

基于动态逆的涡轴发动机自适应模型建模方法研究

夏天乾¹,徐植桂¹,吴金栋¹,汪勇²

(1. 中国航发动控制系统研究所,江苏 无锡 214013;

2. 南京航空航天大学 江苏省航空动力系统重点实验室,江苏 南京 214016)

摘要:为实现对涡轴发动机动态响应的实时跟踪,提出一种基于动态逆与神经网络的涡轴发动机自适应模型建模方法。基于考虑健康因子输入的涡轴发动机状态变量模型及真实发动机可测状态参数,设计一种基于动态逆的健康参数估计方法;基于神经网络建立包含健康参数的涡轴发动机机载模型,共同构成涡轴发动机自适应模型;进行典型任务下的对比仿真分析。研究表明:相比于线性卡尔曼滤波器,基于动态逆的涡轴发动机自适应模型不仅能获得相同的健康参数稳态估计精度,而且总时间消耗可有效减小 26% 左右,实时性更高;自适应模型的稳态误差不超过 0.5%,动态精度更高,更有利于实现涡轴发动机动态响应的自适应跟随。

关键词:涡轴发动机;自适应模型;动态逆;健康参数估计;神经网络

中图分类号:TP183 **文献标志码:**B **文章编号:**1671-5276(2022)05-0123-03

Research on Adaptive Modeling Method of Turboshaft Engine Based on Dynamic Inversion

XIA Tianqian¹, XU Zhigui¹, WU Jindong¹, WANG Yong²

(1. AECC Aero Engine Control System Institute, Wuxi 214013, China; 2. Jiangsu Provincial Key Laboratory of Aerospace Power System, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: In order to realize the real-time tracking of turboshaft engine dynamic response, an adaptive modeling method of turboshaft engine based on dynamic inversion (DI) and neural network (NN) is proposed. Based on the state variable model of turboshaft engine considering health parameters and the measurable state variables of real engine, a health parameter estimation method based on DI is developed, and the onboard model of turboshaft engine consisting of health parameters is established on the basis of NN, two of which commonly constitutes the adaptive model of turboshaft engine. The analysis on the comparison and simulation is conducted under typical flight tasks with the results showing that the adaptive model based on dynamic inversion can not only obtain the consistent steady-state estimation accuracy of health parameters, but also reduce the total time consumption by about 26% effectively with better real-time performance. And the steady-state error of the adaptive model is less than 0.5%, whose higher dynamic accuracy is more beneficial to trace the dynamic response of turboshaft engine adaptively.

Keywords: turboshaft engine; adaptive model; dynamic inversion; health parameter estimation; neural network

0 引言

如何更好地建立涡轴发动机自适应模型是实现性能寻优控制、模型预测控制及在线故障诊断等先进控制技术的基础与前提^[1]。一个好的涡轴发动机自适应模型不仅可以准确表达发动机额定工作下的系统动态,而且需具备实时反映发动机服役期内部件退化对发动机性能影响的能力^[2]。

近年来,随着神经网络与深度学习的快速兴起,促进了基于数据驱动的涡轴发动机机载自适应建模方法的进一步发展^[3]。然而,随着服役时间的延长,涡轴发动机各部件不可避免地发生退化,造成发动机的关键性能参数出现明显偏差;此外,考虑到发动机部件退化因子无法直接测量获得^[4],因此有必要在快速、准确估计发动机退化情形的基础上,构建高保真的涡轴发动机自适应模型。

自卡尔曼(Kalman)估计方法出现以来,以Kalman滤

波估计器为核心,根据发动机实测状态量的变化估计发动机性能退化的自适应建模方法应运而生,出现了很多相关的应用成果^[5]。LUPPOLD R等^[6]率先提出了基于卡尔曼滤波思想的发动机自适应建模方法,根据可测输出实时估计发动机性能退化因子。为弥补线性卡尔曼估计方法只能用于小范围的缺陷,SAAB S S采用拓展卡尔曼滤波的方法^[7],通过在线拟合发动机的状态变量模型,实时求解卡尔曼增益矩阵,拓宽了卡尔曼估计技术的适用范围。显然这种处理给控制系统设计、计算都带来较大的复杂度。此外,POURBABAEE B等^[8]采用多模型混合卡尔曼滤波器实现对燃气轮机传感器的故障检测、隔离和识别,可准确检测发动机故障。张海波等提出了一种基于机载非线性发动机模型,且具有输入端积分补偿的卡尔曼滤波器估计器的发动机自适应模型设计方法^[9]。鲁峰等提出了一种基于容积跟踪滤波器的涡轴发动机自适应部件级仿真模型构建方法,自动修正各部件的流量和效率特性

图,以进行部件气动热力参数计算^[10]。然而,发动机的强非线性特性导致以 Kalman 滤波为核心的发动机自适应模型难以完全跟踪实际发动机的输出。基于此,肖玲斐等^[11]结合滑模控制理论,设计滑模控制器,提出基于误差反馈滑模控制的航空发动机自适应线性动态模型设计方法。但滑模控制量的切换幅度越大,抖动越明显。在精确度要求较高的航空航天领域,这种抖动存在影响系统响应品质的可能。

综上,本文为弥补现有技术研究的不足,提出一种基于动态逆的航空发动机自适应建模方法。

1 基于动态逆的自适应模型

动态逆作为一种多变量控制结构^[12],可对控制变量进行动态特性处理,以达到期望的特性,能对复杂的耦合非线性问题进行解耦控制^[13-14],因此在飞行控制等领域发挥着重要的作用。接下来介绍基于动态逆的健康参数估计方法。

1.1 基于动态逆的健康参数估计器

实现动态逆的前提是获取能实时表达发动机工作特性的数学解析式。而对于涡轴发动机而言,通常可采用状态变量模型近似表达发动机的非线性动态特性。额定状态下,涡轴发动机状态变量模型的表达形式为

$$\begin{aligned} \dot{x} &= Ax + Bu \\ y &= Cx \end{aligned} \quad (1)$$

一般情况下,上式的控制输入向量 u 包括旋翼总距 θ_0 与燃油流量 W_b 。而当发动机性能发生退化时,通常可用部件效率和流量特性与设计值的偏差来表征发动机的健康情况。因此,为了基于动态逆实现对涡轴发动机健康参数的实时估计,输入向量 u 中还需包含部件的健康参数。由此可得基于动态逆的健康参数估计器表达式为

$$\begin{aligned} u &= (C \cdot B)^{-1} \cdot [\lambda - (C \cdot A)x] \\ \lambda &= K \cdot (y_{\text{real}} - y) \end{aligned} \quad (2)$$

式中 y_{real} 代表真实涡轴发动机的可测参数; K 为线性控制器的增益矩阵。若 $C \cdot B$ 非方阵时,可采用广义逆或加号逆代替。由上式可知,当状态变量模型的输出可实时跟踪真实发动机的可测输出时,动态逆即可实现对发动机部件健康参数的最优估计。

1.2 基于神经网络的涡轴发动机机载模型

Back Propagation (BP) 神经网络作为一种根据误差逆向传播算法训练的多层前馈网络^[15-16],可在未知系统工作属性的前提下,学习、存储大量的输入-输出映射关系,是目前应用最为广泛神经网络模型之一。因此本文采用 BP 神经网络离线训练获得涡轴发动机机载模型。

为了使机载模型能更准确地反映原发动机的动态特性,采用非线性自回归滑动平均模型结构。设涡轴发动机机载模型为 2 阶系统,以历史时刻的发动机控制量、健康参数、发动机的相关可测状态参数以及当前时刻的发动机控制量、健康参数为输入,当前时刻发动机状态参数为输出,如下式所示。

$$Y = f_{NN}(M)$$

$$\begin{cases} M = [m_1(k), m_1(k-1), m_1(k-2), \\ m_2(k), m_2(k-1), m_2(k-2), \dots, \\ m_{n-1}(k-1), m_{n-1}(k-2), \\ m_n(k-1), m_n(k-2)]^T \\ Y = [m_{n-r+1}(k), \dots, m_{n-1}(k), m_n(k)]^T \end{cases} \quad (3)$$

式中 M, Y 分别为航空发动机机载模型的输入、输出向量; m 为各向量中的元素; n 为输入向量的维数; r 为输出向量的维数; k 为当前时刻。

2 仿真验证

结合上述原理,可得基于动态逆的涡轴发动机自适应模型结构如图 1 所示。图 1 中自适应模型由涡轴发动机、基于增量式动态逆的健康参数估计器、基于神经网络的涡轴发动机机载模型三部分组成。其中,涡轴发动机机载模型可离线获得。由图可知,在单个仿真步长内,发动机健康参数估计器根据涡轴发动机的可测状态参数与涡轴发动机状态变量模型的状态量,实时估计发动机的健康参数,并传递至涡轴发动机机载模型,一起构成涡轴发动机的自适应模型。

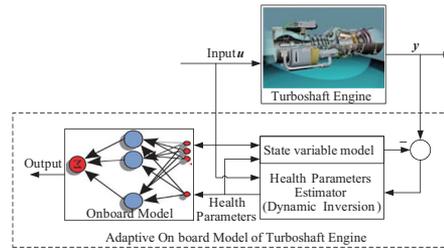


图 1 机载自适应模型结构

假设仅考虑压气机、燃气涡轮的效率发生退化,则涡轴发动机机载模型表达形式如下:

$$\begin{aligned} Y &= f_{NN}(M) \\ M &= [W_b(k), W_b(k-1), W_b(k-2), \\ \theta_0(k), \theta_0(k-1), \theta_0(k-2), \\ d_{\eta_c}(k), d_{\eta_c}(k-1), d_{\eta_c}(k-2), \\ d_{\eta_g}(k), d_{\eta_g}(k-1), d_{\eta_g}(k-2), \\ p_{np}(k-1), p_{np}(k-2), p_{nc}(k-1), p_{nc}(k-2), \\ T_{45}(k-1), T_{45}(k-2), p_3(k-1), p_3(k-2), \\ T_{qe}(k-1), T_{qe}(k-2), H(k-1), H(k-2), \\ v_x(k-1), v_x(k-2)]^T \\ Y &= [p_{np}(k), p_{nc}(k), T_{45}(k), p_3(k), T_{qe}(k)]^T \end{aligned} \quad (4)$$

式中 k 为当前时刻,是指当前周期的数据; $k-1, k-2$ 为历史时刻,是指上周期和上上周期的数据; 输入量为历史时刻的燃油流量 W_b 、旋翼总距 θ_0 、压气机效率健康参数 d_{η_c} 、燃气涡轮效率退化系数 d_{η_g} 、动力涡轮相对转速 p_{np} 、压气机相对转速 p_{nc} 、动力涡轮出口温度 T_{45} 、压气机出口压力 p_3 、发动机输出转矩 T_{qe} 、飞行高度 H 、前飞速度 v_x 以及当前时刻的 $W_b, \theta_0, d_{\eta_c}, d_{\eta_g}$; 输出量为当前时刻的 $p_{np},$

p_{nc} 、 T_{45} 、 p_3 与 T_{qc} 。因此,整个涡轴发动机机载模型包括 26 个输入、5 个输出。机载模型相对测试误差如图 2 所示。由图可知,各输出参数相对误差均 $<0.1\%$,精度较高,满足要求,可用于构建涡轴发动机机载自适应模型。

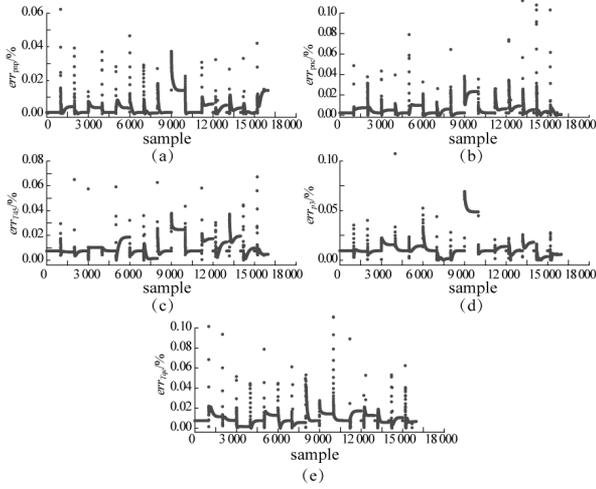


图 2 机载模型相对测试误差

接下来在典型飞行任务下进行基于动态逆的涡轴发

动机自适应模型仿真测试,并与基于线性卡尔曼滤波器的自适应模型进行对比,结果如图 3 所示。其中,直升机飞行高度 $H=200\text{ m}$,前飞速度 $v_x=12\text{ m/s}$,旋翼总距为 9° , $t=10\text{ s}$ 时,压气机、燃气涡轮的效率同时退化 1% 。

由图 3(a)、图 3(b)可知,无论发动机是否工作于额定状态,线性卡尔曼滤波器与基于动态逆的健康参数估计器均能实现对压气机、燃气涡轮效率的实时估计,且稳态估计误差保持一致。而如图 3(h)所示,采用线性卡尔曼滤波器估计发动机健康参数时,单步耗时基本大于基于动态逆的健康参数估计器,后者可使总时间消耗有效减小 26.2% ($(0.1378-0.1017)/0.1378 \times 100\%$)左右,在精度近乎一致的前提下,显著提升了估计健康参数的实时性能。此外,由图 3(c)-图 3(g)可知, $t < 10\text{ s}$ 时,涡轴发动机的健康参数均为 0,发动机处于额定工作状态,此时自适应模型的输出结果与发动机的真实响应保持一致。而随着发动机服役时间变久,虽然压气机、燃气涡轮的效率发生退化,发动机处于非额定工况,工作状态发生显著变化。但基于线性卡尔曼滤波器与动态逆的涡轴发动机自适应模型的输出参数仍可很好地跟踪真实发动机的输出响应,且稳态误差均不超过 0.5% 。相比于前者,结合动态逆与神经网络的涡轴发动机自适应模型动态精度更高,变状态鲁棒性能更加优越。

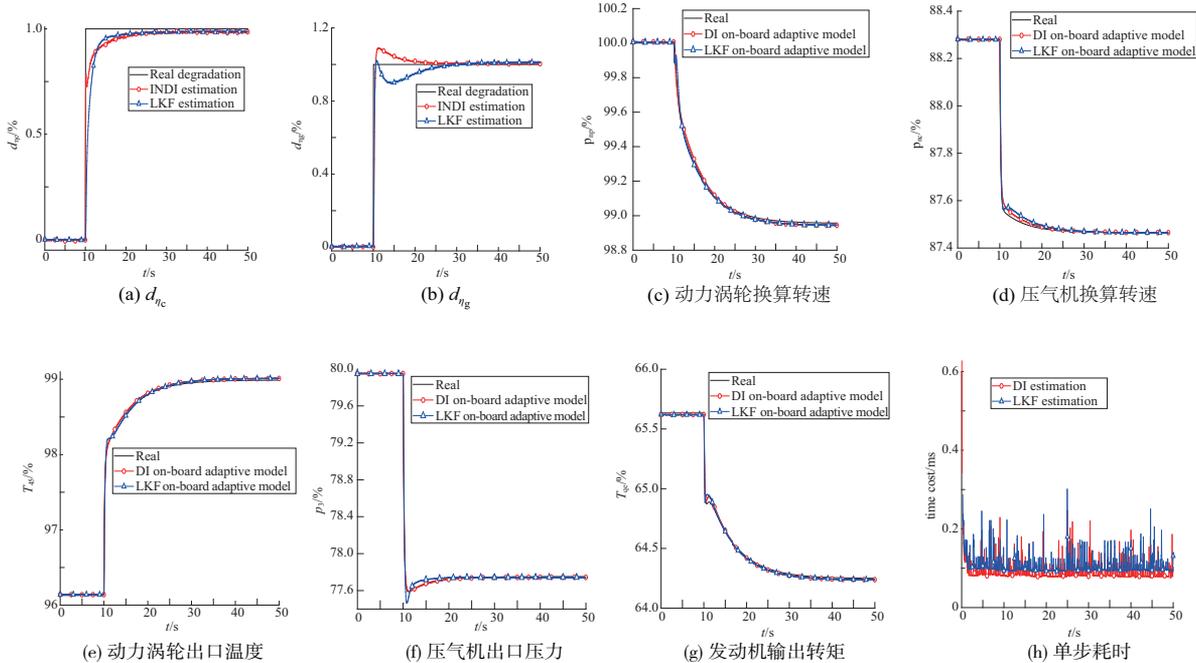


图 3 机载自适应模型仿真结果

3 结语

本文进行了基于动态逆的涡轴发动机自适应建模方法研究,提出并建立了综合基于动态逆的健康参数估计器与基于神经网络的涡轴发动机机载模型的自适应模型,并在典型飞行任务下,进行了仿真对比验证,得到如下结论:

- 1)与线性卡尔曼滤波器相比,动态逆可在获得相同健康参数稳态估计精度的前提下,单步耗时更短,总时间消耗可有效减小 26% 左右,实时性更高;
- 2)相比于线性卡尔曼滤波器,基于动态逆与神经网络的涡轴发动机自适模型可实时跟踪真实发动机的输出响应,稳态误差不超过 0.5% ,动态精度更高,更有利于实现涡轴发动机变状态自适应跟随。

(下转第 148 页)

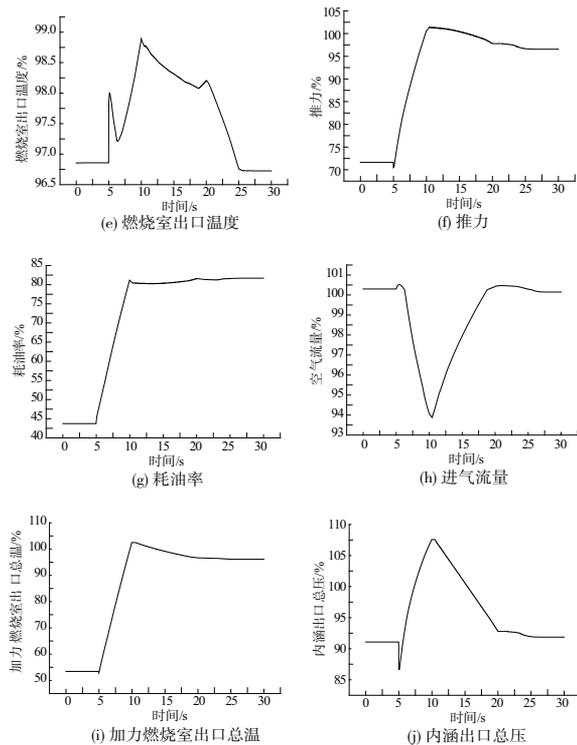


图6 加力动态仿真曲线

仿真结果表明:在开环调节加力燃油流量情况下,当发动机进入加力状态后,加力燃油增加,加力温度上升,加力燃烧室出口总压 P_7^* 增加,使得内涵出口总压 P_6^* 相应上升,导致发动机 EPR 上升,这时增大尾喷管喉道面积 A_8 。同时,涡轮膨胀比下降,涡轮功和转速减小,也需增加

主供油量 W_f ,使得高低转子转速维持在稳定状态;将结果与设计点值进行对比,最大状态推力相较设计点少 1.72%,最大状态耗油率相较发动机设计点少 2.96%,结果表明整个模型加力状态仿真较为准确。

3 结语

本文根据容积动力学法建立变循环发动机的实时动态数学模型,考虑发动机容腔的储能效应,合理选择了 4 个容腔并给出容腔气体流道的压力和温度微分方程,采用欧拉法进行求解,获得了给定初值条件下满足发动机热力学循环的微分方程解。通过对模型进行仿真,其结果表明:所搭建的变循环发动机模型可以模拟发动机模态切换的过程,同时其加力仿真过程也符合变循环发动机性能规律,故证明了本文所采用的建模方法的正确性,为建立具有工程实用性的模型打下了基础。

参考文献:

- [1] 王元. 变循环发动机建模及性能寻优控制技术研究[D]. 南京:南京航空航天大学,2015.
- [2] 窦健,吴琼. 变循环发动机后涵道引射器调节工况的数值研究[J]. 机械制造与自动化,2020,49(3):195-197.
- [3] 张睿. 变循环发动机建模及气动性能研究[D]. 南京:南京航空航天大学,2018.
- [4] 唐世建,童万军. 基于容积法的某涡扇发动机动态建模方法[J]. 航空动力学报,2013,28(3):709-713.
- [5] 苟学中,周文祥,黄金泉. 变循环发动机部件级建模技术[J]. 航空动力学报,2013,28(1):104-111.

收稿日期:2021-05-14

(上接第 125 页)

参考文献:

- [1] SKLIROS C, ESPERON MIGUEZ M, FAKHRE A, et al. A review of model based and data driven methods targeting hardware systems diagnostics[J]. Diagnostics, 2018, 20(1):3-21.
- [2] SAMPATH S, SINGH R. An integrated fault diagnostics model using genetic algorithm and neural networks[J]. Journal of Engineering for Gas Turbines and Power, 2006, 128(1):49-56.
- [3] LARSSON E, ASLUND J, FRISK E, et al. Health monitoring in an industrial gas turbine application by using model based diagnosis techniques[C]//Proceedings of ASME 2011 Turbo Expo; Turbine Technical Conference and Exposition, Vancouver, British Columbia, Canada; 2012:487-495.
- [4] LITT J S. Method for estimation of at least one engine parameter: US, US8185292[P]. 2012-05-22.
- [5] KALMAN R E. A new approach to linear filtering and prediction problems[J]. Journal of Basic Engineering, 1960, 82(1):35-45.
- [6] LUPPOLD R, ROMAN J, GALLOPS G, et al. Estimating in-flight engine performance variations using Kalman filter concepts[C]//25th Joint Propulsion Conference. Monterey, CA. Reston, Virginia: AIAA, 1989.
- [7] SAAB S S. A heuristic Kalman filter for a class of nonlinear systems[J]. IEEE Transactions on Automatic Control, 2004, 49(12):2261-2265.

- [8] POURBABAEE B, MESKIN N, KHORASANI K. Sensor fault detection, isolation, and identification using multiple-model-based hybrid Kalman filter for gas turbine engines[J]. IEEE Transactions on Control Systems Technology, 2016, 24(4):1184-1200.
- [9] 张海波,陈霆昊,孙健国,等. 一种新的航空发动机自适应模型设计与仿真[J]. 推进技术, 2011, 32(4):557-563.
- [10] 鲁峰,高天阳一,黄金泉,等. 一种涡轴发动机自适应部件级仿真模型构建方法:中国, CN108829928 B[P]. 2020-10-27.
- [11] 肖玲斐,杜彦斌,胡继祥,等. 一种基于滑模理论的航空发动机气路故障诊断方法:中国, CN106055770 B[P]. 2019-02-26.
- [12] AVANZINI G, THOMSON D, TORASSO A. Model predictive control architecture for rotorcraft inverse simulation[J]. Journal of Guidance, Control, and Dynamics, 2013, 36(1):207-217.
- [13] 胡文霏,黄金泉. 航空发动机自适应逆控制研究[J]. 航空动力学报, 2005, 20(2):293-297.
- [14] 张海波,汪勇,杜紫岩,等. 涡轴发动机非线性动态逆控制方法及装置:中国, CN109446605 B[P]. 2020-06-05.
- [15] SCHMIDHUBER J. Deep learning in neural networks: an overview[J]. Neural Networks, 2015, 61:85-117.
- [16] 郑前钢. 智能航空发动机综合优化控制研究[D]. 南京:南京航空航天大学,2018.

收稿日期:2021-05-26