

基于 NN-PSM 的航空发动机机载 自适应稳态模型

项德威, 郑前钢, 张海波, 陈 钺, 房 娟

(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: 为建立一种适用于大包线、变状态的高精度、高实时性航空发动机机载自适应稳态模型, 提出一种基于神经网络和推进系统矩阵相融合(NN-PSM)的机载自适应稳态模型建模方法。该方法基于小偏差线性化方法对发动机进行线性化来提取推进系统矩阵, 用于表征机载模型与发动机之间的输出偏差量。基于神经网络建立发动机基线模型, 用于映射飞行条件与发动机输出量之间的关系, 利用神经网络的强拟合能力提高机载模型的稳态精度; 设计卡尔曼滤波器实时估计发动机健康参数, 提高模型的自适应能力。在大包线、变状态的飞行条件下进行仿真验证, 并与传统的复合推进系统模型(CPSM)进行对比, 结果表明: NN-PSM 模型的平均精度在 0.66% 以内, 而 CPSM 的平均精度为 2.07% 以内, 运行时间仅为 CPSM 的 1/10, 且具有数据存储量少的特点。

关 键 词: 机载稳态模型; 推进系统矩阵; 神经网络; 基线模型; 自适应

中图分类号: V231

文献标志码: A

Aero-engine on-board adaptive steady-state model base on NN-PSM

XIANG Dewei, ZHENG Qiangang, ZHANG Haibo,
CHEN Cheng, FANG Juan

(Jiangsu Province Key Laboratory of Aerospace Power System,
College of Energy and Power Engineering,

Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: In order to establish a high-precision, high-real-time aero-engine on-board adaptive steady-state model suitable for large envelopes and multiple states, a on-board adaptive steady-state model based on neural network and propulsion system matrix fusion (NN-PSM) was proposed. Adaptive steady-state modeling method was based on small deviation linearization method to linearize the engine to extract the propulsion system matrix, which was used to characterize output deviation. The engine baseline model was established based on the neural network, and the relationship between the flight conditions and the engine output was mapped, and the neural network used the strong fitting ability to improve the steady-state accuracy of the on-board model. The Kalman filter was designed in real time to improve the adaptive ability of the model.

收稿日期: 2021-04-03

基金项目: 国家自然科学基金(51906102); 国家科技重大专项(2017-V-0004-0054);

智能航空发动机基础问题研究项目(2017-JCJQ-ZD-047-21); 中央高校基本科研业务费(NZ2020002)

作者简介: 项德威(1995—), 硕士生, 研究领域为航空发动机控制。E-mail: 17865324367@163.com

通信作者: 郑前钢(1990—), 讲师, 博士, 研究领域为航空发动机控制。E-mail: zhqg@nuaa.edu.cn

引用格式: 项德威, 郑前钢, 张海波, 等. 基于 NN-PSM 的航空发动机机载自适应稳态模型[J]. 航空动力学报, 2022, 37(2): 409-423.

XIANG Dewei, ZHENG Qiangang, ZHANG Haibo, et al. Aero-engine on-board adaptive steady-state model base on NN-PSM[J]. Journal of Aerospace Power, 2022, 37(2): 409-423.

The simulation was carried out under large envelope and variable state flight conditions, and compared with the traditional compact propulsion system model (CPSM) model. The results showed that the average accuracy of the NN-PSM model was within 0.66%, while the average accuracy of the CPSM model was about 2.07%; the time was about one-tenth of the CPSM model, and the amount of data storage was small.

Key words: on-board steady-state model; propulsion system matrix; neural network; baseline-model; adaptive

航空发动机是多变量、强非线性、时变的复杂系统,其稳定安全运行对发动机控制系统提出了很高的要求^[1]。目前发动机先进控制算法基本基于机载模型,如发动机解析冗余技术^[2]以机载的发动机模型参数为基础进行在线的故障诊断。飞/推综合控制^[3]的核心机制是机载的推进系统模型,以机载模型为优化对象依据不同的飞行需求进行在线的性能寻优计算以获得最优的控制修正量,最大限度地挖掘飞机和发动机的性能潜力。模型预测控制^[4]是基于机载模型的控制方法,通过在线滚动优化求解发动机在满足各种约束下的最优控制。因此,建立一个精确、实时性好的机载模型,并在各种飞行条件下都能对发动机的优化及故障诊断及及时输出精确的性能参数是提高控制系统稳定性的基础。因此,本文提出一种航空发动机机载稳态模型建立方法,在一定程度上提升机载模型精度的同时,大幅提高模型的实时性,并降低模型的数据存储量。

目前,国内外提出了很多关于发动机稳态模型的建模方法。在国外,文献[5]以发动机部件级模型(component level model, CLM)为寻优模型进行实时性能优化,由于部件级模型的非线性计算精度高于线性化模型,提高了机载模型的精度。NASA 构建了可用于性能趋势监控及气路故障诊断的机载模型^[6-10],该模型通过商用模块化航空推进系统(C-MAPSS40k)提取,并成功地检测到了稳态故障。传统的机载自适应模型是基于卡尔曼滤波器的,文献[11-12]在传统的机载自适应模型的基础上,加入神经网络估计模块实时估计发动机偏差量,以补偿模型输出与发动机输出之间的偏差,该方法表现出良好的实时性。近年来,国内的航空发动机机载模型建模研究方面也取得了丰富的成果。文献[13-14]提出的一种基于数据驱动建模方法实现对发动机的故障诊断,有效地提高了部件故障诊断的精度和准确率。程都^[15]提出了一种基于神经网络的航空发动机全包线模型自

适应修正方法,通过并行补偿器对发动机与通用数学模型进行补偿修正。王健康等^[16]提出了一种基于相似理论的机载模型,采用分段线性方法建立稳态线性化模型与非线性模型相结合并用于性能寻优,结果表明,模型的实时性有明显的提高。鲁峰、王海泉等^[17-19]以发动机部件级模型作为基线模型对卡尔曼滤波算法进行了不同程度的改进,提高了机载模型的自适应性。以上航空发动机机载模型建立方法主要集中在分段线性模型(piecewise linear model, PLM)和基于数据驱动的建模方法,如支持向量机^[20]、神经网络^[21-22](neural network, NN)等,并取得良好效果,但都只围绕机载模型的精度或实时性某一个方面展开研究。如分段线性插值方法^[23]的优点在于简单而且实时性好,但由于分段线性模型采用的插值的形式需要存储大量的插值表^[24-25],并且模型在扩展到全包线时,随着输入、输出维数的增加所需数据量极大,显然发动机的样本数据通常无法满足模型建模数据量要求,这也使得模型的精度很难得到保证^[26]。而基于数据驱动的建模方法存在着与分段线性插值同样的缺点,在模型输入、输出维数的增加的情况下,就必须同步增加样本数据的采集量,容易出现维度灾难问题,如支持向量机虽然提高了模型的实时性,但需要极大的数据量来扩展飞行包线。

NASA^[27-28]提出一种复合推进系统模型(compact propulsion system model, CPSM)建模方法,该方法基于物理机理和分段线性插值相融合^[29-30]进行建模,飞行结果表明该模型的实时性与精度都有较好的表现,但CPSM中的非线性模型制约了模型实时性的进一步提升,同时,该模型中的相似换算也在一定程度上影响了模型精度的提升。

基于此,本文提出了一种基于神经网络和推进系统矩阵相融合(neural network-propulsion system matrix, NN-PSM)的发动机机载自适应稳态模型建模方法。该方法的核心部分是基于神经

网络建立一个由飞行条件得到发动机重要性能参数的基线模型,和基于推进系统矩阵得到输出参数的偏差量对机载模型的输出进行修正。相较于传统方法,如文献[2]中采用插值表的形式来获取基准值,采用神经网络来映射地面状态下发动机可测参数与不可测参数偏差量之间的关系以修正模型输出。文献[16]中采用神经网络来映射地面状态下的主燃油量、尾喷管喉道面积与发动机可测参数之间的关系来获取地面状态下该工作点的基准值,及推进系统矩阵(PSM)来获取输出偏差量以修正模型输出。上述方法均需要经过两次相似换算将模型扩展至全包线,该过程在一定程度上影响了建模精度,同时由于大部分运行时间都消耗在了模型的非线性计算与迭代中,这也严重制约着模型的实时性。CPSM同样存在着上述问题。而本文所建立的机载模型由于不需要经过相似换算和非线性计算,提高了模型精度和实时性,同时降低模型的数据存储量。

1 机载模型结构

本文所建立的机载模型结构如图1所示。其中,推进系统矩阵模块是以发动机地面状态的控制量和性能参数为基准点数据采用小扰动方法获取PSM数据集,并根据发动机的主燃油流量 W_b 和尾喷管喉道面积 A_8 ,外涵分别引入中心锥、尾喷管的空气引气量 e_3 、 e_4 ,对地面PSM数据

集进行二维插值以确定模型在该工作点的PSM元素,从而根据发动机与基准点控制量的偏差量确定发动机与模型输出量之间的偏差量,并对模型的输出进行修正,该过程可以有效提升机载模型的精度。

基线模型模块是根据神经网络能以任意精度逼近任意非线性函数和突出的泛化能力来映射发动机控制量与输出性能参数之间的关系,神经网络以发动机飞行条件主燃油流量 W_b 、尾喷管喉道面积 A_8 、高度 H 、飞行马赫数 Ma 作为输入,性能参数 Y 作为输出,建立起适用于全包线全状态的机载稳态模型。机载模型通过该模块可以得到发动机在任一飞行状态下基准点的性能参数值。

自适应模块的输入是通过传感器得到的5个可测参数(风扇转速 N_f 、压气机转速 N_c 、燃烧室出口总压 p_3 、加力燃烧室出口总压 p_6 、低压涡轮进口总温 T_{45}),该模块中的状态变量模型(state variable model, SVM)是分段线性化模型,增广状态变量模型(augmented state variable model, ASVM)是将发动机退化量作为增广的状态变量扩充到状态变量模型中形成的。本文设计的退化量包括 D_f 、 D_c 、 D_b 、 D_1 ,分别表示风扇、压气机的流量退化量,高压、低压涡轮的效率退化量,设计卡尔曼滤波器对增广状态变量模型中的部件退化量进行实时估计,以提高模型的自适应性。




图1 机载稳态模型结构图

Fig.1 Diagram of on-board steady-state model structure

2 推进系统矩阵模块

PSM就是小范围内线性化的发动机对象,若

PSM线性化误差较大,则无法反映发动机参数间的数学关系。控制量与输出量之间的函数关系可以表示为

$$\Delta Y = P \times \Delta u \quad (1)$$

式中 $\Delta Y = [\Delta S_{fc}, \Delta N_f, \Delta N_c, \Delta S_{mf}, \Delta S_{mc}, \Delta F, \Delta T_4, \Delta I_r]$ 为 m 维向量, ΔY 表示发动机输出参数的偏离量, S_{fc} 表示发动机耗油率, N_f 、 N_c 分别表示风扇、压气机的转子转速, S_{mf} 、 S_{mc} 分别表示风扇、压气机的喘振裕度, F 表示发动机推力, T_4 表示涡轮前温度, I_r 表示发动机红外辐射强度; $\Delta u = [W_b, A_8, D_f, D_c, D_h, D_l, e_3, e_4]$ 为 n 维向量, 代表发动机控制量, P 为 $m \times n$ 维推进系统矩阵。

PSM 元素的获取方法是采用小扰动方法从非线性稳态发动机模型中提取。具体的提取方法是采用小偏差线性化方法, 在发动机的某一个稳态工作点, 将其中某一个控制量 (如燃油流量 W_b) 做较小的增量, 而保持其他控制量严格不变, 当发动机达到新的稳态平衡后, 将得到的新稳态

工作点的输出值减掉原稳态点的输出值, 可求得在该控制增量下, 发动机的稳态输出变化增量, 而输出变化增量与控制变化量的比值即表示相应输出参数与该控制量在 PSM 中的元素。数据归一化处理后的数学函数表示为

$$P_{ij} = \sum_j \{ \Delta Y_i / u_i \} \quad (2)$$

$$i = 1, 2, 3, \dots; \quad j = 1, 2, 3, \dots$$

式中 $\Delta Y_i = (Y_i - Y_{i0}) / Y_{id}$, $\Delta u = (u_i - u_{i0}) / u_{id}$, Y_{i0} 和 u_{i0} 分别表示发动机初始稳态点的输出量和控制量, Y_{id} 和 u_{id} 表示发动机设计点的值, Y_i 和 u_i 分别表示某一控制量变化后发动机新的控制量和输出变量。 P_{ij} 为 PSM 元素。

根据本文选取的控制变量和输出变量, 其典型的推进系统矩阵可表示为

$$\begin{bmatrix} \Delta F \\ \Delta S_{fc} \\ \Delta N_f \\ \Delta N_c \\ \Delta S_{mf} \\ \Delta S_{mc} \\ \Delta T_4 \\ \Delta I_r \end{bmatrix} = \begin{bmatrix} P_{11} & P_{12} & P_{13} & P_{14} & P_{15} & P_{16} & P_{17} & P_{18} \\ P_{21} & P_{22} & P_{23} & P_{24} & P_{25} & P_{26} & P_{27} & P_{28} \\ P_{31} & P_{32} & P_{33} & P_{34} & P_{35} & P_{36} & P_{37} & P_{38} \\ P_{41} & P_{42} & P_{43} & P_{44} & P_{45} & P_{46} & P_{47} & P_{48} \\ P_{51} & P_{52} & P_{53} & P_{54} & P_{55} & P_{56} & P_{57} & P_{58} \\ P_{61} & P_{62} & P_{63} & P_{64} & P_{65} & P_{66} & P_{67} & P_{68} \\ P_{71} & P_{72} & P_{73} & P_{74} & P_{75} & P_{76} & P_{77} & P_{78} \\ P_{81} & P_{82} & P_{83} & P_{84} & P_{85} & P_{86} & P_{87} & P_{88} \end{bmatrix} \times \begin{bmatrix} \Delta W_b \\ \Delta A_8 \\ \Delta D_f \\ \Delta D_c \\ \Delta D_h \\ \Delta D_l \\ \Delta e_3 \\ \Delta e_4 \end{bmatrix} \quad (3)$$

即用推进系统矩阵确定控制量与输出量之间的函数关系。

图2表示为发动机主燃油流量 W_b (kg/s)、尾喷管喉道面积 A_8 (m²) 的分段图, 在地面状态下确定发动机主燃油流量 W_b 、尾喷管喉道面积 A_8 范围, 将这两个控制量分别按范围 (0.4~2.7, 0.24~0.33) 均匀分段, 共包含 400 个工作点, 并给定发动机部件的退化量、外涵引气范围 (本文给定的范围都为 0~3%), 图中红色部分表示发动机处于

超温超转状态工作点。

将上述分段后的各控制量分别做小阶跃 ξ , 扰动并保持其他控制量严格不变, 根据式 (2) 进行离线获取发动机各工作点的 PSM, 则模型可以根据 W_b 、 A_8 二维插值来得到当前工作点对应的 PSM 元素。

3 基线模型模块

该模块的作用是根据发动机的飞行条件确定模型基准点的性能参数。由于神经网络具有无限逼近任意非线性函数的功能, 且拟合精度高, 本文即采用神经网络离线训练发动机模型, 映射发动机控制量与性能参数之间的关系。

神经网络是一种多层前馈神经网络, 该网络采取误差逆向传播算法进行数据训练。神经网络的数学本质是找一个满足输入到输出复杂关系的函数。神经网络主要包括信号的前向传递以及误差的反向传播两个过程。神经网络由三部分构成: 输入层 (input)、隐含层 (hidden)、输出层 (output)。文献 [31] 中证明存在一个只含有一个隐含层的神经网络能够逼近闭区间连续的任何函数。因此, 可以不用考虑隐含层层数的问题。




图2 W_b 和 A_8 分段图

Fig.2 Segmented grap of W_b and A_8

本文采用图3所示的三层神经网络,包括一个输入层、一个隐含层、一个输出层, $x_1, x_2, \dots, x_p$ 为输入层参数值, W_{pq} 、 W_{qt} 为神经元之间的连接权值, θ_p 、 θ_k 为误差。 $f_p(\theta)$ 为激活函数,负责将神经元的输入映射到输出端,一般选取S型函数(sigmoid),S型函数的函数形式为

$$f'(x) = \frac{\alpha e^{-\alpha x}}{1 + e^{-\alpha x}} = \alpha f(x) [1 - f(x)] \quad (4)$$

神经网络的输入为四个控制量 $u = [H, Ma, W_b, A_8]$, 其中 H 表示高度,输出为发动机性能参数 $Y = [W_{fc}, N_f, N_c, S_{mf}, S_{mc}, F, T_4, I_r]$ 。为了让神经网络具备映射发动机控制量与输出量之间关系的能力,采集各飞行包线、变状态下发发动机的控制量和输出量,并分别作为输入样本和输出样本通过神经网络进行离线训练。神经网络训练过程中的信号正向传播,输入信号通过隐含层作用于输出节点,经过隐含层激活函数进行非线性变换,产出输出信号,对比实际输出与期望输出,当实际的输出与期望值的输出不匹配时,则进入误差的反向传播。误差的反向传播过程将输入层逐层反转,误差分配给各层所有单元,各单元权值通过各层获得的误差进行调整。修正方法为梯度下降法,即梯度下降最快的方向修正。




图3 三层神经网络结构图

Fig.3 Diagram of three layer neural network structure

在神经网络训练中,隐含层节点数的确定非常重要,该参数的设定决定了神经网络的训练结果,神经网络在训练时出现“过拟合”现象的直接原因就是由于隐含层节点数的选取出现了问题。现阶段,国内外还没有建立出一种科学、有效可以确定隐含层节点数的方法。

文献[32]中说到一定存在最佳的隐含层节点数,针对如何找到最佳节点数,国内外学者给出了各种解决方案,提出了不少经验公式。

$$\sum_{p=0}^P C_{n_1}^p > s \quad (5)$$

其中 s 是样本量; n_1 为实验数值; P 为输入层节点数。当 $p > n_1$ 时, $\sum_{p=0}^P C_{n_1}^p = 0$ 。

$$n_1 = (P + Q)^{1/2} + a \quad (6)$$

式中 Q 为输出层节点数; a 为 1~10 之间的常数。

最终依据上述方法本文选取隐含层节点数为 9,由于神经网络数据存储量取决于隐含层的层数和隐含层的节点数,而隐含层节点数 S 可以根据输入、输出的维数 H_i 、 H_o 和式(6)进行确定。那么,当神经网络训练完后机载模型需要存储的数据量为 $H_i \times H_o \times S$,进而大大减小模型的数据存储量。

4 自适应模块

设计卡尔曼滤波器是用来估计发动机部件的退化量,卡尔曼滤波器的主要设计思想是通过将发动机部件的退化因子增广到状态变量中去,发动机可测输出参数的偏离量作为卡尔曼滤波器的输入,进而在线估计出发动机各部件的退化量,实现机载模型对发动机真实状态的实时跟踪。

发动机状态变量模型的数学表达式如下:

$$\begin{cases} \Delta \dot{x} = A \Delta x + B \Delta u \\ \Delta y = C \Delta x + D \Delta u \end{cases} \quad (7)$$

式中 $x = [N_f, N_c]$, $u = [W_b, A_8]$, $y = [N_f, N_c, p_3, p_6, T_{45}]$, $\Delta x = (x - x_b)/x_b$, $\Delta u = (u - u_b)/u_b$, $\Delta y = (y - y_b)/y_b$, A 、 B 、 C 、 D 为适维矩阵,下标 b 表示控制量变化前发动机的初始稳态参数。由于系统误差和测量误差的影响,将式(7)改为如下形式:

$$\begin{cases} \Delta \dot{x} = A \Delta x + B \Delta u + L \Delta \eta + w \\ \Delta \dot{y} = C \Delta x + D \Delta u + M \Delta \eta + v \end{cases} \quad (8)$$

式中 L 、 M 都为适维矩阵, $\Delta \eta$ 表示发动机部件的退化量, w 为系统噪声, v 为测量噪声。 w 和 v 为不相关的服从正态分布的零高斯白噪声,其协方差阵分别为 Q 和 R 。本文取风扇流量退化 D_f 、压气机流量退化 D_c 、高压涡轮效率退化 D_h 、低压涡轮效率退化 D_l 来模拟发动机的部件退化。由于 $\Delta \eta$ 无法直接获取,这里在式(8)的基础上将四个退化量作为增广的状态量,并采用估计算法来求取,得到的增广状态变量形式如下:

$$\begin{cases} \begin{bmatrix} \Delta \dot{x} \\ \Delta \dot{\eta} \end{bmatrix} = \begin{bmatrix} A & L \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \Delta \hat{x} \\ \Delta \hat{\eta} \end{bmatrix} + \begin{bmatrix} B \\ 0 \end{bmatrix} \Delta u + w \\ \Delta y = [C \quad M] \begin{bmatrix} \Delta \hat{x} \\ \Delta \hat{\eta} \end{bmatrix} + Du + v \end{cases} \quad (9)$$

根据式(9)以卡尔曼滤波器作为状态观测器,

可得到如下全维观测器方程:

$$\begin{cases} \begin{bmatrix} \Delta \dot{x} \\ \Delta \dot{\eta} \end{bmatrix} = \begin{bmatrix} A & L \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \Delta \hat{x} \\ \Delta \hat{\eta} \end{bmatrix} + \left(\begin{bmatrix} B \\ 0 \end{bmatrix} - K [C \quad M] \right) \Delta u + K \Delta y \\ \Delta y = [C \quad M] \begin{bmatrix} \Delta \hat{x} \\ \Delta \hat{\eta} \end{bmatrix} + Du \end{cases} \quad (11)$$

式中 $K = J [C \quad M]^T R^{-1}$ 顶标 $\wedge$ 表示估计值, 为卡尔曼滤波器增益阵, J 为如下 Riccati 方程的解:

$$\begin{bmatrix} A & L \\ 0 & 0 \end{bmatrix} J + J \begin{bmatrix} A_b & I \\ 0 & 0 \end{bmatrix}^T - J [C \quad M]^T R^{-1} [C \quad M] J + J + Q = 0 \quad (12)$$

5 数值仿真

5.1 精度验证

机载模型的精度和实时性是十分关心的问题, 所以为了更好地验证该方法应用到航空发动机建模的效果, 在这一节对本文建立的 NN-PSM 模型与 CPSM 进行精度对比。



ϵ 表示 NN-PSM、CPSM 分别与真实发动机之间的相对误差, 即 $\epsilon = \frac{v_n - v_c}{v_c}$, v_n 表示 NN-PSM、CPSM 的参数值, v_c 表示真实发动机参数值。

图 4、图 5 为 NN-PSM、CPSM 分别在典型巡航包线高度 $H=8.0 \sim 13$ km, 飞行马赫数 $Ma=0.7 \sim 1.5$ 下随机选取 2 100 个不同高空工作点的

$$\begin{cases} \begin{bmatrix} \Delta \dot{x} \\ \Delta \dot{\eta} \end{bmatrix} = \begin{bmatrix} A & L \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \Delta \hat{x} \\ \Delta \hat{\eta} \end{bmatrix} + \begin{bmatrix} B \\ 0 \end{bmatrix} \Delta u + K(\Delta y - \Delta \hat{y}) \\ \Delta y = [C \quad M] \begin{bmatrix} \Delta \hat{x} \\ \Delta \hat{\eta} \end{bmatrix} + Du \end{cases} \quad (10)$$

进一步表示为

误差仿真结果。图 6、图 7 为 NN-PSM、CPSM 在 $H=9.0$ km, $Ma=1.0$, 油门杆角度 $\alpha_{pla}=20^\circ \sim 100^\circ$, $A_8=0.24 \sim 0.33$ m² 下选取 2 100 个不同状态工作点的误差仿真结果。表 1、表 2 的数据表示发动机各性能参数的平均误差。从图 4~图 7 可以看出本文所建立的 NN-PSM 模型在大包线、变状态下各性能参数的最大误差为 1%, 相比于 CPSM 精度有了很大提升, 表明 NN-PSM 模型的性能参数更加接近于真实发动机。由表 1、表 2 可以看出风扇喘振裕度的平均误差远低于 CPSM 的 1.323%、2.07%, 而推力、耗油率、高低压转子转速的平均误差相较于 CPSM 都有大幅的降低, 同时本模型可用于表征发动机的红外辐射强度, 该参数的最大误差为 2%, 平均误差在 0.6% 左右, 同样表现出很好的精度效果。












图4 NN-PSM模型在大包线范围内的工作点精度测试

Fig.4 NN-PSM model operating point accuracy test in the range of lager envelope







图5 CPSM在大包线范围内工作点的精度测试
Fig.5 CPSM model operating point accuracy test in the range of lager envelope

5.2 自适应验证

为验证基于卡尔曼滤波器的机载模型的准确性和实时性,在 $H=0\text{ km}$, $Ma=0$,油门杆处于 70° 的地面工作状态下,进行了发动机单部件退化和多部件同时退化的情况下机载模型对发动机推力跟踪效果仿真验证,验证结果如图8所示,纵坐标 F 表示推力,图中的“real”曲线表示发动机实际推力,“KF”曲线表示机载模型基于卡尔曼滤波器修正后的推力,“ND”曲线表示发动机不发生部件退化时的推力。图8(a)~图8(d)分别表示风扇、压气机、高压涡轮、低压涡轮的单部件退化时的推力跟踪情况,图8(e)表示4个部件同时退化时的发动机推力跟踪情况。







图 6 NN-PSM 模型变状态工作点的精度测试

Fig.6 Accuracy test of NN-PSM model variable state operating point






图 7 CPSM 变状态工作点的精度测试
Fig.7 Accuracy test of CPSM model variable state
operating point

在仿真过程中,设置单部件与多部件的退化量均为 2%。从图 8 中可以看出,在发动机的部件发生退化时,发动机的推力有明显的下降,这也正是发动机的部件退化特性,而本文所建立的机载模型在发动机部件发生退化时能够在 2~4 s 内快速地跟踪上发动机的推力,并且当发动机出现单部件退化时,机载模型与发动机推力的稳态误差不超过 0.3%,达到了较高的精度。而当发动机 4 个部件同时发生退化时,模型可以在 5~6 s 内跟

表 1 大包线范围内工作点的平均误差
Table 1 Averaged error of operating point in the range of lager envelope

模型	平均误差/%							
	S_{fc}	N_f	N_c	S_{mf}	S_{mc}	F	T_4	I_r
NN-PSM	0.496	0.206 3	0.196	0.435	0.284	0.283 2	0.166 9	0.66
CPSM	0.762 3	1.111 8	0.368	1.323	0.28	0.768 9	0.696 1	

表 2 变状态工作点的平均误差

Table 2 Averaged error of variable state operating point

模型	平均误差/%							
	S_{fc}	N_f	N_c	S_{mf}	S_{mc}	F	T_4	I_r
NN-PSM	0.365 9	0.247 1	0.149	0.553	0.163	0.294	0.166	0.548
CPSM	0.944 7	0.668 2	0.128	2.07	0.367	0.933	0.307	




图 8 地面状态下发动机部件退化估模型推力跟踪精度验证

Fig.8 Verification of thrust tracking accuracy of engine component degradation estimation model under ground conditions

踪上发动机的推力,并且稳态误差不超过 0.5%,机载模型同样可以快速跟踪上发动机的推力。

5.3 实时性验证

如图 9 所示,在 $H=8.0\sim 13.0\text{ km}$, $Ma=0.7\sim 1.5$ 的飞行包线下随机选取 2 000 各不同状态工作点并记录每一个工作点的运行时间。表 3 为两个模型平均每次运行时间。本程序的运行环境为 Windows 10 家庭中文版的操作系统,CPU 为主频为 2.60 GHz 的 Inter(R)Core(TM)i7-10750H,内存为 16.0 GB。




图 9 大包线工作点运行时间

Fig.9 Running time of operating points of large envelop

由图 9 可以看出,CPSM 的最大运行时间为 0.002 84 ms,而 NN-PSM 模型的最大运行时间为 0.029 31 ms,实时性有了大幅的提升,同时由表 3 可知本文所建立的机载模型的相较于 CPSM 实时性提升超过 10 倍。说明本文所建立的机载稳态模型在提高精度的同时可以大幅提高模型的实时性,也能使得该机载模型可以更好地运用于实际应用。

表 3 模型平均运行时间

Table 3 Average computing time of model	
模型	平均运行时间/ms
NN-PSM	0.002 09
CPSM	0.028 07

6 结 论

通过将本文建立的发动机机载稳态模型与 CPSM 进行比较研究,可以得出以下结论:

- 1) 在精度方面相比于 CPSM 有明显的提高,各性能参数的最大误差为 1%,平均误差在 0.6% 左右。
- 2) 在实时性方面由于不需要进行非线性计算相较于 CPSM 提升了 10 倍左右,且模型随着控制量维数的增加,本文所建立模型的数据存储

量小。
3) 本文提出的建模方法具有普遍意义,对建模相关的参数变化范围没有要求。如果应用到实际工程中,可以进一步扩大包线的状态范围,并根据实际型号的限制要求确定控制量范围。

参考文献:

[1] 孙健国.面向 21 世纪航空动力控制展望[J].航空动力学报,2001,16(2):97-102.
SUN Jianguo.Prospects for actual aviation power contro control facing the 21st century[J].Journal of Aerospace Power,2001,16(2):97-102.(in Chinese)

[2] 袁鸞.发动机自适应建模及神经网络控制[D].南京:南京航空航天大学,2004.
YUAN Yang.Aeroengine adaptive modeling and neural network control[D].Nanjing:Nanjing University of Aeronautics and Astronautics,2004.(in Chinese)

[3] 何凤林.变循环发动机直接推力控制方法研究[D].南京:南京航空航天大学,2019.
HE Fenglin.Research on direct thrust control method of variable cycle engine[D].Nanjing:Nanjing University of Aeronautics and Astronautics,2019.(in Chinese)

[4] 袁春飞,姚华,刘源.基于机载自适应模型的航空发动机控制[J].推进技术,2006,27(4):354-358.
YUAN Chunfei,YAO Hua,LIU Yuan.On-board adaptive model based control of aero-engine[J].Journal of Propulsion Technology,2006,27(4):354-358.(in Chinese)

[5] SILVA V V R,KHATIB W,FLEMING P J.Performance optimization of gas turbine engine[J].Engineering Application of Artificial Intelligence,2005,18(5):575-583.

[6] SIMON D L,RINEHART A W.A model-basted anomaly detection approach for analyzing streaming aircraft engine measurement data[R].ASME Paper GT2014-27172,2014.

[7] RINEHART A W,SIMON D L.An integrated architecture for aircraft engine performance monitoring and fault diagnostics:engine test result[R].AIAA 2014-3924,2014.

[8] MAY R D,CSANK J,LAVELLE T M,et al.A high-fidelity simulation of a generic commercial aircraft engine and controller[R].AIAA 2010-6630,2010.

[9] GILYARD G,ORME J.Subsonic flight test evaluation of a performance seeking control algorithm on an F-15 air-plane [R].AIAA 92-1821,1992.

[10] LIN K M,LIN C J.A study on reduced support vector machines[J].IEEE Transsactions on Neural Networks,2003,14(6):1449-1459.

[11] VLOPONI A.Enhanced self-tuning on-board real-time model (ESTROM) for aircraft engine performance health tracking[R].NASA/CR 2008-215272,2008.

- [12] SIMON D L. An integrated architecture for onboard aircraft engine performance trend monitoring and gas path fault diagnostics[R]. NASA TM 2010-216358, 2010.
- [13] 李业波, 李秋红, 黄向华, 等. 航空发动机气路部件故障融合诊断方法研究[J]. 航空学报, 2014, 35(6): 1612-1622.
LI Yebo, LI Qiuhong, HUANG Xianghua, et al. Research on fault fusion diagnosis method of aero-engine pneumatic components[J]. Acta Aeronautica et Astronautica Sinica, 2014, 35(6): 1612-1622. (in Chinese)
- [14] 胡鹤翔. 基于改进 SVM 的航空发动机齐鲁故障诊断研究[D]. 天津: 中国民航大学, 2019.
HU Hexiang. Research on fault diagnosis of aeroengine gas path based on improved SVM[D]. Tianjin: China Civil Aviation University, 2019. (in Chinese)
- [15] 程都. 基于神经网络的航空发动机模型自适应修正[D]. 辽宁大连: 大连理工大学, 2019.
CHENG Du. Adaptive modification of aero-engine model base on neural network[D]. Dalin Liaoning: Dalin University of Technology, 2019. (in Chinese)
- [16] 王健康, 张海波, 孙健国, 等. 基于复合模型及 FSQP 算法的发动机性能寻优控制试验[J]. 推进技术, 2012, 33(8): 579-590.
WANG Jiankang, ZHANG Haibo, SUN Jianguo, et al. Research on model-based optimal control for aero-engine[D]. Journal of Propulsion Technology, 2012, 33(8): 579-590. (in Chinese)
- [17] 鲁峰, 黄金泉, 吕怡秋, 等. 基于非线性自适应滤波的发动机气路部件健康诊断方法[J]. 航空学报, 2013, 34(11): 2529-2538.
LU Feng, HUANG Jinquan, LÜ Yiqiu, et al. Aircraft engine gas-path components health diagnosis based on nonlinear adaptive filters[J]. Acta Aeronautica et Astronautica Sinica, 2013, 34(11): 2529-2538. (in Chinese)
- [18] 鲁峰, 黄金泉, 陈煜. 航空发动机部件性能故障融合诊断方法研究[J]. 航空动力学报, 2009, 24(7): 1649-1653.
LU Feng, HUANG Jinquan, CHEN Yu. Research on performance fault fusion diagnosis of aero-engine component[J]. Journal of Aerospace Power, 2009, 24(7): 1649-1653. (in Chinese)
- [19] 王海泉, 欧阳玲, 黄杰. 涡扇发动机机载自适应模型及性能退化估计[J]. 计算机仿真, 2012, 29(10): 76-80.
WANG Haiquan, OUYANG Ling, HUANG Jie. Research on airborne real-time adaptive model of aero-engine and performance degenerate estimate[J]. Computer Simulation, 2012, 29(10): 76-80. (in Chinese)
- [20] 王修岩, 李萃芳, 高铭阳, 等. 基于 SVM 和 SNN 的航空发动机气路故障诊断[J]. 航空动力学报, 2014, 29(10): 2493-2498.
WANG Xiuyan, LI Cuifang, GAO Mingyang, et al. Fault diagnosis of aero-engine gas path based on SNM and SNN[J]. Journal of Aerospace Power, 2014, 29(10): 2493-2498. (in Chinese)
- [21] 皮骏, 马圣, 张奇奇, 等. 基于改进果蝇算法优化的 GRNN 航空发动机排期温度预测模型[J]. 航空动力学报, 2019, 34(1): 9-15.
PI Jun, MA Sheng, ZHANG Qiqi, et al. Aero-engine exhaust gas temperature prediction model based on IFOA-GRNN[J]. Journal of Aerospace Power, 2019, 34(1): 9-15. (in Chinese)
- [22] 李永进, 张海波, 张天宏. 一种考虑非线性余项的机载发动机自适应模型建立及其在寻优控制中的应用[J]. 推进技术, 2016, 37(1): 172-180.
LI Yongjin, ZHANG Haibo, ZHANG Tianhong. Establishment and application in performance seeking control of an on-board adaptive aero-engine model considering nonlinear remainders[J]. Journal of Propulsion Technology, 2016, 37(1): 172-180. (in Chinese)
- [23] 李永进, 徐植桂, 张海波. 一种超声速状态下机载推进系统模型的建模方法[J]. 航空动力学报, 2017, 32(5): 1273-1279.
LI Yongjin, XU Zhigui, ZHANG Haibo. A novel method for on-board propulsion system modeling under supersonic state[J]. Journal of Aerospace Power, 2017, 32(5): 1273-1279. (in Chinese)
- [24] 丁凯峰, 樊思齐. 基于 RBF 网络的航空发动机辨识模型[J]. 航空动力学报, 2000, 15(2): 205-208.
DING Kaifeng, FAN Siqi. Aero-engine identification model based on RBF network[J]. Journal of Aerospace Power, 2000, 15(2): 205-208. (in Chinese)
- [25] ORME J S, GILYARD G B. Preliminary supersonic flight test evaluation of performance seeking control[R]. AIAA 93-1821, 1993.
- [26] 李永进, 贾爽龙, 张海波, 等. 基于稀疏编码器的发动机机载模型建模方法研究[J]. 推进技术, 2017, 38(6): 1209-1217.
LI Yongjin, JIA Shuanglong, ZHANG Haibo, et al. Research on modeling method of on-board engine model based on sparse auto-encoder[J]. Journal of Propulsion Technology, 2017, 38(6): 1209-1217. (in Chinese)
- [27] MAINE T, GILYARD G, LAMBERT H. A preliminary evaluation of an F100 engine parameter estimation process using flight data[R]. Orlando, US: 26th Joint Propulsion Conference, 1990.
- [28] NOBBS S, JACOBS S, DONAHUE D. Development of the full-envelope performance seeking control algorithm[R]. Nashville, US: 28th Joint Propulsion Conference and Exhibit, 1992.
- [29] ZHENG Qiangang, WANG Yong. Aero-engine dynamic model based on an improved compact propulsion system dynamic model[J]. Journal of Systems and Control Engineering, 2020, 235(7): 1036-1045.

- [30] 金崇文,郑前钢,张海波,等. 基于复合推进系统动态模型-状态变量模型的航空发动机直接推力预测控制[J]. 推进技术, 2022, 43(1):348-357.
- JIN Chongwen, ZHENG Qiangang, ZHANG Haibo, et al. Direct thrust predictive control of aeroengine base on compact propulsion system dynamic model-state variable model [J]. Journal of Propulsion Technologym, 2022, 43(1):348-357. (in Chinese)
- [31] AZGHADI S M R, SHAHHOSSEINI H. Gender classification based on feed forward back propagation neural network. [C]//International Conference on Artificial Intelligence and Innovations: From Theory to Applications. Athens, Greece: NASA, 2007:299-304.
- [32] 王嵘冰,徐艳红,李波,等. BP神经网络隐含层节点数确定方法研究[J]. 计算机技术与发展, 2018, 28(4):31-35.
- WANG Rongbing, XU Yanhong, LI Bo, et al. Research on method of hidden layer nodes in BP neural network[J]. Computer Technology and Development, 2018, 28(4):31-35. (in Chinese)

(编辑:陈 越)