

基于改进平方根无迹卡尔曼滤波方法的 涡扇发动机气路状态监控

胡 宇, 杨月诚, 张世英, 孙振生, 朱杰堂
(第二炮兵工程大学 动力工程系, 西安 710025)

摘 要: 针对涡扇发动机气路状态监控存在模型未知或不准确导致滤波效果下降甚至发散的问题, 研究了一种融入高斯过程回归(GPR)的改进平方根无迹卡尔曼滤波(UKF)方法. 该方法利用 GPR 对训练数据进行学习, 建立发动机气路部件状态监控的 GPR 模型, 替代 UKF 方法中的非线性系统模型; 采用超球体单形采样和平方根滤波方法来提高滤波的计算效率和数值稳定性. 仿真结果表明: 训练的 GPR 模型解决了 UKF 方法对发动机原系统模型和噪声协方差矩阵依赖性的问题; 与扩展卡尔曼滤波(EKF)和平方根 UKF 方法相比较, 改进平方根 UKF 方法精度更高, 对健康参数的估计精度达到 99.9%, 实现了对涡扇发动机单个和多个气路部件健康参数的有效跟踪.

关 键 词: 涡扇发动机; 高斯过程回归; 无迹卡尔曼滤波; 超球体单形采样; 健康参数
中图分类号: V233.7 **文献标志码:** A

Turbofan engine gas path performance monitoring based on improved square root unscented Kalman filter

HU Yu, YANG Yue-cheng, ZHANG Shi-ying,
SUN Zhen-sheng, ZHU Jie-tang

(Department of Power Engineering,
the Second Artillery Engineering University, Xi'an 710025, China)

Abstract: An improved spherical simplex square root unscented Kalman filter (ISRUKF) algorithm based on Gaussian process regression (GPR) was investigated to specifically address unknown or inaccurate models problems, resulting in bad or even divergent filtering results in turbofan engine performance monitoring. The transition and measurement GPR models of turbofan engine dynamic systems were established, and used as a substitute for nonlinear model in unscented Kalman filter (UKF). Meantime, the spherical simplex sampling was exploited to decrease the computational complexity, while square root of measurement residuals covariance matrixes was used instead of variance matrixes during recursive arithmetic process to improve the calculation efficiency and numerical stability in ISRUKF algorithm. Using the GPR, the models were firstly trained and verified, thus overcoming dependency on the previous engine models with the abilities of adaptive noise adjustment and high precision. The gradual and rapid deterioration process of different turbofan engine gas path components were then testified and compared by the extended Kalman filter (EKF), SRUKF and ISRUKF. The results show that the precision of ISRUKF has reached 99.9%, demonstrating the effectiveness of the ISRUKF for health parameters monitoring of turbofan engine gas path.

Key words: turbofan engine; Gaussian process regression (GPR); unscented Kalman filter (UKF); spherical simplex sampling; health parameter

近年来,视情维修的概念^[1]在航空发动机领域受到越来越多的重视,其目标是改善航空发动机安全性和可操作性,减少生命周期费用。而视情维修的前提是获得航空发动机准确的健康状态信息。气路部件作为发动机关键零部件,工作条件恶劣,容易发生故障。如何准确有效的评估气路部件的健康状况,是实现航空发动机性能参数估计、故障诊断与预测、性能寻优控制等的有效保证,是现代航空发动机视情维修的重要组成部分。卡尔曼滤波方法作为一种实时递推的最优估计方法,受到国内外学者的广泛关注。早在 20 世纪 80 年代末, Luppold R H 等^[2]首先将卡尔曼滤波器引入到航空发动机气路性能分析与故障诊断中。目前,基于卡尔曼滤波器的航空发动机气路部件性能分析研究主要分为两个方向:基于线性系统的卡尔曼滤波^[3]和基于非线性系统的卡尔曼滤波^[4]。基于线性系统的卡尔曼滤波是在航空发动机线性模型的基础上进行状态估计,其滤波精度极大地依赖于线性模型的精度^[3]。基于非线性系统的卡尔曼滤波由于采用航空发动机非线性系统模型替代线性系统模型,在全飞行包线内具有更广泛的适应性^[5]。常见的非线性滤波方法有扩展卡尔曼滤波(extended Kalman filter, EKF)、无迹卡尔曼滤波(unscented Kalman filter, UKF)。EKF 实际上还是将非线性问题转化为线性问题^[6]; UKF 通过构造一组确定的加权样本来近似非线性分布,能够获得分布函数的 2 阶矩,且不需要计算 Jacobian 矩阵,精度和适用范围都优于 EKF,受到了广泛的重视与应用^[7-8]。无论是基于线性系统的卡尔曼滤波,还是基于非线性系统的卡尔曼滤波,对航空发动机模型都具有较强的依赖性,并认为系统噪声和测量噪声已知。而实际航空发动机工作过程中,由于安装制造差异,工作环境变化影响等因素作用,存在着模型未知或者难以建立准确模型的情况^[9],且系统噪声的统计特性一般难以确定,这是导致滤波发散的重要原因之一^[10],而实际的实验过程获得准确噪声的方法是结合先验知识和试凑法,这个过程比较复杂而且难以得到满意的效果。因此,上述两类方法都存在一定的局限性。

高斯过程回归(Gaussian process regression, GPR)通过寻找训练数据之间的关系来对系统进行辨识,是一种具有概率意义的非参数黑箱模型,

对处理高维数、小样本和非线性等复杂问题具有很好的适应性^[11],并成功运用于状态模型的学习^[12]。因此,针对涡扇发动机模型未知或模型不准确的情况,本文将 GPR 方法融入到涡扇发动机系统模型的学习,并结合超球体比例修正单形采样与平方根 UKF(square root unscented Kalman filter, SRUKF),研究一种改进平方根 UKF 方法(improved square root unscented Kalman filter, ISRUKF),来实现对涡扇发动机气路部件健康参数的有效估计,并通过单个部件和多个部件发生蜕化的仿真实验验证了该方法的有效性。

1 涡扇发动机气路部件状态监控

涡扇发动机在实际运行过程中由于部件积尘、老化和外物吸入等原因,可能导致涡扇发动机气路部件性能下降甚至故障的发生,其形式表现为部件健康参数渐变性和突变性蜕化。为了对气路部件健康状态进行有效监控,设计了一种基于 ISRUKF 方法的涡扇发动机气路部件状态监控系统,其基本原理框图如图 1 所示。系统主要分为两大模块:离线学习过程和滤波过程。离线学习过程是根据采集获得的涡扇发动机实际数据运用 GPR 离线学习获得涡扇发动机 GPR 模型;滤




图 1 基于 ISRUKF 的气路部件状态监控原理图

Fig. 1 Schematic of gas path component performance monitoring based on ISRUKF

波过程是采用发动机 GPR 模型替代滤波过程的系统模型,并结合超球体采样与 SRUKF 方法来实现对健康参数的有效估计。

2 基于 GPR 的涡扇发动机模型

无论是采用线性卡尔曼滤波方法还是非线性卡尔曼滤波方法对涡扇发动机气路状态进行监控,需要建立发动机线性或非线性系统模型。由于发动机线性系统模型是在稳态点进行线性化处理以后得到的,存在一定的模型误差;非线性系统模型精度较高,但存在建模复杂与计算量大的缺点。因此,本文通过引入 GPR 对发动机训练数据进行学习来获得发动机系统模型。

2.1 GPR^[11]

根据统计学理论,对于任意一组随机变量 $\{x_i \in \mathbf{X}, i=1, 2, \dots, N\}$, $\mathbf{X}$ 为训练数据的输入集,对应的过程状态 $\{h(x_1), h(x_2), \dots, h(x_N)\}$ 的联合分布服从 N 维高斯分布,即高斯过程(Gaussian process, GP)。从函数角度出发,GP 的全部统计特性完全可由其均值函数 $a(\mathbf{x})$ 和协方差函数 $k(x_i, x_j)$ 决定

$$\begin{cases} a(\mathbf{x}) = E[h(\mathbf{x})] \\ k(x_i, x_j) = E\{[h(x_i) - a(x_i)][h(x_j) - a(x_j)]\} \end{cases} \quad (1)$$

式中 x_i, x_j 为任意随机变量。因此 GP 可以定义为 $h(\mathbf{x}) \sim \mathbf{G}[a(\mathbf{x}), k(x_i, x_j)]$ 。

在机器学习领域,GP 是高斯随机过程和贝叶斯学习理论相结合的产物,根据输出值的类型可分为回归和分类两种。GPR 是一种用于从训练数据中学习来获得回归函数的强有力的非参数方法。给定包含 n 个训练观测数据点的集合 $D = D(\mathbf{X}, \mathbf{y}) = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, 其中 $\mathbf{X} = [x_1, x_2, \dots, x_n]$, $x_i \in \mathbf{R}^d$ 表示 d 维输入量, $y_i \in \mathbf{R}$ 为相应输出矢量。输入和输出量之间满足如下模型:

$$y_i = h(x_i) + \varepsilon_i \quad (2)$$

式中真实输出值 $f(x_i)$ 被噪声 ε_i 污染,且 $\varepsilon_i \sim N(0, \delta_n^2)$ 。GPR 实际上就是根据训练集学习输入 $\mathbf{X}$ 与输出 $\mathbf{y}$ 之间的非线性映射关系 $f: \mathbf{R}^d \rightarrow \mathbf{R}$, 从而能够依据映射关系和新的输入 x_* 预测出相应输出值 y_* 。

则由式(2)可得 $\mathbf{y}$ 的先验分布为

$$\mathbf{y} \sim N(0, \mathbf{K} + \delta_n^2 \mathbf{I}_n) \quad (3)$$

式中 $\mathbf{K} = \mathbf{K}(\mathbf{X}, \mathbf{X})$ 为 $n \times n$ 阶对称正定协方差矩

阵,矩阵中的元素 $\mathbf{K}(i, j) = k(x_i, x_j)$ 度量了 x_i 和 x_j 的相关性。 $k(\cdot, \cdot)$ 为一个对任何点集都能保证产生一个非负定协方差矩阵的核函数,可以选择不同的核函数,其中应用最广泛的是平方指数核函数(squared exponential, SE)。

$$k(x_i, x_j) =$$

$$\delta_r^2 \exp\left[-\frac{1}{2}(x_i - x_j)^T \mathbf{W}^{-1}(x_i - x_j)\right] \quad (4)$$

式中 δ_r^2 为信号方差,决定预测值的不确定度; $\mathbf{W} = \text{diag}([l_1^2, l_2^2, \dots, l_d^2])$, l 为方差尺度,反映不同输入维之间过程的相对平稳性。

因此,给定训练数据集 D 和新的输入 x_* , 通过 GPR 可预测 y_* 分布服从高斯分布

$$y_* \sim N[\mathbf{G}_\mu(x_*, D), \mathbf{G}_\Sigma(x_*, D)] \quad (5)$$

式中 $\mathbf{G}_\mu(x_*, D) = \mathbf{k}_*^T [\mathbf{K} + \delta_n^2 \mathbf{I}_n]^{-1} \mathbf{y}$ 和 $\mathbf{G}_\Sigma(x_*, D) = k(x_*, x_*) + \delta_n^2 - \mathbf{k}_*^T [\mathbf{K} + \delta_n^2 \mathbf{I}_n]^{-1} \mathbf{k}_*$ 分别表示根据新的输入 x_* 采用 GPR 预测输出得到的均值和方差, $\mathbf{k}_*$ 为 x_* 和 $\mathbf{X}$ 之间的协方差矩阵。式(5)中包含的未知参数集合 $\theta = \{\mathbf{W}, \delta_r^2, \delta_n^2\}$, 称为 GPR 的超参数。通过最大化训练集的对数边缘似然函数得到,并采用共轭梯度优化法求得其最优解。GPR 详细理论及推导过程见文献[11]。

2.2 发动机 GPR 模型建立

采用非线性系统滤波方法时,涡扇发动机非线性系统模型可表示为

$$\begin{cases} \mathbf{x}_{k+1} = f(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{w}_k \\ \mathbf{y}_k = g(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{v}_k \end{cases} \quad (6)$$

其中 $\mathbf{x}_k \in \mathbf{R}^n$ 表示为状态向量, $\mathbf{u}_k \in \mathbf{R}^l$ 为输入控制向量, $\mathbf{y}_k \in \mathbf{R}^m$ 为测量向量, $\mathbf{w}$ 和 $\mathbf{v}$ 分别为系统和测量噪声。 $f(\cdot)$, $g(\cdot)$ 分别表示非线性系统方程和测量方程。

根据 GPR 理论,非线性系统模型中的系统方程的状态变量作为一组随机变量 $\{x'_k = [\mathbf{x}_k \ \mathbf{u}_k], k=1, 2, \dots, N\}$, 其对应的输出量 $\{x'_{k+1} = [\mathbf{x}_{k+1} \ \mathbf{u}_{k+1}], k=1, 2, \dots, N\} = \{f(x'_1), f(x'_2), \dots, f(x'_N)\}$ 的联合分布服从 N 维高斯分布;同理,非线性系统模型中测量方程的状态变量和控制量作为一组随机变量 $\{x'_k = [\mathbf{x}_k \ \mathbf{u}_k], k=1, 2, \dots, N\}$, 其对应的 $\{y_k, k=1, 2, \dots, N\} = \{g(x'_1), g(x'_2), \dots, g(x'_N)\}$ 的联合分布也服从 N 维高斯分布。因此,可以采用 GPR 方法建立发动机状态 GPR 模型与测量 GPR 模型。

以非线性部件级模型模拟真实涡扇发动机,采集发动机工作过程状态变量和测量变量的数据,并采用 GPR 方法对数据进行训练并建立发动

机状态 GPR 模型与测量 GPR 模型. 由于 GPR 模型的输出一般为标量, 而发动机状态变量和测量变量都为多维变量, 因此, 状态方程和测量方程的每一维都必须采用一个不同的 GPR 模型.

对于状态模型, 一般利用 GPR 方法将前一时刻状态量 $\mathbf{x}_{k-1}$ 映射到当前状态增量 $\Delta \mathbf{x}_k = \mathbf{x}_k - \mathbf{x}_{k-1}$, 可以降低基于 GPR 状态转移模型的误差^[13]. 取训练数据 $D^{f,i} = (\mathbf{X}_i, \Delta \mathbf{Y}_i^i)$, 其中 $\mathbf{X}_i = [\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_{n-1}]$, $\Delta \mathbf{Y}_i^i = [\Delta \mathbf{x}_1^i, \Delta \mathbf{x}_2^i, \dots, \Delta \mathbf{x}_n^i]$, 学习训练数据建立发动机状态增量转移模型为 $\Delta \mathbf{x}_k = f(\mathbf{x}_{k-1}) = \mathbf{G}_\mu^f(\mathbf{x}_{k-1}, D^f)$, 则其状态模型可表示为

$$\mathbf{x}_k = \mathbf{x}_{k-1} + \Delta \mathbf{x}_k = \mathbf{x}_{k-1} + \mathbf{G}_\mu^f(\mathbf{x}_{k-1}, D^f) + \mathbf{w}_k \quad (7)$$

$$\mathbf{w}_k \sim N[0, \mathbf{G}_\Sigma^f(\mathbf{x}_{k-1}, D^f)] \quad (8)$$

式中 $\mathbf{w}_k$ 表示估计的系统噪声. $\mathbf{G}_\mu^f$ 和 $\mathbf{G}_\Sigma^f$ 分别表示预测获得的状态模型的均值和噪声方差.

对于测量模型, 采用 GPR 方法直接将状态 $\mathbf{x}_k$ 映射到测量值 $\mathbf{y}_k$. 取训练数据为 $D^{g,i} = (\mathbf{X}_g, \mathbf{Y}_g^i)$, 其中 $\mathbf{X}_g = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m]$, $\mathbf{Y}_g^i = [\mathbf{y}_1^i, \mathbf{y}_2^i, \dots, \mathbf{y}_m^i]$, 训练数据后建立的测量模型为

$$\mathbf{y}_k = \mathbf{G}_\mu^g(\mathbf{x}_k, D^g) + \mathbf{v}_k \quad (9)$$

$$\mathbf{v}_k \sim [0, \mathbf{G}_\Sigma^g(\mathbf{x}_k, D^g)] \quad (10)$$

式中 $\mathbf{v}_k$ 表示估计的测量噪声. $\mathbf{G}_\mu^g$ 和 $\mathbf{G}_\Sigma^g$ 分别表示预测获得的测量模型均值和噪声方差.

3 ISRUKF 算法

UKF 是一种基于最小方差估计准则的非线性高斯状态滤波器, 其中最重要的是确定 UT (unscented transfer) 变换算法中 Sigma 点的采样策略, 即确定使用 Sigma 点的个数、位置以及相应的权值. 运用比较广泛的是对称采样, 其 Sigma 点的个数为 $2n+1$, 本文采用超球体比例修正单形采样^[14]来近似发动机状态的非线性分布, 其 Sigma 点的个数为 $n+2$, 可以有效降低了计算负担, 适应于实时性较高的发动机滤波过程^[15]. 同时, 传统的 UKF 方法由于计算机的舍入误差造成滤波误差协方差阵 $\mathbf{P}_k$ 失去非负定性和对称性, 进而使滤波增益矩阵 $\mathbf{K}_k$ 计算失真而造成的滤波发散问题, 克服该种发散的方法是采用平方根方法^[16].

因此, 本文以 GPR 方法建立的涡扇发动机 GPR 模型(7)~模型(10)替代 UKF 方法中原系统模型, 并结合超球体单形采样与平方根滤波方法来设计 ISRUKF 算法, 其算法流程如下:

1) 滤波前的 GPR 模型学习过程. 构建系统状态和测量模型训练数据并训练 GPR 模型

$$\begin{cases} \Delta \mathbf{x}_k = \mathbf{G}_\mu^f(\mathbf{x}_{k-1}, D^f) \\ \mathbf{Q}_k = \mathbf{G}_\Sigma^f(\mathbf{x}_{k-1}, D^f) \end{cases} \quad (11)$$

$$\begin{cases} \mathbf{y}_k = \mathbf{G}_\mu^g(\mathbf{x}_k, D^g) \\ \mathbf{R}_k = \mathbf{G}_\Sigma^g(\mathbf{x}_k, D^g) \end{cases} \quad (12)$$

2) 设置状态和协方差平方根的初始值

$$\begin{cases} \hat{\mathbf{x}}_0 = E[\mathbf{x}_0] \\ \mathbf{S}_{\mathbf{x}_0} = \text{chol}\{E[(\mathbf{x}_0 - \hat{\mathbf{x}}_0)(\mathbf{x}_0 - \hat{\mathbf{x}}_0)^T]\} \end{cases} \quad (13)$$

式中 $\text{chol}(\cdot)$ 表示对矩阵进行下三角 Cholesky 分解运算.

3) 运用超球体比例修正单形采样获得 sigma 点

$$\begin{aligned} \boldsymbol{\chi}_{i,k-1} &= \hat{\mathbf{x}}_{k-1} + \mathbf{S}_{\mathbf{x}_{k-1}} \boldsymbol{\chi}_i^j \\ i &= 0, \dots, n+1 \end{aligned} \quad (14)$$

式中 $\boldsymbol{\chi}_i \in \mathbf{R}^{n \times (n+2)}$ 表示运用超球体比例修正单形采样获得的采样点, $\hat{\mathbf{x}}_{k-1} \in \mathbf{R}^n$ 且 $\mathbf{S}_{\mathbf{x}_{k-1}} \in \mathbf{R}^{n \times n}$.

4) 时间更新

将 sigma 点 $\boldsymbol{\chi}_{i,k-1}$ 代入到系统状态 GPR 模型(11)中, 可得进一步状态预测值和系统噪声协方差矩阵平方根形式

$$\begin{aligned} \boldsymbol{\chi}_{i,k|k-1} &= \hat{\mathbf{x}}_{i,k-1} + \Delta \mathbf{x}_{i,k-1} = \\ &= \hat{\mathbf{x}}_{i,k-1} + \mathbf{G}_\mu^f(\boldsymbol{\chi}_{i,k-1}, D^{f,i}) \end{aligned} \quad (15)$$

$$\mathbf{Q}_k = \mathbf{G}_\Sigma^f(\boldsymbol{\chi}_{k-1}, D^f) = \mathbf{S}_w \mathbf{S}_w^T \quad (16)$$

$$\hat{\mathbf{x}}_k^- = \sum_{i=0}^{n+1} \omega_i^m \boldsymbol{\chi}_{i,k|k-1} \quad (17)$$

$$\mathbf{S}_{\mathbf{x}_k}^- = \text{qr}([\sqrt{\omega_i^c}(\boldsymbol{\chi}_{1:n+1,k|k+1} - \hat{\mathbf{x}}_k^-) \mathbf{S}_w]) \quad (18)$$

$$\mathbf{S}_{\mathbf{x}_k}^- =$$

$$\text{cholupdata}(\mathbf{S}_{\mathbf{x}_k}^-, \boldsymbol{\chi}_{0,k|k+1} - \hat{\mathbf{x}}_k^-, \omega_0^c) \quad (19)$$

式中 $\text{qr}(\cdot)$ 表示对矩阵进行奇异分解, $\text{cholupdata}(\mathbf{S}, \mathbf{U}, \pm m)$ 表示对下三角矩阵 $\mathbf{S}$ 进行 cholesky 更新, 相当于计算 $\text{chol}(\mathbf{S}\mathbf{S}^T \pm \sqrt{m}\mathbf{U}\mathbf{U}^T)$.

5) 测量更新

将 sigma 点 $\boldsymbol{\chi}_{i,k-1}$ 代入到系统测量 GPR 模型(12)中, 可得进一步测量预测值和测量噪声协方差矩阵平方根形式

$$\mathbf{y}_{i,k|k-1} = \mathbf{G}_\mu^g(\boldsymbol{\chi}_{i,k|k-1}, D^g) \quad (20)$$

$$\mathbf{R}_k = \mathbf{G}_\Sigma^g(\boldsymbol{\chi}_{k|k-1}, D^g) = \mathbf{S}_v \mathbf{S}_v^T \quad (21)$$

$$\hat{\mathbf{y}}_k^- = \sum_{i=0}^{n+1} \omega_i^m \mathbf{y}_{i,k|k-1} \quad (22)$$

$$\mathbf{S}_{\mathbf{y}_k}^- = \text{qr}([\sqrt{\omega_i^c}(\mathbf{y}_{1:n+1,k|k+1} - \hat{\mathbf{y}}_k^-) \mathbf{S}_v]) \quad (23)$$

$$\mathbf{S}_{\mathbf{y}_k}^- = \text{cholupdata}(\mathbf{S}_{\mathbf{y}_k}^-, \mathbf{y}_{0,k|k+1} - \hat{\mathbf{y}}_k^-, \omega_0^c) \quad (24)$$

$$\mathbf{P}_{\mathbf{x}_k \mathbf{y}_k} = \sum_{i=0}^{n+1} \omega_i^c (\boldsymbol{\chi}_{i,k|k-1} - \hat{\mathbf{x}}_k^-) (\mathbf{y}_{i,k|k-1} - \hat{\mathbf{y}}_k^-)^T \quad (25)$$

$$\mathbf{K}_k = (\mathbf{P}_{x_k y_k} / \mathbf{S}_{y_k}^-) / \mathbf{S}_{y_k}^- \quad (26)$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{y}_k - \hat{\mathbf{y}}_k^-) \quad (27)$$

$$\mathbf{U} = \mathbf{K}_k \mathbf{S}_{y_k}^- \quad (28)$$

$$\mathbf{S}_{x_k} = \text{cholupdata}(\mathbf{S}_{x_k}^-, \mathbf{U}, -1) \quad (29)$$

该算法中,由于获取 GPR 模型的训练数据遍布系统变化的整个过程,并根据真实数据的变化情况来获取模型的输出均值和噪声,理论上具有较准确地模拟真实系统模型的能力.将 GPR 融入 UKF 算法中,可以克服传统滤波算法对于系统模型和先验噪声协方差的依赖,而且可以克服基于线性模型的滤波方法由于采用线性化处理带来的滤波性能下降和发散等问题^[17].同时,算法中采用超球体采样和平方根滤波方法可以有效提高滤波的计算效率和数值稳定性.

4 仿真结果与分析



以某型涡扇发动机为研究对象,建立其部件级非线性模型并模拟真实涡扇发动机进行仿真试验.在建立发动机非线性系统模型时,健康参数作为状态变量进行考虑^[7,18].如式(5)所示,状态量 $\mathbf{x}_k$ 中包含健康参数 $\mathbf{h}_k = [\eta_{fan}, m_{fan}, \eta_{hpc}, m_{hpc}, \eta_{apt}, m_{hpt}, \eta_{pt}, m_{ipt}]$,分别表示风扇、压气机、高、低压涡轮的效率系数和流量系数,其数值能够反映气路部件的健康状态.输出测量向量 $\mathbf{y}_k = [N_l, N_h, p_{25}, T_{25}, p_3, T_3, p_{45}, T_{45}]$,分别表示为高、低压转子转速,压气机进气口压力、温度,燃烧室进口压力、温度,低压涡轮进气口压力、温度.所有测量参数都依据相似理论转换到标准地面状态下并进行了归一化处理.为了有效验证 ISRUKF 方法能够实现对涡扇发动机气路部件健康参数的有效跟踪,仿真试验分析主要分为两部分:发动机 GPR 模型有效性验证和气路部件健康参数跟踪分析.仿真验证过程在高度 $H=0$,马赫数 $Ma=0$,低压转子转速为 $N_l = 70\% N_{l,d}$ ($N_{l,d}$ 为低压转子设计转速)的工作状态下进行. GPR 模型的学习过程选取平方指数(SE)核函数,超参数初值为 $\ln l_i = 0, i=1, 2, \dots, 8; \ln \delta_i = 0; \ln \delta_n = 0.1$ (其中 l_i 为方差尺度, δ_i 为信号方差, δ_n 为噪声强度),并采用共轭梯度优化算法搜索最优超参数,收敛指标设为最大迭代步数为 200 或迭代步之间相对目标值差值为 <0.01 .

4.1 涡扇发动机 GPR 模型验证

对采用 GPR 建立的发动机模型进行验证.在没有噪声干扰条件下进行,对发动机作控制量

1%的小扰动,采集模拟真实发动机工作过程的状态参数和测量参数的变化数据,并运用 GPR 对数据进行学习获得发动机 GPR 模型.同时,在 1% 的范围内取小扰动,以 0.5% 的扰动为例,采集测试数据并得到 GPR 模型的阶跃响应曲线,并与非线性部件级模型(component-level-model, CLM)、基于偏导数法(partial derivative method, PDM)的线性模型^[19]输出结果相比较,如图 2 所示.

图 2 中 CLM, PDM 和 GPR 分别表示非线性部件级模型、基于偏导数法的线性模型和 GPR 模型的输出结果.从图 2 可以看出,由于偏导数法采用近似方法获得发动机线性模型,存在一定的建模误差;而 GPR 模型是基于实际数据进行学习获得,具有非常高的精度,与非线性部件级模型阶跃响应曲线几乎重叠.相比于非线性部件级建模, GPR 模型还具有简单易实现的特点.经验证,基于 GPR 方法建立的模型在其他工作状态点同样具有较高的精度.因此,在 SRUKF 算法中可以采






图 2 3 种模型阶跃输出响应比较

Fig. 2 Comparison of step responses for three models

用发动机 GPR 模型替代非线性系统模型。

4.2 气路部件性能蜕化估计

设涡扇发动机在飞行工作过程中,部件的渐变性能蜕化程度保持不变,期间出现突发性故障^[18]。为验证 ISRUKF 算法能够实现发动机健康参数的有效估计,分别对单个气路部件发生蜕化和多个部件同时发生蜕化两种情况进行分析。

对单个部件发生蜕化的情况,选取发动机气路部件典型故障模式下的健康参数蜕化量,取风

扇效率系数 η_{fan} 和风扇流量系数 m_{fan} 在仿真时间周期 $t=5000\text{ s}$ 内分别在发生下降 2% 和 2.5% 的渐变性能蜕化,并在 $t=2500\text{ s}$ 处发生其健康参数下降 1% 的突发性故障^[20]。将非线性系统模型作为真实发动机模型,分别加载系统和量测噪声 $\mathbf{Q}=0.000\ 2^2\ \mathbf{I}_{n \times n}$, $\mathbf{R}=0.000\ 2^2\ \mathbf{I}_{m \times m}$ 来模拟发动机真实变化情况进行两次仿真。第 1 次仿真采集学习 GPR 模型所需的训练数据,共 5000 组数据。第 2 次仿真分别采用基于线性模型的 EKF 方法、基于非线性模型的 SRUKF 方法与基于 GPR 模型的 ISRUKF 方法对健康参数进行滤波估计。ISRUKF 算法的缩放因子 $\alpha=0.01$,加权项 $\beta=2$,sigma 权值, $\mathbf{W}_0$ 取 $0.2^{[21]}$,健康参数初始状态为 $\mathbf{h}_0=[1,1,1,1,1,1,1,1]$ 。由于健康参数维数和测量值维数都为 8 和 8,则共需要训练 16 个 GPR 模型。优化后的最优超参数如表 1 所示, $G^{f,i}$ 表示训练的第 i 个状态 GPR 模型, $G^{g,i}$ 表示训练的第 i 个测量 GPR 模型。从表 1 中可以看出,除 $G^{f,1}$ 和 $G^{f,5}$ 对应的噪声强度 δ_n^* 偏大外,其他模型的噪声强度均约为 2×10^{-4} ,其原因是由于模型 $G^{f,1}$ 和 $G^{f,5}$ 分别对应风扇效率系数和流量系数发生蜕化的 GPR 模型,蜕化过程存在更强的扰动性导致估计噪声强度偏大。但其噪声强度数量级与其他模型基本一致,并与仿真条件设置的噪声基本相符合。因此,说明优化的超参数是有效的,通过 GPR 方法能够获得有效的噪声方差矩阵。

表 1 超参数的优化结果

Table 1 Optimal values of the hyperparameters

模型	ℓ_1^f	ℓ_2^f	ℓ_3^f	ℓ_4^f	ℓ_5^f	ℓ_6^f	ℓ_7^f	ℓ_8^f	$\delta_n^*/10^{-4}$	$\delta_n^*/10^{-4}$
$G^{f,1}$	0.032	3.8	3.0	3.4	5.2	3.7	1.6	3.2	160	5.0
$G^{f,2}$	15	0.0016	4.7	3.8	21	4.8	4.1	4.9	9.6	1.9
$G^{f,3}$	7.2	4.6	0.0014	4.5	18	4.5	5.0	4.8	8.3	2.0
$G^{f,4}$	18	4.6	4.0	0.0016	23	4.5	4.7	5.1	9.7	2.0
$G^{f,5}$	27	6.8	6.9	6.8	0.05	6.7	5.6	6.1	0.037	5.0
$G^{f,6}$	13	4.1	3.9	3.7	19	0.0016	3.7	4.0	9.7	2.0
$G^{f,7}$	16	5.4	5.2	4.5	27	4.0	0.0012	5.4	8.2	1.9
$G^{f,8}$	16	4.9	5.3	4.8	34	5.1	5.1	0.0013	8.3	2.0
$G^{g,1}$	0.0055	3.5	3.4	3.6	0.17	3.5	3.7	2.9	14	2.0
$G^{g,2}$	0.14	2.4	2.2	2.5	0.11	2.7	2.2	2.5	2.7	1.9
$G^{g,3}$	0.0085	2.5	2.5	2.6	0.2	2.6	2.5	2.9	37	2.0
$G^{g,4}$	0.0086	2.8	3.3	3.3	1.4	3.6	3.7	3.3	14	2.0
$G^{g,5}$	0.0085	3.6	3.6	3.2	0.042	3.1	3.4	3.3	17	2.0
$G^{g,6}$	0.022	3.5	5.7	2.4	0.13	5.9	3.0	5.5	5.2	2.0
$G^{g,7}$	0.0067	3.5	3.4	3.7	0.43	2.5	3.7	3.3	11	2.0
$G^{g,8}$	0.032	2.0	2.9	1.2	0.31	2.6	3.1	1.6	28	2.2

在 ISRUKEF 算法中,以状态和测量 GPR 模型替代发动机非线性模型进行仿真,滤波结果分别与 SRUKF, EKF 输出结果相比较,如图 3~图 5 所示。图 3~图 5 分别表示采用 EKF 方法、SRUKF 方法和 ISRUKEF 方法得到的风扇健康参数蜕化过程滤波效果,其中下标 true 表示模拟的健康参数真实蜕化过程。从仿真结果可以看出,3 种方法基本都能够实现对风扇蜕化过程健康参数的有效跟踪。其中,由于 EKF 采用 PDM 获得的线性模型不可避免地存在一定的建模误差,使得估计参数的误差较大。而非线性模型的高精度使得 SRUKF 方法比 EKF 获得更高的健康参数跟踪精度。图 5 中,由于基于 GPR 模型的 ISRUKEF 方法采用高斯过程回归具有较好模拟系统模型的能力,能够较准确地反映真实系统的动态变化过程,且滤波过程 GPR 模型能够根据新的输入对噪声进行自适应调整,从而有效地提高了滤波跟踪的精度。其中,ISRUKEF 方法对各个健康参数的跟踪精度平均能达到 99.9%,而 EKF 方法和 SRUKF 分别为 95% 和 98% 左右,在部分健康参数突变性蜕化点处精度较低,如 EKF 方法中低压涡轮效率系数 η_{lpt} 在突变点处的精度仅为 90%,因此,相对于其他两种方法,ISRUKEF 更能有效地跟踪健康参数的蜕化过程,特别是对突变性蜕化过程的跟踪,基本上做到误差很小。

为更加直观地比较 3 种算法的性能,整个滤波过程引用健康参数跟踪的均方根误差(RMSE)




图3 基于 EKF 方法的风扇健康参数蜕化估计效果
Fig. 3 Filtering results of fan with EKF




图4 基于 SRUKF 方法的风扇健康参数
蜕化估计效果

Fig. 4 Filtering results of fan with SRUKF




图5 基于 ISRUKEF 方法的风扇健康参数蜕化估计效果
Fig. 5 Filtering results of fan with ISRUKEF

形式

$$E_{\text{rmse}} = \sqrt{\frac{1}{n} \sum_{k=1}^n (\hat{x}_k - x_k)^2} \quad (30)$$

式中 n 表示所有采样点, x_k 表示蜕化过程健康参数的真实值。3 种算法的误差对比如图 6 所示。从图 6 可以明显看出,相比于 EKF 和 SRUKF, ISRUKEF 方法的滤波误差更小。因此,对单个部件发生蜕化情况, ISRUKEF 具有好的滤波效果。

对多个部件同时发生蜕化的情况。取风扇和压气机在整个飞行过程中同时发生蜕化,风扇效率和流量系数分别下降 2% 和 2.5%, 压气机效率

和流量分别下降 2% 和 1.6%, 且在 $t=2500\text{ s}$ 处分别发生下降 1% 突变性故障^[20]. 分别采用 3 种方法对健康参数的蜕化过程进行滤波跟踪比较. 图 7、图 8 和图 9 分别表示采用 EKF, SRUKF 和 ISRUKEF 方法获得风扇和压气机健康参数蜕化过程的滤波曲线, 其中, ISRUKEF 的跟踪精度最高, 平均能达到 99.9%, EKF 和 SRUKF 分别为 93% 和 97% 左右.




图 6 3 种方法的均方根误差比较

Fig. 6 Comparison of RMSEs for EKF, SRUKF and ISRUKEF




图 7 基于 EKF 方法的风扇和压气机健康参数蜕化估计效果

Fig. 7 Filtering results of fan and hpc with EKF





图 8 基于 SRUKF 方法的风扇和压气机健康参数蜕化估计效果

Fig. 8 Filtering results of fan and HPC with SRUKF




图 9 基于 ISRUKEF 方法的风扇和压气机健康参数蜕化估计效果

Fig. 9 Filtering results of fan and HPC with ISRUKEF

图 10 表示三者滤波误差比较结果. 从图中可以看出, 当风扇和压气机同时发生渐变性和突变性蜕化时, EKF 方法对健康参数的估计误差最大, SRUKF 方法其次, ISRUKEF 方法的误差最




图 10 3 种方法的均方根误差比较

Fig. 10 Comparison of RMSEs for EKF, SRUKF and ISRUKEF

小,因此,对于多个部件同时发生蜕化的情况,ISRUKF同样也具有较好的适应性,这也说明GPR方法完全有能力将学习获得的GPR模型替代发动机非线性模型来实现发动机气路状态监控.对于发动机其他工作状态和气路部件故障模式,ISRUKF方法同样能够获得较好的跟踪效果,限于篇幅,本文不再赘述.

5 结 论

针对涡扇发动机气路部件状态监控系统存在模型未知或者不准确导致滤波精度下降甚至发散的问题,本文研究了一种ISRUKF方法,实现了对发动机气路部件健康参数的有效监控.根据发动机训练数据,采用高斯过程回归获得的GPR模型具有较好模仿系统模型的能力,可替代UKF算法中的非线性系统模型;通过对模型与气路部件性能蜕化的仿真与对比分析表明,ISRUKF方法解决了滤波过程模型未知的问题,克服了EKF方法由于建模误差带来滤波效果下降的缺点;与基于非线性部件级模型的SRUKF方法相比较,基于GPR模型的ISRUKF具有简单易实现的特点.因此,ISRUKF方法是一种能够对发动机气路部件健康状态跟踪和诊断的有效算法.

参考文献:

- [1] Rajamani R, Wang J, Jeong K Y. Conditioned based maintenance for aircraft engine[J]. ASME Paper GT2004-54127, 2004.
- [2] Luppold R H, Roman J R, Gallops G W, et al. Estimating in flight engine performance variations using Kalman filter concepts[R]. AIAA 1989-2584, 1989.
- [3] 袁春飞, 姚华. 基于卡尔曼滤波器和遗传算法的航空发动机性能诊断[J]. 推进技术, 2007, 28(1): 9-13.
YUAN Chunfei, YAO Hua. Development of kalman filter and genetic algorithm for aero-engine performance diagnostics[J]. Journal of Propulsion Technology, 2007, 28(1): 9-13. (in Chinese)
- [4] Dewallef P, Léonard O. On-line performance monitoring and engine diagnostic using robust Kalman filtering techniques[R]. ASME Paper GT2003-38379, 2003.
- [5] 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.
ZHANG Haibo, CHEN Tinghao, SUN Jianguo, et al. Design and simulation of a new novel engine adaptive model[J]. Journal of Propulsion Technology, 2011, 32(4): 557-563. (in Chinese)
- [6] Kobayashi T. Application of a constant gain extended Kalman filter for in-flight estimation of aircraft engine performance parameters[R]. NASA/TM 2005-213865, 2005.
- [7] 张鹏, 黄金泉. 航空发动机气路故障诊断的平方根 UKF 方法研究[J]. 航空动力学报, 2008, 23(1): 169-173.
ZHANG Peng, HUANG Jinquan. SRUKF research on aeroengines for gas path component fault diagnostics[J]. Journal of Aerospace Power, 2008, 23(1): 169-173. (in Chinese)
- [8] 张鹏, 黄金泉. 基于双重卡尔曼滤波器的发动机故障诊断[J]. 航空动力学报, 2008, 23(5): 952-956.
ZHANG Peng, HUANG Jinquan. Aeroengine fault diagnosis using dual Kalman filtering technique[J]. Journal of Aerospace Power, 2008, 23(5): 952-956. (in Chinese)
- [9] 郑铁军, 王曦, 罗秀芹, 等. 建立航空发动机状态空间模型的修正方法[J]. 推进技术, 2005, 26(1): 46-49.
ZHENG Tiejun, WANG Xi, LUO Xiuqin, et al. Modified method of establishing the state space model of aeroengine[J]. Journal of Propulsion Technology, 2005, 26(1): 46-49. (in Chinese)
- [10] 刘小勇, 樊思齐. 自适应卡尔曼滤波在航空发动机参数估计中的应用[J]. 航空动力学报, 1995, 10(3): 304-306.
LIU Xiaoyong, FAN Siqi. Application of Kalman filtering for an aeroengine parameter estimation[J]. Journal of Aerospace Power, 1995, 10(3): 304-306. (in Chinese)
- [11] Williams C K I, Rasmussen C E. Gaussian processes for machine learning[M]. Cambridge, USA: MIT Press, 2006.
- [12] Ferris B, Hahnel D, Fox D. Gaussian processes for signal strength-based location estimation[C] // Proceedings of Robotics, Science and Systems. Philadelphia, USA: MIT Press, 2006: 782-794.
- [13] 何志昆, 刘光斌, 赵曦晶, 等. 基于 GPR 模型的自适应平方根容卡尔曼滤波算法[J]. 航空学报, 2013, 34(9): 2202-2211.
HE Zhikun, LIU Guangbin, ZHAO Xijing, et al. Adaptive square-root cubature Kalman filter algorithm based on Gaussian process regression models[J]. Acta Aeronautica et Astronautica Sinica, 2013, 34(9): 2202-2211. (in Chinese)
- [14] 赵琳, 王小旭, 李亮, 等. 非线性系统滤波理论[M]. 北京: 国防工业出版社, 2012.
- [15] Julier S J, Uhlmann J K. Reduced sigma point filters for the propagation of means and covariance through nonlinear transformations[C] // Proceedings of the American Control Conference. Anchorage, USA: American Automatic Control Council, 2002: 887-892.
- [16] 卫志农, 孙国强, 庞博. 无迹卡尔曼滤波及其平方根形式在电力系统动态状态估计中的应用[J]. 中国电机工程学报, 2011, 31(16): 74-80.
WEI Zhinong, SUN Guoqiang, PANG Bo. Application of UKF and SRUKF to power system dynamic state estimation[J]. Proceedings of the CSEE, 2011, 31(16): 74-80. (in Chinese)
- [17] 李鹏, 宋申民, 陈兴林. 自适应平方根无迹卡尔曼滤波算法[J]. 控制理论与应用, 2010, 27(2): 143-146.
LI Peng, SONG Shenming, CHEN Xinglin. Adaptive

- square-root unscented Kalman filter algorithm[J]. Control Theory & Applications, 2010, 27(2): 143-146. (in Chinese)
- [18] Borguet S, Léonard O. A generalized likelihood ratio test for adaptive gas turbine performance monitoring[J]. Journal of Engineering for Gas Turbines and Power, 2009, 131(1): 1-8.
- [19] 胡宇, 杨月诚, 张世英, 等. 基于改进拟合法的涡扇发动机状态变量模型建立方法[J]. 推进技术, 2013, 34(3): 405-410.
- HU Yu, YANG Yuecheng, ZHANG Shiyong, et al. Establishment of turbofan engine state variable model based on improved fitting method[J]. Journal of Propulsion Technology, 2013, 34(3): 405-410. (in Chinese)
- [20] Volponi A J, DePold H, Ganguli R, et al. The use of Kalman filter and neural network methodologies in gas turbine performance diagnostics: a comparative study[J]. Journal of Engineering for Gas Turbines and Power, 2003, 125(4): 917-924.
- [21] Castrejón-Lozano J G, Carrillo L R G, Dzul A, et al. Spherical simplex sigma point Kalman filters: a comparison in the inertial navigation of a terrestrial vehicle[C] // Proceedings of the American Control Conference, Washington, USA: American Automatic Control Council, 2008: 3356-3541.

JASSP