3): 78-81.

机系统作为 1 个整体考虑,利用系统的输入输出响应关系,通过合适的数据分析处理方法建立系统模型^[6]。

进行飞行试验的航空发动机多为技术状态不成熟、仍处在调整完善期间的发动机。飞行试验采用比正常使用更为严酷的条件对发动机进行考核鉴定,因此需要在飞行试验过程中对发动机实时监控,主要采用人工方式进行,监控质量受试飞工程师个人能力等因素影响,在发动机型号日益增加的情况下需要耗费大量人力资源。随着计算机技术的迅猛发展,有必要建立发动机智能化、自动化的实时条件监控系统。

航空发动机条件监控对于飞机安全和飞行安全保障至关重要,为建立发动机故障检测与隔离系统,首先需要建立发动机正常工作情况下的精确模型^[2-4,6]。人工神经网络模型属于黑箱模型,是数据驱动模型的一种,直接从发动机运行数据中即可辨识得到发动机模型,在目前已得到广泛应用^[2-6,12];Clifton^[7]与 Fast^[9]分别应用神经网络方法建立了发动机健康监测模型,通过试验数据对模型进行训练学习,而后对模型进行验证,获得了不错的监测精度;Fast 在发动机正常工作数据基础上建立基于多层前向人工神经网络的发动机参数变化模型,并成功应用于发动机故障检测中^[9-10]。本文基于某型涡扇发动机实际飞行试验数据,对该型发动机的加减速瞬态模型进行辨识研究,以便在试飞过程中对发动机实施实时监控。

1 基于人工神经网络的发动机加减速瞬态模型

文中研究对象为用于飞行试验的涡扇发动机,其工作参数由加装的机载测试系统测量和记录,选用实际飞行试验数据对该型发动机进行模型辨识,抽取了该型发动机慢车至中间 35 次加速过程试验数据样本,中间至慢车 45 次减速过程试验数据样本,试验样本点在飞行包线中的分布如图 1 所示。图中, $H_{p,\min}$ 、 $H_{p,\max}$ 、 $Ma_{i,\min}$ 、 $Ma_{i,\max}$ 分别代表最低、最高飞行高度和最小、最大飞行马赫数,因该型发动机慢车推力较小,试验样本点主要集中在飞行包线的左半边。

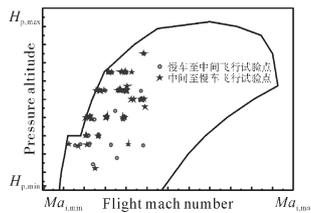


图 1 某型发动机加减速瞬态过程试验点分布

1.1 人工神经网络

人工神经网络在函数逼近方面的应用非常广泛,已形成较为成熟的分析方法。研究表明^[9],前馈神经网络

只要采用足够数目的隐含层以及合适的神经元数目即可对任意函数逼近,同时也对人工神经网络进行函数逼近的数学基础与充分条件进行证明,人工神经网络也适用于有限个间断点的函数拟合。

该型发动机模型辨识时采用的人工神经网络结构如图 2 所示。第 1 层有 R 个外部输入,第 1、2 层的输出分别是第 2、3 层的输入,第 1~3 层分别有 S^1 、 S^2 和 S^3 个神经元。可以将第 2 层看作是 1 个单层网络,有 $R=S^1$ 个输入, $S=S^2$ 个神经元,权值矩阵 $W^2=S^1 \times S^2$ 。第 2 层的输入记为 a^1 ,输出记为 a^2 。 b 为神经元偏置系数, f 为神经元激励函数。如果某层的输出是神经网络的输出,该层为输出层,其他层称为隐含层,图中神经网络具有 1 个输出层和 2 个隐含层。

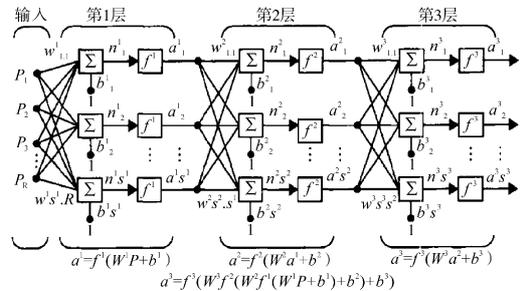


图 2 某型发动机模型辨识采用的 3 层神经网络结构

若 X 为神经网络输入向量,经过 3 层神经网络计算后的模型输出为

$$Y = f^3\{W^3 f^2[W^2 f^1(W^1 X + b^1) + b^2] + b^3\} \quad (1)$$

式中: X 为输入参数向量, Y 为神经网络输出向量, f 为神经网络激励函数, W 为权重系数矩阵, b 为偏置系数向量,上标 1、2 和 3 分别代表神经网络第 1 隐含层、第 2 隐含层和输出层。

1.2 飞行试验数据样本

航空发动机进行加、减速性飞行试验时,油门杆动作的前后,均要求发动机稳定工作一定时间。为了简化发动机模型复杂度,以发动机加、减速过程的持续时间 t 作为额外输入变量,记油门杆起始动作为 t_0 ,则时间参数范围为 $[t_0-5, t_0+20]$,采用静态神经网络进行模型辨识。

1.3 人工神经网络结构设置

采用 BP 算法对建立的神经网络系统进行训练学习,以神经网络输出结果与飞行试验数据之间的均方差作为训练学习的性能指数。人工神经网络采用 3 层结构,2 个隐含层采用 tan-sigmoid 激励函数,输出层采用线性激励函数,训练学习过程基于 Mat-

lab2013b 神经网络工具箱, 训练学习算法采用 LM 算法。

神经网络输入输出参数见表 1。为了便于讨论分析, 对试验数据进行归一化处理, 选择的归一化参数为数据样本中参数的最大值和最小值, 分别用下标 max 和 min 表示。

表 1 某型发动机神经网络模型输入输出参数

输入 / 输出	参数名称	参数符号	归一化参数	单位
输入	飞行高度	H_p	$[H_{p,\min}, H_{p,\max}]$	m
输入	飞行马赫数	Ma_i	$[Ma_{i,\min}, Ma_{i,\max}]$	-
输入	大气总温	T_{tb}	$[T_{tb,\min}, T_{tb,\max}]$	K
输入	发动机油门杆角度	P_{hi}	$[P_{hi,\min}, P_{hi,\max}]$	刻度
输入	发动机作战 / 训练状态	G_{dr}	[0, 1]	-
输入	加、减速持续时间	t_{dummy}	[0, 24]	s
输出	风扇转子转速	n_L	$[n_{L,\min}, n_{L,\max}]$	%
输出	压气机转子转速	n_H	$[n_{H,\min}, n_{H,\max}]$	%
输出	低压涡轮出口温度	T_6	$[T_{6,\min}, T_{6,\max}]$	K
输出	低压涡轮出口压力	P_6	$[P_{6,\min}, P_{6,\max}]$	MPa

1.4 神经网络模型训练学习

进行某型发动机加、减速过程模型辨识时, 采取如下训练学习步骤:

步骤 1: 初始化神经网络隐含层神经元个数;

步骤 2: 将试验数据样本按照预定的比例 70%、15% 和 15% 进行随机分组, 分别用于模型训练、验证和测试;

步骤 3: 利用模型训练和模型验证数据样本训练学习发动机神经网络模型;

步骤 4: 利用模型测试数据样本对辨识得到的发动机模型进行测试, 若满足精度要求, 则训练学习结束, 输出辨识得到发动机模型, 若不满足精度要求, 则重复步骤 2;

步骤 5: 调整神经网络隐含层神经元数目, 若达到预定的最大数目, 则停止训练学习, 若未达到, 重复步骤 2;

步骤 6: 对比步骤 4 得到的神经网络模型参数预测精度, 选择结构最简单, 预测精度最高的神经网络模型。

2 模型辨识结果

某型发动机飞行试验期间的加、减速试验过程中飞行试验点分布为: $0.02H_{p,\max} \sim 0.72H_{p,\max}$, $0.15Ma_{i,\max} \sim$

$0.43Ma_{i,\max}$, $-0.86T_{tb,\max} \sim 0.56T_{tb,\max}$, 为了降低计算复杂度, 剔除重复的试验数据样本点。进行慢车至中间、中间至慢车加速瞬态过程模型辨识时, 抽取具有代表性的飞行试验数据样本, 将数据样本按 70%、15% 和 15% 的比例随机分组, 这 3 组数据分别用于模型训练、验证和测试。为便于分析, 用相对误差来表征预测结果的精度。

$$E_{rel}(\%) = \frac{|Y_{fit} - Y_{sim}|}{Y_{fit}} \times 100\% \quad (2)$$

式中, Y_{fit} 为飞行试验实测数据, Y_{sim} 为神经网络模拟结果, E_{rel} 为相对误差。

2.1 慢车至中间过程参数模型

抽取该型发动机 35 次慢车至中间的加速过程试验数据样本用于模型辨识, 其结果如图 3 所示。由于试验次数较多, 图中只给出 5 次慢车至中间加速过程的模型辨识结果, 实线为辨识模型模拟计算结果, 虚线为计算结果相对飞行试验数据的误差分布情况, 图 4 同此说明。从模型预测结果与实际飞行试验结果对比中可见, 发动机油门杆稳定时风扇转子转速、压气机转子转速以及低压涡轮出口温度的模型计算结果相对误差均不超过 2%, 油门杆动作期间的相对误差不超过 5%。在油门杆动作以及稳定期间, 低压涡轮出口压力的模型计算结果相对误差均不高于 5%。该型发动机慢车状态存在 2 种不同的尾喷管控制方案, 尾喷管的收放动作对低压涡轮出口压力有直接影响, 因此低压涡轮出口压力的辨识模型精度略低。

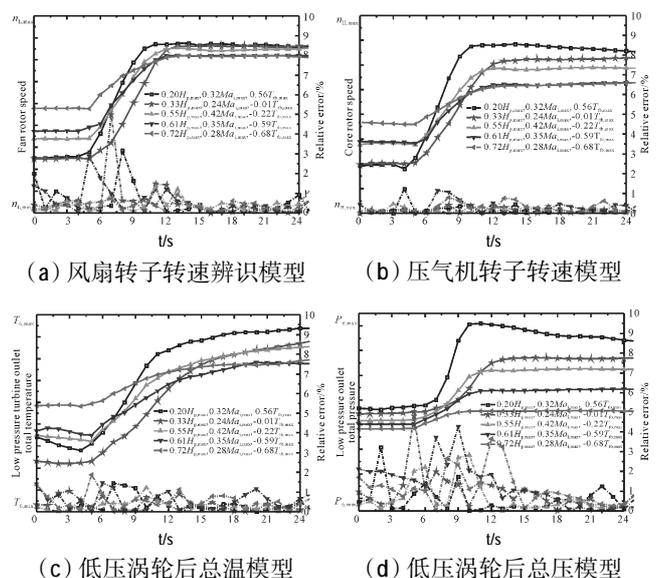


图 3 慢车至中间加速过程模型辨识结果

2.2 中间至慢车过程参数模型

抽取了某型发动机 45 次中间至慢车减速过程试验数据样本用于模型辨识,其结果如图 4 所示。从模型预测结果与实际飞行试验结果对比中可见,发动机油门杆稳定时风扇转子转速、压气机转子转速以及低压涡轮出口温度的模型计算结果相对误差均不超过 2%,油门杆动作期间的相对误差不超过 5%。在油门杆动作以及稳定期间,低压涡轮出口压力的模型计算结果相对误差均不高于 5%。同慢车至中间过程辨识结果类似,低压涡轮出口压力受尾喷管收放的直接影响,辨识精度略低。

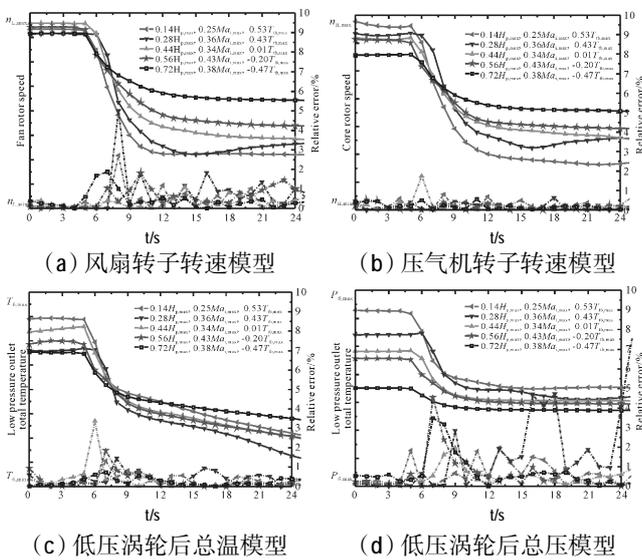
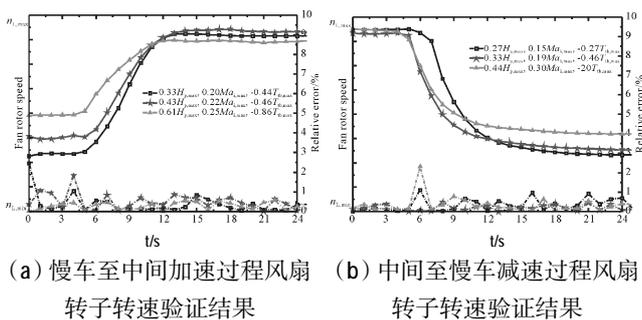


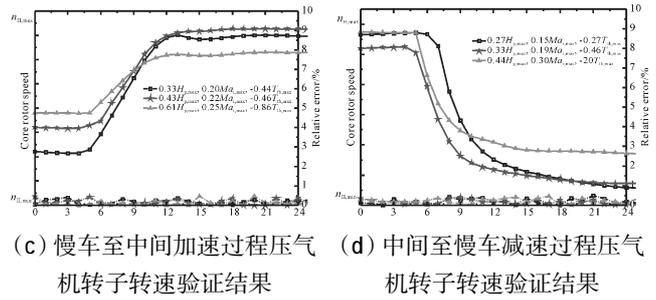
图 4 中间至慢车减速过程模型辨识结果

3 辨识模型验证

分别选择未参与到发动机模型辨识过程的 7 次慢车至中间、中间至慢车过程数据样本对模型进行测试,验证该型发动机模型的推广性能,计算结果如图 5 所示。为了清晰显示,图中只给出 3 次测试结果,从图中可见,将辨识模型应用至新的试验数据样本上时,低、高压转子转速的相对误差均低于 2%。该型发动机的辨识模型在非样本点上的推广性能较好。



(a) 慢车至中间加速过程风扇转子转速验证结果 (b) 中间至慢车减速过程风扇转子转速验证结果



(c) 慢车至中间加速过程压气机转子转速验证结果 (d) 中间至慢车减速过程压气机转子转速验证结果

图 5 风扇转子及压气机转子转速验证结果

4 结论

本文基于某型发动机科研试飞实际飞行试验数据,利用 3 层前向人工神经网络辨识得到了某型发动机的慢车至中间加速过程以及中间至慢车减速过程的参数预测模型,利用飞行试验数据对辨识模型进行了检验,检验结果表明该型发动机辨识模型具有可靠的精度,可以应用于发动机定型试飞过程中的安全监控、故障监测中,同时本文采用的模型辨识方法可以推广应用至该型发动机的其他瞬态过程参数辨识中。

参考文献:

- [1] Gennady G, Haydn A. Dynamic modeling of gas turbines: identification, simulation, condition monitoring and optimal control [M]. London: Springer-Verlag, 2004: 90-110.
- [2] Ruano A, Fleming P. Nonlinear identification of aircraft gas-turbine dynamics[J]. Neurocomputing, 2003, 55(3): 551-579.
- [3] Sina T, Sadough Z. Dynamic neural network-based fault diagnosis of gas turbine engines[J]. Neurocomputing, 2014, 125(5): 153-165.
- [4] Joly R, Ogaji S. Gas-turbine diagnostics using artificial neural networks for a high bypass ratio military turbofan engine [J]. Applied Energy, 2004, 78(4): 397-418.
- [5] Aidan W, Donald L. An integrated architecture for aircraft engine performance monitoring and fault diagnostics: engine test results [R]. AIAA-2014-3924.
- [6] Jonas S, Qinghua Z. Nonlinear black-box modeling in system identification: a unified overview[J]. Automatica, 1995, 31(12): 1691-1724.
- [7] Clifton D. Condition monitoring of gas-turbine engines [D]. London: University of Oxford, 2005.
- [8] Dawn A, Nam N, Joo H C. Statistical aspects in neural network for the purpose of prognostics[R]. AIAA-2014-0481.
- [9] Fast M, Assadi M. Development and multi-utility of an ANN model for an industrial gas turbine[J]. Applied Energy, 2009, 86(1): 9-17.
- [10] Fast M. Artificial neural networks for gas turbine monitoring[D]. Scania: Lund University, 2010.
- [11] Andrea L. Analytical and neural network models for gas turbine design and off-design simulation [J]. International Journal of Applied Thermodynamics, 2001, 4(4): 173-182.
- [12] Wenfeng L, Yongsheng W. Identifying the inlet pressure distortion signal based on wavelet-neural network[R]. AIAA-2004-2604.
- [13] Chiras N, Evans C. Nonlinear gas turbine modeling using feed forward networks[R]. ASME 2002-GT-30035.
- [14] Madan M, Liang J, Noriyasu H. Static and dynamic neural networks: from fundamentals to advanced theory [M]. Hoboken: Wiley-IEEE Press, 2003: 106-140.
- [15] Oliver L, Pierre D. Adaptive estimation algorithm for aircraft engine performance monitoring[J]. Journal of Propulsion and Power, 2008, 24(4): 763-769.

(编辑:赵明普)