

文章编号:1000-8055(2013)09-2145-10

基于喘振裕度估计模型的发动机高稳定性控制

王健康^{1,2}, 张海波¹, 陈 可¹, 孙丰勇¹, 周 晓¹

(1. 南京航空航天大学 能源与动力学院, 南京 210016;

2. 中国空间技术研究院 北京控制工程研究所, 北京 100190)

摘 要: 为解决超机动飞行中发动机喘振裕度不可测量的难题, 提出一种发动机喘振裕度的建模方法。喘振裕度的模型分为常规飞行时的无畸变模型与超机动飞行时的损失量模型两部分。无畸变模型是基于喘振裕度特征选择算法筛选最优模型输入, 以非线性拟合方法建模实现; 损失量模型则基于在线攻角预测模型实时评估发动机进口畸变度, 进而计算获得。而后利用上述估计模型对发动机的稳定性进行实时预测, 在不改变发动机原控制回路的基础上, 对涡轮落压比控制指令进行喘振损失补偿, 实现高稳定性控制。最后, 通过大攻角机动飞行的数字仿真, 验证了上述方案可以准确控制发动机喘振裕度在 11%~13%, 保证了发动机工作的稳定性和高效性。

关 键 词: 超机动飞行; 发动机; 喘振裕度; 估计模型; 稳定性控制

中图分类号: V231

文献标志码: A

High stability control of engine based on surge margin estimation model

WANG Jian-kang^{1,2}, ZHANG Hai-bo¹, CHEN Ke¹,
SUN Feng-yong¹, ZHOU Xiao¹

(1. College of Energy and Power Engineering,
Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

2. Beijing Institute of Control Engineering,
China Academy of Space Technology, Beijing 100190, China)

Abstract: In order to solve the immeasurable problem of engine surge margin in super-maneuvering flight, an approach to build an engine surge margin estimation model was proposed. The modeling process consists of two parts: surge margin benchmark value model under routine flight condition and surge margin loss value model under super-maneuvering flight condition. The benchmark value model was developed using nonlinear fitting method, and the input of model was fixed by surge margin feature selection algorithm. The surge margin loss value was obtained by an angel of attack predictive model which can be used to real-timely estimate engine inlet distortion index. Based on the predictive messages of surge margin estimation model, a scheme of high stability engine control through correcting turbine expansion ratio command was designed for super-maneuvering flight. In this way, the

收稿日期: 2012-09-24

网络出版地址: http://www.cnki.net/kcms/detail/11.2297.V.20130926.1103.201309.2145_020.html

基金项目: 国家自然科学基金(51006052); 航空科学基金(2010ZB52011)

作者简介: 王健康(1986—), 男, 江苏沭阳人, 工程师, 博士, 主要从事飞行器控制与测试研究。

E-mail: wangjiankang16@163.com

通讯作者: 张海波(1976—), 男, 山东潍坊人, 副教授, 博士, 主要从事飞行/推进系统综合建模与控制研究。

E-mail: zh_zhbb@126.com

great advantage is that the original closed-loop doesn't need changes. Finally, some surer-maneuvering flight missions with large angle of attack were imitated. The simulation results show that surge margin ranges between 11% and 13% with above stability control concept, ensuring that engine can work safely and efficiently.

Key words: super-maneuvering flight; engine; surge margin; estimation model; stability control

超机动能力是现代战斗机的必备技术之一,但在过失速状态,发动机需工作在大攻角和侧滑角的条件下,此时进口畸变严重,致使发动机性能降低、稳定工作裕度减少,严重时甚至会产生喘振等不稳定工作现象^[1]. 针对这一难题,美国 NASA 于 1993 年开展了发动机高稳定性控制(high stability engine control, HISTEC)研究,主要利用压缩部件的压比损失来近似表征喘振裕度损失,而后通过设计先进控制规律及时修正风扇及压气机的瞬态工作线,以保证发动机足够的稳定裕度^[1-3]. 近年来,主动失速/喘振控制作为一种非常规的控制方法也得到了一定的研究^[4-6],该技术主要基于失速先兆与相关性测量来进行发动机主动稳定性控制(如脉冲切油等),本质上属于限制保护控制的范畴,在与主控制回路协调工作以及充分发挥发动机性能潜力方面还存在一定的不足. 国内对 HISTEC 的研究较少,王立峰等^[7-8]以发动机进口畸变时可通过风扇喘振压比损失进行补偿,使喘振裕度回到未畸变状态为思路,设计了发动机稳定性控制器,该方案虽能保证发动机的稳定性,但在机动过程中会有喘振裕度过大现象,发动机潜力不能得到充分的发挥.

如果在超机动飞行条件下能实时预测发动机的喘振裕度,通过 HISTEC 来限制喘振裕度的范围,控制发动机工作线与喘振边界线之间始终保持一定的距离,发动机即可始终处于高效、稳定的工作状态. 袁春飞与陈霆昊等^[9-10]提出了一种直接喘振裕度控制的方法,即通过实时估算喘振裕度并将其加入控制回路中作为被控量,来实现对喘振裕度的直接控制. 很明显,这种控制形态更为高效,但其先决条件是必须对喘振裕度进行快速准确的估计. 而建立发动机喘振裕度估计模型一直是防喘/消喘控制中的难题,文献^[10]中将喘振裕度分为畸变时的喘振裕度损失量和常规飞行时的未畸变值两部分来分别计算,具有一定的借鉴价值,但其采用等换算空气流量的思路求取喘振裕度(实际应取等换算转速线),通过压缩部件压比来直接计算,即将喘振裕度看作可测量,这种方

法在低速时存在一定的局限性. 再者,传统的非线性拟合等方法均凭经验采用飞行高度、马赫数、主燃油量、喷口面积等作为模型输入,经笔者研究这些参数与喘振裕度的相关性并非紧密,故很难实现喘振裕度的准确辨识.

本文以某型双轴混合排气带加力的涡扇发动机为研究对象. 首先,对处于正常飞行状态的发动机喘振裕度估计模型进行研究,通过设计喘振裕度特征选择算法确定与喘振裕度相关性最强的发动机部分可测变量,用其作为未畸变时喘振裕度模型的输入,而后基于 BP(back propagation)神经网络预测发动机在该状态下的喘振裕度值;其次,当发动机处于进气畸变状态时,通过设计在线攻角预测模块实时估计进气畸变度,而后将其转化为喘振压比损失量,进而构建喘振裕度损失量的预测模型;最后,结合喘振裕度未畸变时的预测值和畸变时的畸变损失量,即可准确估计出在发动机进气畸变状况下的喘振裕度.

而对于 HISTEC,则通过首先确定发动机高效、稳定工作的喘振裕度范围,而后利用上述喘振裕度估计模型的预测信息实时判断发动机的工作状态,进而实施控制. 如喘振裕度预测值显示发动机工作裕度适当,则保持发动机控制指令不变;反之,若显示发动机的工作裕度过小或过大,则根据压缩部件的喘振压比损失比例,计算出发动机的涡轮落压比损失量,进而在发动机原控制回路中对其控制指令进行补偿,最终提升发动机的稳定性或工作效率. 如此,便可在不改变发动机原控制回路的基础上实现 HISTEC,相比与文献^[7, 10]需另单独设计高稳定性控制器,该控制方案更具优势及工程实用性.

1 设计原理

在发动机部件级模型中,通常采用如下公式来表示发动机压缩部件的喘振裕度^[11]:

$$S_m = \frac{\pi_s / W_{\text{cor},s} - \pi_o / W_{\text{cor},o}}{\pi_o / W_{\text{cor},o}} = \frac{\pi_s}{\pi_o} \cdot \frac{W_{\text{cor},o}}{W_{\text{cor},s}} - 1 \quad (1)$$

式中 S_m 表示发动机压缩部件喘振裕度, π 表示压比, W_{cor} 表示换算空气流量, 下标 s, o 分别代表喘振边界值和工作线上的值. 在发动机使用过程中遇到进气道出口流场不均匀或总温突升等情况, 则会使得发动机喘振边界下移或工作线上移, 引起喘振裕度损失. 以喘振边界下移为例, 则有^[11]

$$\Delta S_m = \frac{\pi_s/W_{cor,s} - \pi_l/W_{cor,l}}{\pi_o/W_{cor,o}} \quad (2)$$

式中 ΔS_m 表示喘振裕度损失量, 下标 l 表示下移的稳定边界值. 而此时, 由于稳定边界线下移, 发动机压缩部件的压比也必然产生了一定的损失, 该损失量 Δp_{rs} 的表达如下^[11]:

$$\Delta p_{rs} = \frac{\pi_s/W_{cor,s} - \pi_l/W_{cor,l}}{\pi_o/W_{cor,o}} \quad (3)$$

结合式(1)~式(3), 喘振裕度损失量可表示为

$$\Delta S_m = \Delta p_{rs}(1 + S_m) \quad (4)$$

由上述各式可知, S_m 和 ΔS_m 均为不可测量参数, 在发动机发生进口畸变情况下, 如果能准确估计无畸变状态下的 S_m , 并计算出喘振压比损失 Δp_{rs} , 则畸变时的喘振裕度即可表达如下:

$$S_{m,d} = S_m - \Delta S_m \quad (5)$$

本文利用预测手段, 基于当前及历史时刻的状态信息分别设计求取下一时刻 S_m 与 ΔS_m 的方法, 来建立适用于超机动飞行的发动机喘振裕度估计模型, 并进一步实现 HISTEC, 结构框图如图1所示, 图中 k 为当前时刻, α 为飞行攻角, X 为喘振裕度模型的输入, S' 为发动机高效稳定工作的裕度范围, $\Delta\pi'$ 为涡轮落压比补偿量, λ 为压比转换系数, n_t 和 n_c 分别为风扇和压气机相对换算转速, W_{fb} , W_{fa} , A_s 分别为主燃油量、加力燃油量和

尾喷口喉道面积. 其设计思路如下:

首先, 在通常的超机动飞行包线范围内(高度为 3~7 km, 马赫数为 0.3~0.7), 基于 BP 神经网络训练发动机无进气畸变状态下的喘振裕度模型, 以此来估计下一时刻的喘振裕度. 在此之前, 利用最小二乘支持向量回归机(LSSVR)设计喘振裕度特征选择算法, 以每个参数对喘振裕度的贡献程度大小为准, 筛选出一组最具价值的发动机可测参数作为模型输入.

其次, 对于进气畸变时喘振裕度损失量的求取, 则是通过设计攻角预测模型来评估下一时刻的畸变度, 本文采用 D_{c60} 作为进气畸变指标^[12], 进而计算出喘振压比损失 Δp_{rs} , 再由式(4)求取喘振裕度损失量 ΔS_m . 而且, 本文通过设计在线滚动稀疏最小二乘支持向量回归机(OSP-LSSVR)来构建在线攻角预测模型, 其最大优势是可根据实时攻角信息完成预测模型的在线自我更新, 利用最近时刻的有效信息实现较高精度的预测, 且具有很好的实时性与鲁棒性, 克服了文献[9-10]离线训练模型样本固定且有限、大包线范围内难以实现的不足.

最后, 在 HISTEC 中根据预测值 $S_{m,d}$ 实时判断发动机喘振裕度. 一般发动机正常状态喘振裕度为 15%~25%^[11], 若充分发挥发动机性能潜力从而保持较高的效率, 喘振裕度为 10%~15%^[9], 本文设定发动机高效稳定工作裕度 S' 为 11%~13%, 若 $S_{m,d}$ 超出 S' 范围, 则认为下一时刻的机动操作影响到了发动机稳定性或裕度过大, 便通过对控制回路中涡轮落压比 π_t 的控制指令进行相应补偿, 使得发动机工作点与喘振边界间保持




图1 发动机稳定性控制结构图

Fig. 1 Sketch map of engine stability control

适当距离,从而实现超机动飞行时发动机的稳定性控制。

下面针对上述3部分研究内容分别进行设计和仿真验证。

2 无畸变喘振裕度模型

本节首先基于LSSVR设计了喘振裕度特征选择算法,以筛选一组最具价值的可测参数为输入;而后采用对非线性映射具有任意逼近能力的神经网络进行模型设计。

2.1 LSSVR 算法

假定给定一组训练数据集 $\{(\mathbf{x}_i, y_i)\}_{i=1}^N$,其中 $\mathbf{x}_i \in R^n, y_i \in R, N$ 为训练样本的规模,则可得最小二乘支持向量回归机模型^[13]

$$\begin{aligned} \min_{\mathbf{w}, e_i} J(\mathbf{w}, e_i) &= \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{\gamma}{2} \sum_{i=1}^N e_i^2 \\ \text{s. t. } y_i &= \mathbf{w}^T \varphi(\mathbf{x}_i) + b + e_i \\ i &= 1, \dots, N \end{aligned} \quad (6)$$

式中 e_i 为模型输出误差; $\mathbf{w}$ 为高维特征空间的权矩阵; $\gamma \in R^+$ 为惩罚因子; $\varphi(\cdot)$ 为输入空间 R^n 到高维特征空间的非线性映射; b 为偏置量。构建上述优化问题的Lagrange函数如下:

$$\begin{aligned} L(\mathbf{w}, b, e_i, \alpha_i) &= \\ J - \sum_{i=1}^N \alpha_i [\mathbf{w}^T \varphi(\mathbf{x}_i) + b + e_i - y_i] \end{aligned} \quad (7)$$

式中 α_i 为Lagrange乘子。则式(6)的KKT(Karush-Kuhn-Tucker)条件为

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 \rightarrow \mathbf{w} = \sum_{i=1}^N \alpha_i \varphi(\mathbf{x}_i) \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^N \alpha_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 \rightarrow \alpha_i = \gamma e_i \\ \frac{\partial L}{\partial \alpha_i} = 0 \rightarrow \mathbf{w}^T \varphi(\mathbf{x}_i) + b + e_i - y_i = 0 \end{cases} \quad (8)$$

在消去 e_i 和 $\mathbf{w}$ 后,可得线性系统

$$\begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \mathbf{K} \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{Y} \end{bmatrix} \quad (9)$$

式中 $\mathbf{Y} = [y_1, y_2, \dots, y_N]^T; \boldsymbol{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_N]^T; \mathbf{1} = [1_1, 1_2, \dots, 1_N]^T; \mathbf{K}$ 中元素 $K_{i,j} = k(\mathbf{x}_i, \mathbf{x}_j) + \delta_{i,j}/\gamma$,其中 $\delta_{i,j} = \begin{cases} 1 & i=j \\ 0 & i \neq j \end{cases}, k(\cdot, \cdot)$ 为核函数。解式(9)即可求得 $\boldsymbol{\alpha}, b$,进而给定一个新的输入变量 $\mathbf{x}$,可得

$$f(\mathbf{x}) = \sum_{i=1}^N \alpha_i k(\mathbf{x}, \mathbf{x}_i) + b \quad (10)$$

2.2 喘振裕度特征选择

对于无畸变的喘振裕度模型,式(10)中的 $f(\mathbf{x})$ 即为其估计值, $\mathbf{x}$ 为模型输入,因而 $\mathbf{x}$ 的维数必须加以确定。首先,结合式(7)和式(8),得到如下不带约束的Wolfe对偶优化问题^[13]:

$$\begin{aligned} \min \left\{ \bar{L}(b, \boldsymbol{\alpha}) = \left[\frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j k(\mathbf{x}_i, \mathbf{x}_j) + \right. \right. \\ \left. \left. \frac{1}{2\gamma} \sum_{i=1}^N \alpha_i^2 - \sum_{i=1}^N \alpha_i y_i + b \sum_{i=1}^N \alpha_i \right] \right\} \end{aligned} \quad (11)$$

进而,对式(11)可进行如下等价变形:

$$\begin{aligned} \min \left\{ \bar{L}(b, \boldsymbol{\alpha}) = \left[\frac{1}{2} [b \quad \boldsymbol{\alpha}^T] \begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \mathbf{K} \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} - \right. \right. \\ \left. \left. [b \quad \boldsymbol{\alpha}^T] \begin{bmatrix} 0 \\ \mathbf{Y} \end{bmatrix} \right] \right\} \end{aligned} \quad (12)$$

再令 $\frac{d\bar{L}}{d\boldsymbol{\alpha}} = 0$,其中 $\bar{\boldsymbol{\alpha}} = [b, \boldsymbol{\alpha}^T]^T$,则有

$$\begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \mathbf{K} \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ \mathbf{Y} \end{bmatrix} \quad (13)$$

将式(13)代入式(12)中,则可得最优值 $\bar{L}^*$

$$\begin{aligned} \bar{L}^* &= -\frac{1}{2} \begin{bmatrix} 0 & \mathbf{Y}^T \end{bmatrix} \begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \mathbf{K} \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ \mathbf{Y} \end{bmatrix} = \\ &= -\frac{1}{2} \begin{bmatrix} 0 & \mathbf{Y}^T \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = -\frac{1}{2} \mathbf{Y}^T \boldsymbol{\alpha} \end{aligned} \quad (14)$$

在计算过程中,若 $\bar{L}$ 取得最优值 $\bar{L}^*$,则此时的喘振裕度估计精度最高,若将输入向量 $\mathbf{x}$ 中的第 i 个参数移除,则最优值变为

$$\bar{L}^*(i) = -\frac{1}{2} \mathbf{Y}^T \boldsymbol{\alpha}(i)$$

式中 $\boldsymbol{\alpha}(i)$ 为移除第 i 个变量后式(13)的解。由此,可设计如下准则^[13],即根据对喘振裕度的影响程度来对 $\mathbf{x}$ 中各个参数进行排序

$$\Delta(i) = |\mathbf{Y}^T [\boldsymbol{\alpha} - \boldsymbol{\alpha}(i)]| \quad (15)$$

对于 $\mathbf{x}$ 中第 i 个和第 j 个两个不同参数,如果 $\Delta(i)$ 的值小于 $\Delta(j)$,则说明第 i 个参数对最优值 $\bar{L}^*$ 的贡献程度不及第 j 个参数。通过 $\Delta(i)$ 序列,即可每次剔除一个对喘振裕度影响最小的参数。最终,本文在不同飞行高度和马赫数下通过对油门杆角度充分激励,共采集3816组动态数据用于喘振裕度特征选择,并将与风扇及压气机喘振裕度相关的21个发动机可测参数作为筛选范围。该筛选过程如图2(a)、图2(b)所示。

图2中横轴上的每个“特征选择次序”对应图中一个黑点,该黑点表示其对应的纵轴参数在该

步筛选中被舍弃,越早舍弃说明该参数的价值越小,其中 H 为飞行高度, Ma 为马赫数, T, p, τ, π 分别为总温、总压、温比和压比,下标 2, 22, 23, 25, 3 分别表示风扇进口截面、风扇出口截面、风扇引气截面、压气机进口截面、压气机出口截面。从而依次排出对喘振裕度贡献最大的参数如下:

风扇喘振裕度

$$T_{22} > p_2 > n_t > p_3 > W_{fb} > T_3 > n_c > T_2 > A_8 > \dots$$

压气机喘振裕度

$$n_c > T_3 > \pi_c > p_3 > T_{22} > p_2 > A_8 > W_{fb} > n_t > \dots$$

以尽量使用较少的传感器以及简化训练模型为原则,在上述两组参数中仅选用前 5 个相关性较强的参数分别作为模型的输入,即风扇喘振裕度模型的输入参数包括 $T_{22}, p_2, n_t, p_3, W_{fb}$, 压气机喘振裕度模型的输入参数包括 $n_c, T_3, \pi_c, p_3, T_{22}$.




图2 风扇及压气机喘振裕度 $S_{m,f}$ 和 $S_{m,c}$ 特征选择过程示意图

Fig. 2 Schematic of feature selection for surge margin of fan and compressor $S_{m,f}$ and $S_{m,c}$

2.3 无畸变 S_m 模型

选定无畸变 S_m 模型的输入参数之后,采用 BP 3 层神经网络进行模型设计,其数学表达为

$$\mathbf{Y} = f(\mathbf{X}) \quad (16)$$

对于风扇喘振裕度,有

$$\begin{cases} \mathbf{X} = [T_{22}(k-1), T_{22}(k-2), \dots, T_{22}(k-N_1), \\ p_2(k-1), p_2(k-2), \dots, p_2(k-N_2), \\ n_t(k-1), n_t(k-2), \dots, n_t(k-N_3), \\ p_3(k-1), p_3(k-2), \dots, p_3(k-N_4), \\ W_{fb}(k-1), W_{fb}(k-2), \dots, W_{fb}(k-N_5)] \\ \mathbf{Y} = [S_{m,f}(k)] \end{cases}$$

由于发动机模型一般可简化为一个 2 阶对象,为了保证 S_m 模型具有合适的动静态精度且输入参数尽可能少,本文将 $N_1, N_2, \dots, N_5$ 均设置为 3. 根据该模型,即可实时预测下一时刻的喘振裕度值,即

$$\mathbf{Y}_{k+1} = f(\mathbf{X}_{k+1})$$


此外,由于神经网络类似于一个非线性插值器,在内插时精度较高,而外插时精度较低,因而所选的训练数据应尽量包含各变量可能出现的最大值和最小值. 在模型训练过程中,首先在 H 为 3~7 km, Ma 为 0.3~0.7 的包线范围内通过对油门杆角度进行充分激励,采集 18227 组动态数据用作模型训练样本,另外随机采集 3717 组数据作为测试样本(仿真步长为 20ms);而后以调试法来确定映射网络的神经元个数,最终选择 $S_{m,f}$ 模型的神经元个数为 14,该模型的测试结果如图 3 所示. 同理,也可对压气机喘振裕度模型进行设计,最终确定 $S_{m,c}$ 模型的神经元个数为 11,测试结果如图 4 所示. 图 3 和图 4 中,图 3(a)和图 4(a)为经特征选择后模型训练的测试误差图,图 3(b)和图 4(b)为采用传统方法训练模型的测试误差图(即模型输入参数为 $H, Ma, W_{fb}, W_{fa}, A_8$),其中测试误差为相对误差,表达如下:

$$e_{er} = \left| \frac{\tilde{S}_m - S_m}{S_m} \right| \times 100\%$$


式中 $\tilde{S}_m$ 为喘振裕度估计值, S_m 为发动机部件级模型的喘振裕度实际输出,即目标值.

从图 3(a)和图 4(a)可以看出,经特征选择后再训练喘振裕度模型, $S_{m,f}$ 及 $S_{m,c}$ 模型的相对测试误差分别在 4% 和 1% 以内,估计值与目标值具有很好的吻合度,完全可以满足动态模型设计要求,其中误差较大处是由于瞬时油门杆角度变化剧烈而产生,在小幅度拉动油门杆的过程中精度更优. 经计算,整个测试样本的 $S_{m,f}$ 和 $S_{m,c}$ 的平均相对

误差分别为 0.568% 和 0.0584%，说明风扇和压气机喘振裕度预测模型均具有良好的预测精度。同时，再将图 3~图 4 中的(a)和(b)对比来看，采用传统方法训练喘振裕度模型的效果很差， $S_{m,f}$ 和 $S_{m,c}$ 的相对测试误差均在 20% 以上，远远不及经特征选择后的训练效果，这就验证了本文喘振裕度特征选择方法的有效性。




(a) 特征选择后 $S_{m,f}$ 模型测试误差




(b) 传统方法 $S_{m,f}$ 模型测试误差

图 3 风扇喘振裕度预测模型精度测试

Fig. 3 Accuracy test of $S_{m,f}$ prediction model of fan



(a) 特征选择后 $S_{m,c}$ 模型测试误差



(b) 传统方法 $S_{m,c}$ 模型测试误差

图 4 压气机喘振裕度预测模型精度测试

Fig. 4 Accuracy test of $S_{m,c}$ prediction model of compressor

3 喘振裕度损失量模型

发动机进口流场畸变强度和飞行状态有着密

切的关系，由马赫数 Ma 和飞行攻角 α 引起的进气畸变变量决定了发动机喘振边界的损失大小。本文首先基于 OSP-LSSVR 算法设计在线攻角预测模型，而后以 $D_{c60} = D_{c60}(Ma, \alpha)$ 为进气畸变指标，通过将进气畸变度转化为喘振压比损失，进而求取畸变时的喘振裕度损失量。

3.1 OSP-LSSVR 算法

在 2.1 节中介绍了 LSSVR 算法，该算法的实现主要在于求解式(9)。若将其进一步用于在线攻角预测，其在线学习过程中每次输入均需重复地求解式(9)，该训练代价必然严重影响攻角预测的实时性。为此，使用文献[14]中的迭代策略来减轻训练代价，即假定在第 n 步

$$\mathbf{R}^n = \begin{bmatrix} 0 & \mathbf{1}_{|P|}^T \\ \mathbf{1}_{|P|} & \mathbf{K}_{PP} \end{bmatrix}^{-1} \quad (17)$$

式中 P 是第 n 步时支持向量的索引集合， $|\cdot|$ 代表集合的势，则可进一步求得

$$\mathbf{R}^{n+1} = \begin{bmatrix} \mathbf{R}^n & \mathbf{0} \\ \mathbf{0}^T & 0 \end{bmatrix} + \lambda \begin{bmatrix} \boldsymbol{\beta} \\ \boldsymbol{\beta}^T - 1 \end{bmatrix} \quad (18)$$

式中 $\boldsymbol{\beta} = \mathbf{R}^n \begin{bmatrix} 1 \\ \bar{\mathbf{k}}_s \end{bmatrix}$, $\lambda = (\bar{\mathbf{k}}_s^T [-1 \quad \bar{\mathbf{k}}_s^T]^T \boldsymbol{\beta}^T)^{-1}$, $s \in P$,

$\bar{\mathbf{k}}_s = k(\mathbf{x}_s, \mathbf{x}_s) + 1/\gamma$ 。当第 n 步的 $\begin{bmatrix} b^n \\ \boldsymbol{\alpha}_p^n \end{bmatrix} = \mathbf{R}^n \begin{bmatrix} 0 \\ \mathbf{Y}_p \end{bmatrix}$

已知，则第 $n+1$ 步

$$\begin{aligned} \begin{bmatrix} b^{n+1} \\ \boldsymbol{\alpha}_p^{n+1} \\ \alpha_s^{n+1} \end{bmatrix} &= \mathbf{R}^{n+1} \begin{bmatrix} 0 \\ \mathbf{Y}_p \\ y_s \end{bmatrix} = \begin{bmatrix} \mathbf{R}^n & \mathbf{0} \\ \mathbf{0}^T & 0 \end{bmatrix} \begin{bmatrix} 0 \\ \mathbf{Y}_p \\ y_s \end{bmatrix} + \\ &\lambda \left(\boldsymbol{\beta}^T \begin{bmatrix} 0 \\ \mathbf{Y}_p \end{bmatrix} - y_s \right) \begin{bmatrix} \boldsymbol{\beta} \\ -1 \end{bmatrix} = \\ &\begin{bmatrix} b^n \\ \boldsymbol{\alpha}_p^n \\ 0 \end{bmatrix} + \lambda \left(\boldsymbol{\beta}^T \begin{bmatrix} 0 \\ \mathbf{Y}_p \end{bmatrix} - y_s \right) \begin{bmatrix} \boldsymbol{\beta} \\ -1 \end{bmatrix} \quad (19) \end{aligned}$$

如此， $\mathbf{R}$, $\boldsymbol{\alpha}$, b 就可以有效地迭代计算出来，进而可实现攻角预测模型的构建。但此时支持向量集的容量没有上限，下面结合滚动窗法进行改进。设滚动窗口样本数据的最大容量为 $\bar{l}$ 个，若第 $m+1$ 时刻加入 $\mathbf{x}_{m+1}$ 后，窗口数据不超过 $\bar{l}$ 个，则将 $\mathbf{x}_{m+1}$ 直接加入窗口中作为支持向量，否则根据下述推导先将最远时刻的输入向量 $\mathbf{x}_{m+1-\bar{l}}$ 删掉后再加入。删除数据时，首先根据 Sherman-Morrison 定理^[15]将 m 时刻的 $\mathbf{K}_m^{-1}$ 分解如下：

$$\mathbf{K}_m^{-1} = \begin{bmatrix} g_m & \mathbf{G}_m^T \\ \mathbf{G}_m & \bar{\mathbf{K}}_m \end{bmatrix}^{-1} = \begin{bmatrix} 0 & \mathbf{0} \\ \mathbf{0} & \bar{\mathbf{K}}_m^{-1} \end{bmatrix} + \bar{\mathbf{z}}_m \bar{\mathbf{z}}_m^T \bar{r}_m =$$

$$\begin{bmatrix} 0 & \mathbf{0} \\ \mathbf{0} & \bar{\mathbf{K}}_m^{-1} \end{bmatrix} + \begin{bmatrix} \mathbf{U}^{-1} & \mathbf{V}^T \\ \mathbf{V} & \mathbf{U}^{-1} \mathbf{V} \mathbf{V}^T \end{bmatrix} \quad (20)$$

式中 $\bar{\mathbf{K}}_m$ 表示 m 时刻删除最远样本后的 $\mathbf{K}$ 阵

$$\begin{aligned} g_m &= k(\mathbf{x}_1, \mathbf{x}_1) + 1/\gamma \\ \bar{\mathbf{r}}_m &= (g_m - \mathbf{G}_m^T \bar{\mathbf{K}}_m^{-1} \mathbf{G}_m)^{-1} \\ \mathbf{G}_m &= [k(\mathbf{x}_1, \mathbf{x}_2) \quad k(\mathbf{x}_1, \mathbf{x}_3) \quad \cdots \quad k(\mathbf{x}_1, \mathbf{x}_i)]^T \\ \bar{\mathbf{z}}_m &= [-1 \quad \mathbf{G}_m^T \bar{\mathbf{K}}_m^{-1}]^T \\ \mathbf{U} &= \bar{\mathbf{r}}_m^{-1} \\ \mathbf{V} &= -\bar{\mathbf{r}}_m^{-1} \bar{\mathbf{K}}_m^{-1} \mathbf{G}_m \end{aligned}$$

通过式(20)可提取出 $\bar{\mathbf{K}}_m^{-1}$, 而后将式(9)改写为

$$\begin{bmatrix} b_m \\ \boldsymbol{\alpha}_m \end{bmatrix} = \begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \mathbf{K}_m \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ \mathbf{Y}_m \end{bmatrix} \quad (21)$$

不难求得

$$\begin{aligned} b_m &= \frac{\mathbf{1}^T \mathbf{K}_m^{-1} \mathbf{Y}_m}{\mathbf{1}^T \mathbf{K}_m^{-1} \mathbf{1}}, \\ \boldsymbol{\alpha}_m &= \mathbf{K}_m^{-1} \left[\mathbf{Y}_m - \frac{\mathbf{1} \mathbf{1}^T \mathbf{K}_m^{-1} \mathbf{Y}_m}{\mathbf{1}^T \mathbf{K}_m^{-1} \mathbf{1}} \right] \end{aligned}$$

进而,即可利用式(18)~式(19)计算出 $m+1$ 时刻的 $\mathbf{R}, \boldsymbol{\alpha}, b$, 以实现攻角状态的实时在线滚动预测,而始终保持有效支持向量的数量恒定且最接近当前时刻。

到此,虽然已实现了攻角在线预测的设计,且具有较好的实时性,但是由式(10)可知,该算法将所有的输入数据 $\mathbf{x}_i |_{i=1}^N$ 都作为支持向量,明显缺乏稀疏性。而且,由于滚动窗口容量有限,一些冗余的输入信息必然使得攻角预测精度大打折扣。所以,很有必要对算法的稀疏性进行改善,其中最行之有效的办法就是加入阈值判断准则:事先设定一个较小正数 ϵ , 当预测精度小于 ϵ 时,则认为该输入信息为冗余信息并舍弃,反之则作为支持向量执行式(18)~式(21),进而更新预测模型,如此便实现了 OSP-LSSVR 算法。

3.2 在线攻角预测模型

利用上述 OSP-LSSVR 算法实现攻角的在线预测,具有精度高、实时性好等显著优势,但在模型计算过程中,由于未来时刻的真实攻角状态未知,故以 $|\alpha_{k+1} - \bar{\alpha}_{k+1}| < \epsilon$ 作为阈值判断准则便不能实现,其中 k 表示当前时刻, α_{k+1} 和 $\bar{\alpha}_{k+1}$ 分别为下一时刻的攻角实际值和估计值。不过,该攻角预测模型使用最近时刻且最有效的攻角信息建模,可以很好地保留系统动态特性,而由于相邻时刻的攻角特性相近,本文退一步采用 k 时刻的攻角预测误差代替 $k+1$ 时刻的误差,即以

$|\alpha_k - \bar{\alpha}_k| < \epsilon$ 作为预测模型更新的判断准则,设计3阶攻角预测模型如下:

$$\mathbf{Y}' = f(\mathbf{X}') \quad (22)$$

式中

$$\begin{cases} \mathbf{X}' = [\alpha_{k-3}, \alpha_{k-2}, \alpha_{k-1}] \\ \mathbf{Y}' = [\alpha_k] \end{cases}$$

由此可推导出在 $k+1$ 时刻模型输入-输出关系

$$\mathbf{Y}'_{k+1} = f(\mathbf{X}'_{k+1}) \quad (23)$$

式中

$$\begin{cases} \mathbf{X}'_{k+1} = [\alpha_{k-2}, \alpha_{k-1}, \alpha_k] \\ \mathbf{Y}'_{k+1} = [\alpha_{k+1}] \end{cases}$$

如此设计,由于当前时刻的 α_k 可测,即可通过式(22)求取 α_k 后,经 $|\alpha_k - \bar{\alpha}_k| < \epsilon$ 进行阈值判断,决定对现有模型的支持向量集是否进行更新,而后进行式(23)的迭代计算。为了提升模型精度,在设计过程中对输入参数均作了归一化处理,因对阈值 ϵ 也进行了改进,即采用 k 时刻模型输出的相对偏差量 e_k 作为目标值,如下:

$$e_k = \left| \frac{\bar{\alpha}_k - \alpha_k}{\alpha_k} \right| \times 100\% < \epsilon'$$

在阈值判断过程中,若 e_k 小于 ϵ' , 则认为此时的在线攻角预测模型可以满足精度要求,不需要更新支持向量集便可准确预测出下一时刻的攻角 α_{k+1} , 反之则认为此时预测模型精度不足,需要加入 k 时刻的数据对支持向量集进行实时更新后,方可进行 $k+1$ 时刻的攻角预测。

最终,通过在 OSP-LSSVR 算法中使用高斯核函数 $k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / 2v^2)$ 设计在线攻角预测模型,经调试设定模型相关参数如下:

$$\bar{l} = 14, \epsilon' = 0.005, v = 1.6, \gamma = 2^{20}$$

其中 $\bar{l}$ 的选择原则为滚动窗口容量尽量小以优化在线模型的实时性,判断阈值 $\epsilon' = 0.005$ 表示模型训练精度可达到 5%,进而可使得模型测试精度较高(约为 1%,下文进行验证),核参数 v 与惩罚因子 γ 则通过交叉验证的方法确定。

该在线攻角预测模型的设计具有很好的实时性与鲁棒性,在全包线范围均可适用。如图 5(a) 和图 5(b) 所示,分别以 $H=5 \text{ km}, Ma=0.5$ 和 $H=12 \text{ km}, Ma=0.8$ 状态为例,说明上述模型的有效性。在测试过程中,通过对升降舵角 δ 进行充分激励,产生攻角的动态变化,其变化范围为 $-20^\circ \sim 70^\circ$ 。图 5(a) 中,共包含 2016 组动态数据,经 OSP-LSSVR 算法在线运算仅需 219 ms,相对测试误差在 1% 以内,说明了 $k+1$ 时刻的攻角实际值与预测值具有很快的响应速度和很高的吻合

度,同样如图5(b)所示,在高空状态该模型也具有很好的预测效果,比起文献[9-10]采用离线方法训练攻角预测模型实现 3° 的预测误差,本文方案具有明显的优势。




图5 攻角预测模型精度测试

Fig. 5 Accuracy test of α_{k+1} predictive model for angle of attack

3.3 喘振裕度损失量模型

喘振裕度损失量模型的建立主要分为3个步骤,首先利用预测的攻角状态确定下一时刻的进气畸变量;而后将进气畸变量转换为喘振压比损失;最后利用式(4)求取喘振裕度损失量。

基于3.2节建立的在线攻角预测模型,采用 D_{c60} 为畸变指标衡量参数^[12],则可求得

$$D_{c60}(k+1) = D_{c60}(Ma, \alpha_{k+1})$$

而在进气畸变条件下,发动机对畸变的敏感性(即压缩部件的喘振压比损失)与进气畸变指标 D_{c60} 成一定的线性关系,经验公式如下^[8,12]:

$$\Delta p_{rs} = \pi_s (K_{circ} \cdot D_{c60} + \text{const})$$

式中 K_{circ} 为发动机对周向畸变的敏感系数,常数const可认为是径向畸变和平面波的影响因素。到此,由式(4)即可计算 $k+1$ 时刻的发动机压缩部件喘振裕度损失量

$$\Delta S_m(k+1) = \Delta p_{rs} [1 + S_m(k+1)]$$

式中 $S_m(k+1)$ 通过2.3节的无畸变喘振裕度模型来获取,最后,通过式(5)便可直接求得处于畸变状态下的 $k+1$ 时刻发动机压缩部件喘振裕度,如下:

$$S'_m(k+1) = S_m(k+1) - \Delta S_m(k+1)$$

4 发动机高稳定性控制

4.1 控制方案及仿真平台

基于上述发动机喘振裕度估计模型,根据图1所示控制结构,以风扇压缩部件为例,对本文的HISTEC进行设计。在超机动飞行的控制过程中,认为发动机在无畸变状态下保留有足够的喘振裕度,但其效率并不一定较高,故设定发动机高效稳定的工作裕度范围 S' 为 $11\% \sim 13\%$ 。

若发动机发生进气畸变使得喘振裕度预测值小于 11% ,则判断发动机安全裕度过小,进而切入高稳定性控制回路,为了不改变发动机原闭环控制回路特性,仅在原闭环回路的基础上对涡轮落压比 π_t 的控制指令 $\pi_{t,r}$ 进行相应的喘振压比损失补偿,其补偿量由风扇喘振压比损失按比例进行计算,如下:

$$\Delta \pi' = \lambda \cdot \Delta p_{rs} = (\pi_t / \pi_f) \cdot \Delta p_{rs}$$

进而可根据控制率给出新的涡轮落压比控制指令 $\pi_{t,r} + \Delta \pi'$,使得风扇喘振裕度达到 11% 以上,以保证发动机安全稳定工作。相反,若喘振裕度预测值大于 13% ,则判断发动机效率较低,安全裕度过剩,则给出涡轮落压比控制指令 $\pi_{t,r} + (-\Delta \pi')$,使得风扇喘振裕度低于 13% ,保持较高的发动机效率。再者,若喘振裕度预测值在 S' 范围内,则认为发动机可高效稳定工作,从而保持常规控制不变。

在图1所示的飞机/发动机综合仿真模型中,飞机模型为飞行纵向平面内的某型非线性动力学仿真模型,可模拟平飞直行、爬升、加速和下滑等飞行任务;该飞机由2台某型涡扇发动机提供推力,发动机模型为采用部件法建立的非线性气动热力学模型,发动机加力控制器为采用增广线性二次型调节器设计的双变量控制器,控制量为 A_8 和 W_{fb} ,被控量为 π_t 和 n_c (或者 π_t 和 n_f ,根据发动机进口温度选择相应的控制模式), W_{fb} 为开环给定;该综合仿真模型的仿真步长为 20 ms ,其中使用到的攻角数据来源于NASA Dryden飞行研究中心F/A-18A飞机的飞行试验数据^[16]。


4.2 数字仿真分析

为了验证本文设计的喘振裕度估计模型及HISTEC方案的有效性,在主频为 2.53 GHz ,内存为 2 G 的仿真环境下,基于上述飞机/发动机综合仿真模型,在中低空、大攻角低速飞行条件下,对超机动飞行任务进行仿真模拟。操作过程中将油门杆拉至最大加力状态,在 $t=0\text{ s}$ 时分别采用


常规控制方法和本文 HISTEC 方法进行控制,在 $t=2,5,8,12,15$ s 时刻,分别对 δ 设置不同的阶跃(负阶跃表示向上偏转升降舵). 其仿真结果如图 6 和图 7 所示,其中下标“no”为常规控制响应,“histec”为高稳定性控制响应.

图 6(a)和图 6(b)分别为 $H=6$ km, $Ma=$

0.63 和 $H=4$ km, $Ma=0.54$ 状态下大攻角机动飞行过程中 $S_{m,f}$ 的响应曲线. 从图中可以看出,高稳定性控制方案能够准确地把 $S_{m,f}$ 控制在 $11\% \sim 13\%$, 使发动机在超机动过程中的稳定性得到保证,且具有较高效率,这正体现了本文 HISTEC 方案的优越性及有效性.



(a) $H=6$ km, $Ma=0.63$ 时, $S_{m,f}$ 的响应曲线



(b) $H=4$ km, $Ma=0.54$ 时, $S_{m,f}$ 的响应曲线

图 6 超机动飞行条件下发动机高稳定性控制仿真结果

Fig. 6 Simulation results of HISTEC under super-maneuvering flight condition




图 7 在 $H=6$ km, $Ma=0.63$ 状态下发动机变量的变化情况

Fig. 7 Responses of engine parameters at $H=6$ km, $Ma=0.63$

下面进一步以 $H=6\text{ km}$, $Ma=0.63$ 状态下发动机高稳定性控制中各变量的变化为例,说明本文高稳定性控制方案的具体实现过程。

从图7可以看出,当 δ 减小时,攻角 α 增大,进气畸变量 D_{e60} 增大,而 D_{e60} 决定了喘振裕度损失量($\Delta S_{m,f}$, $\Delta S_{m,c}$)的大小,从而致使发动机喘振裕度降低,当机动操作完成后,进气畸变量则回到原来的水平。此外,从攻角响应曲线可以看出当前攻角 α_k 与预测值 α_{k+1} 非常接近,一方面说明了相邻时刻的攻角特性相似;另一方面也体现出本文攻角预测模型具有很好的精度。

再结合图6(a)和图7,通过高稳定性控制与常规控制的响应曲线对比,可知该控制过程的被控量为 π_t 和 n_c 。当 $S_{m,f}$ 预测值小于11%时,高稳定性控制对涡轮落压比控制指令进行相应的喘振损失补偿,涡轮落压比 π_t 上升,喷管面积 A_8 扩张程度明显大于常规控制,进而使得图6(a)中的 $S_{m,f}$ 保持在11%以上;而当 $S_{m,f}$ 预测值大于13%时,涡轮落压比控制指令也会得到相应的修正,喷管面积缩小,最终 $S_{m,f}$ 保持在13%以内,使发动机具有较高的效率,相比之下常规控制方法则完全不能达到这种效果。另外,由于飞行条件的改变导致 W_{fb} 和 W_{fa} 产生变化,而两种控制方法的飞行条件变化一致,故 W_{fb} 和 W_{fa} 在两种控制方法中的响应曲线几乎重合。

5 结 论

1) 提出了基于喘振裕度特征选择算法筛选最佳的发动机可测参数作为模型输入,以BP神经网络拟合无畸变状态喘振裕度模型的方法。

2) 设计了在线攻角预测模型,基于该模型实时评估发动机进气畸变度,进而建立畸变时的喘振裕度损失量模型。

3) 结合以上结论建立了适用于超机动飞行的发动机喘振裕度估计模型,并基于该模型在保持原控制回路不变的基础上,实现了中低空、大攻角低速飞行状态下的发动机高稳定性控制。

参考文献:

- [1] DeLaat J C, Southwick R D, Gallops G W. High stability engine control (HISTEC)[R]. AIAA 96-2586, 1996.
- [2] Orme J S, DeLaat J C, Southwick R D, et al. Development and testing of a high stability engine control (HISTEC) system[R]. NASA/TM-1998-206562, 1998.
- [3] Southwick R D, Gallops G W, Kerr L J, et al. High stability engine control (HISTEC) flight test results [R]. NASA/TM-1998-208481, 1998.
- [4] LIU Yuan, Dhingra M, Prasad J V R. Active compressor stability management via a stall margin control mode[J]. Journal of Engineering for Gas Turbines and Power, 2010, 132(5): 1-10.
- [5] Inoue M, Kuroumaru M, Tanino T, et al. Propagation of multiple short-length-scale stall cells in axial compressor rotor [J]. Journal of Turbomachinery, 2000, 122(1): 45-54.
- [6] Dhingra M, Neumeier Y, Prasad J V R, et al. A stochastic model for a compressor stability measure[J]. Journal of Engineering for Gas Turbines and Power, 2007, 129(3): 730-737.
- [7] WANG Lifeng, LI Zhengxi, LIN Zi. Enhancing the fidelity of post-stall flight simulation using detailed propulsion system model[R]. AIAA-2004-4810, 2004.
- [8] 王立峰, 张津. 超机动飞行推进系统稳定性控制研究[J]. 推进技术, 2000, 21(4): 1-4.
WANG Lifeng, ZHANG Jin. Propulsion system stability control for super-maneuvering flight[J]. Journal of Propulsion Technology, 2000, 21(4): 1-4. (in Chinese)
- [9] 袁春飞. 飞行/推进系统综合优化控制模式及其关键技术[D]. 南京: 南京航空航天大学, 2004.
YUAN Chunfei. A study of propulsion optimization control modes[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2004. (in Chinese)
- [10] 陈霆昊, 张海波, 孙健国. 基于攻角预测模型的航空发动机高稳定性控制[J]. 航空动力学报, 2010, 25(7): 1676-1682.
CHEN Tinghao, ZHANG haibo, SUN Jianguo. Aero-engine high stability control scheme design based on angle of attack predictive model[J]. Journal of Aerospace Power, 2010, 25(7): 1676-1682. (in Chinese)
- [11] 廉筱纯, 吴虎. 航空发动机原理[M]. 西安: 西北工业大学出版社, 2005.
- [12] Goldsmith E L, Seddon J. Practical intake aero dynamic design[M]. [S. l.], US: AIAA, 1993.
- [13] Ojeda F, Suykens J A K, De Moor B. Low rank updated LSSVM classifiers for fast variable selection[J]. Neural Networks, 2008, 21(2/3): 437-449.
- [14] ZHAO Yongping, SUN Jianguo, WANG Jiankang. Online parsimonious least squares support vector regression and its application to sensor analytical redundancy for aero-engines[J]. Transactions of Nanjing University of Aeronautics and Astronautics, 2009, 26(4): 280-287.
- [15] 黄红选, 韩继业. 数学规划[M]. 北京: 清华大学出版社, 2006.
- [16] Steenken W G, Williams J G, Walsh K R. Inlet flow characteristics during rapid maneuvers for an F/A-18A airplane[R]. NASA/TM-1999-206587, 1999.