

基于自适应 AR 模型巡航飞行参数预测研究

钱宇 王立新 张恒 刘瑜

(中国民用航空飞行学院 四川 广汉 618307)

摘要 为更准确实现飞行参数趋势预测,提出一种基于自适应自回归(AR)模型的稳定巡航飞行参数预测方法。根据稳定巡航参数筛选条件,获取建模所需飞行参数。利用卡尔曼滤波原理估计 AR 模型参数,并与飞行参数构建系统方程,利用无迹卡尔曼滤波实时更新、修正 AR 模型参数估计值,将自适应 AR 模型的预测值与曲线拟合模型和灰色模型的预测值进行对比。以波音 B777-300ER 飞机的快速存取记录器数据样本进行仿真验证,结果表明:自适应 AR 模型在数据预测和收敛速率方面均更优,可有效降低预报模型随步数增加导致的精度误差,提高参数预测准确性。研究在飞机维修保障、状态监控与预测等方面具有重要作用。

关键词 无迹卡尔曼滤波 自适应 AR 模型 飞行参数预测 曲线拟合模型 灰色模型

中图分类号 TP206 TP3 文献标志码 A DOI:10.3969/j.issn.1000-386x.2024.04.011

CRUISE FLIGHT PARAMETERS PREDICTION BASED ON ADAPTIVE AR MODEL

Qian Yu Wang Lixin Zhang Heng Liu Yu

(Civil Aviation Flight University of China, Guanghan 618307, Sichuan, China)

Abstract In order to realize the trend prediction of flight parameters more accurately, a stable cruise flight parameter prediction method based on adaptive auto regressive (AR) model is proposed. According to the screening conditions of stable cruise parameters, the flight parameters required for modeling were obtained. The parameters of AR model were estimated by Kalman filter principle, and the system equations were constructed with flight parameters. The parameters of AR model were updated and modified by unscented Kalman filter (UKF) in real time. The predicted values of adaptive AR model were compared with those of curve fitting model and grey model. The data samples of Boeing B777-300ER quick aircraft recorder (QAR) were used for simulation verification. The results show that the adaptive AR model is better in data prediction accuracy and convergence rate, which can effectively reduce the accuracy error of prediction model with the increase of steps and improve the accuracy of parameter prediction. This research is of great significance in aircraft maintenance support, condition monitoring and prediction.

Keywords Unscented Kalman filter Adaptive AR model Flight parameter prediction Curve fitting model Grey model

0 引言

飞行参数的趋势监控是飞机维修保障、状态监控与预测的重要手段之一。快速存取记录器(Quick Aircraft Recorder, QAR)数据直接用于飞行参数的趋势监控,会导致工作量增加且预测模型较复杂。对于参数

的趋势监控与预测,应在飞机处于稳定工作状态的情况下实施。随着民航的不断发展,A380、B787 等大型民航客机的机载系统均已装备大量先进技术以实现飞机健康状态的实时监控、视情维修及故障预测等^[1]。目前我国民航运营机型以 B737、A320 为主,它们并不具备加装这些技术的硬件条件,航空公司对飞机维修保障、状态监控与预测仍以 QAR 数据分析预测为主要

技术手段。

飞行数据是一种非常典型的时间序列^[2],这些数据包含着飞机设备的各种工作状态以及性能变化的趋势信息,既有线性系统数据也有非线性系统数据。如何充分发挥飞行数据的作用,吸引着广大科研工作者进行广泛而深入的研究。例如利用 AR 模型实现时序预测,但在 AR 模型^[3]参数估计方面,不同的参数估计算法对模型预测精度影响很大。Levinson-Durbin^[4]递推算法求解 Yule Walker 方程快速有效,所得模型稳定且均方预测误差随模型阶次增加而减小,但误差较大。Burg 提出 Burg 算法^[5],所得模型稳定且计算效率高,但递推依然采用 L-D 算法。Marple 提出最小二乘法(Least Square, LS)^[6-7],可让模型所有参数总的均方误差达到最小,但它不能确保模型的稳定性。递推最小二乘法(Recursive Least Square, RLS)^[8-10]利用迭代算法代替矩阵求逆,有效提高了算法收敛速度且所得模型较稳定,可实时预测参数,但输入数据信息缺乏完整性。自适应 Kalman 滤波^[11-13]算法可实时更新和修正模型参数,模型收敛性和稳定性均有提高,但对于非线性系统将无法达到估计最优。

模型参数估计的准确性对飞行数据预测至关重要,于是本文利用 UKF 算法对 AR 模型随机差分方程参数进行实时估计和修正,既有效提高模型参数估计精度,也解决了模型参数估计时变性与预测模型定长性之间的差异性及非线性系统参数估计精度低的问题。另外还采用曲线拟合模型和灰色模型预测飞行参数,并与自适应 AR 模型进行对比。选择波音 B777-300ER 飞机的发动机排气温度(Exhaust Gas Temperature, EGT)、燃油流量这两组非线性系统数据进行仿真验证。

1 自回归模型 AR(n)

对于一个平稳、零均值的时间序列 $\{x_t, t = 1, 2, \dots, N\}$,可拟合为一个随机差分方程:

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_n x_{t-n} + a_t \quad (1)$$

式(1)称为 n 阶自回归模型,即 AR(n)。其中, x_t 是时间序列 $\{x_t\}$ 在 t 时刻的元素; $\phi_i (i = 1, 2, \dots, n)$ 为自回归系数; $a_i (i = 1, 2, \dots, n)$ 为残差, i 时刻系统的高斯白噪声输入,是一个服从正态分布且相对独立的变量。

采用 AR(n) 模型进行建模研究,建模过程需遵循一定的时序理论,这里将其分为五个阶段:(1) 采集数据;(2) 数据特性检验;(3) 估计模型参数;(4) 模型

适用性检验;(5) 数据预测。

1.1 稳定巡航数据采集

每次飞行任务之后, QAR 会记录下整个飞行阶段的数据, QAR 记录数据的方式为每次/s, 包含大气数据、发动机数据等数百个数据,这些数据被用于机务日常维修、飞行检查、性能监控及飞行品质监控等。

飞行参数的趋势监控与预测可为飞机日常维修、飞行检查、性能监控等提供极其重要的依据。由于 QAR 记录的数据众多,我们需要对整个飞行阶段的数据进行分段处理,分为滑行、起飞、爬升、巡航、下降、着陆几个阶段,且只有飞机处于稳定状态下的 QAR 数据才更能反映飞机的实际情况。因此本文把巡航段数据作为研究对象,并参考波音、空客稳定巡航筛选标准(如表 1 所示)对两组非线性系统巡航数据进行筛选,获取稳定巡航工作状态下的飞行数据。

表 1 稳定巡航数据筛选标准

参数	波动范围/(kg · h ⁻¹)	参数	波动范围/℃
燃油流量	150	EGT	18

稳定巡航数据筛选需采集巡航段数据、设定稳定时间、建立筛选标准,在巡航段 QAR 数据中逐行检验后续稳定时间内飞行参数是否超过筛选标准,若未超出,则说明当前稳定时间段内飞机处于稳定巡航工作状态,反之,从下一行开始重复上述过程,直至数据末尾。稳定时间参考空客的标准设定为 60 s,即稳定时间内数据波动不超过给定的波动范围。

1.2 数据特性检验

在实际应用中,时序零均值检验一般被省略,最主要的是检验平稳性。利用如下的逆序法对时序的平稳性进行验证。

将 $\{x_t\}$ 均分成 k 段子序 $\{x_1\}, \{x_2\}, \dots, \{x_k\}$, 求出各子序列的平均值并构成一个新的时间序列 $\mu_1, \mu_2, \dots, \mu_k$, 当 $i > j (j = 1, 2, \dots, k-1)$ 时, 出现 $\mu_i > \mu_j$ 则定义为 μ_j 的一个逆序, 其逆序数 A_j 为 $\mu_i > \mu_j (i > j)$ 出现的次数, 将所有逆序数求总和, 总和则称为时间序列的逆序总数, 逆序总数 A 及其理论均值和理论方差的计算公式如下:

$$A = \sum_{j=1}^{k-1} A_j \quad (2)$$

$$E[A] = \sum_{j=1}^{k-1} E[A_j] = \frac{k(k-1)}{4} \quad (3)$$

$$\sigma_A^2 = \frac{k(2l^2 + 3l - 5)}{72} \quad (4)$$

$$u = \frac{(A + 1/2 - E[A])}{\sigma_A} \quad (5)$$

构造标准正态分布统计量 u , 取显著性水平为 0.05 时, 若 $|u| \leq 1.96$, 则 μ_i 间无显著性差异, $\{x_i\}$ 为平稳时序。

1.3 模型参数估计和适用性检验

AR 模型参数估计方法包括: LS、L-D、Burg 法、极大似然估计法等。为了提高预测模型的精度, 本文采用 UKF 算法^[13]对 AR 模型参数进行预测, 并实时更新和修正模型参数。

AR 模型适用性检验实则为确定模型的最适阶数。目前采用最多的方法是 Akaike 信息准则, 包括: FPE(Final Prediction Error) 准则、AIC(Akaike Information Criterion) 准则、BIC(Bayesian Information Criterion) 准则。本文采用 AIC 准则确定模型阶数, 当 $AIC(n)$ 最小时, n 为模型最适阶数。

$$AIC(n) = N \ln \sigma_a^2 + 2n \quad (6)$$

式中: σ_a 为白噪声方差; N 为时序长度。

1.4 预测模型

模型参数和阶数被确定之后, 可用时序的历史值来预测以后 k 步参数值, 预测模型计算公式如下:

$$\hat{x}(t+k) = \begin{cases} \sum_{i=1}^n \phi_i x(t+k-i) & k=1 \\ \sum_{i=1}^{k-1} \phi_i \hat{x}(t+k-i) + \sum_{i=k}^n \hat{\phi}_i x(t+k-i) & 1 < k \leq n \\ \sum_{i=1}^k \hat{\phi}_i \hat{x}(t+k-i) & k > n \end{cases} \quad (7)$$

2 AR 模型参数估计算法

2.1 RLS 算法

在系统参数估计方面, LS 算法应用非常广泛, 它的基本思想是对线性系统偏差程度进行评估。RLS 由 LS 发展而来, 其基本思想是: 本次的估计值 $\hat{\theta}(t) =$ 上次的估计值 $\hat{\theta}(t-1) +$ 修正项。RLS 算法特别适用于实时辨识, 可使非线性状态方程得到较为准确的结果。RLS 算法具体递推过程如下:

$$e(t) = y(t) - \hat{\theta}(t-1)x(t) \quad (8)$$

$$K(t) = \frac{P(t-1)x(t)}{\lambda + x^T(t)P(t-1)x(t)} \quad (9)$$

$$P(t) = \frac{1}{\lambda} [1 - K(t)x(t)]P(t-1) \quad (10)$$

$$\hat{\theta}(t) = \hat{\theta}(t-1) + K(t)e(t) \quad (11)$$

式中: $e(t)$ 为误差值; $y(t)$ 为系统输入数据; $x(t)$ 为观测值; $\hat{\theta}(t)$ 为参数估计值; $K(t)$ 为 Kalman 滤波增益;

$P(t)$ 为协方差, 设初始值 $P(0) = 10^\alpha$, α 一般为正整数, 本文取为 5; λ 被称为遗忘因子, 取值 0 ~ 1, 越趋近 1, 辨识度越高, 本文取为 1。

2.2 UKF 算法实现参数估计

2.2.1 Kalman 滤波^[14]推导及状态估计

状态空间模型如下:

$$\begin{cases} U(t+1) = RU(t) + W(t) \\ Y(t) = HU(t) + V(t) \end{cases} \quad (12)$$

式中: $U(t)$ 为系统在 t 时刻的状态值; $Y(t)$ 为对应状态的观测值; R 为系统状态转移矩阵; H 为观测矩阵; $W(t)$ 和 $V(t)$ 是互不相关的白噪声。

具体递推过程如下:

状态一步预测方程为:

$$\hat{U}(t+1|t) = R\hat{U}(t|t) \quad (13)$$

状态更新为:

$$\hat{U}(t+1|t+1) = \hat{U}(t+1|t) + K(t+1)\epsilon(t+1) \quad (14)$$

$$\epsilon(t+1) = Y(t+1) - H\hat{X}(t+1|t) \quad (15)$$

滤波增益矩阵为:

$$K(t+1) = P(t+1|k)H^T[HP(t+1|t)H^T + e]^{-1} \quad (16)$$

一步预测协方差阵为:

$$P(t+1|t) = RP(t|t)R^T + Q \quad (17)$$

状态协方差阵更新为:

$$P(t+1|t+1) = [I_n - K(t+1)H]P(t+1|t) \quad (18)$$

由递推过程可知, 通过式(14)和式(18)利用系统的观测值 t 时刻系统状态预测值 $\hat{U}(t+1|t+1)$ 及协方差阵 $P(t+1|t+1)$ 。系统观测值在递推过程中被实时更新和修正, 有效地改善了模型预测精度。

2.2.2 UKF 算法实现 AR 模型参数估计

计算 $2n+1$ 个 Sigma 点, 即采样点, 其中 n 为状态维数。

$$\begin{cases} X^{(0)} = \bar{X} & i=0 \\ X^{(i)} = \bar{X} + (\sqrt{(n+\lambda)P})_i & i=1, 2, \dots, n \\ X^{(i)} = \bar{X} - (\sqrt{(n+\lambda)P})_i & i=n+1, n+2, \dots, 2n \end{cases} \quad (19)$$

式中: $P = (\sqrt{P})^T(\sqrt{P})$; $(\sqrt{P})_i$ 表示矩阵方根的第 i 列。

计算采样点权值:

$$\begin{cases} \omega_m^{(0)} = \frac{\lambda}{n+\lambda} \\ \omega_c^{(0)} = \frac{\lambda}{n+\lambda} + (1-\alpha^2 + \beta) \\ \omega_m^{(i)} = \omega_c^{(i)} = \frac{\lambda}{2(n+\lambda)}, i=1 \sim 2n \end{cases} \quad (20)$$

式中: ω 为权值; 下标 m 为均值; c 为协方差; β 为非负权系数。

设 $\mathbf{X}(t)$ 为 t 时刻系统状态的输入向量, 且 $\mathbf{X}(t) = (x(t-1), x(t-2), \dots, x(t-n))$, $x(t)$ 可由 $\mathbf{X}(t)$ 与参数 $f_i (i=1, 2, \dots, n)$ 加权求和得到。假设 AR 模型参数和飞行参数构建的非线性系统为:

$$\begin{cases} \varphi(t+1) = f(\varphi(t)) + \gamma(t) \\ x(t) = \phi(t)\mathbf{X}^T(t) + \varepsilon(t) \end{cases} \quad (21)$$

式中: $\gamma(t)$ 为高斯白噪声, 其方差为 $Q(t)$, 值为 10^{-4} ; $\varepsilon(t)$ 同为零均值平稳白噪声, 与 $\gamma(t)$ 互不相关, 相互独立, 其方差为 $\sigma_\varepsilon^2 = 10^{-3} \times x(t)$ 。

$\hat{\phi}(t)$ 表示由 t 时刻观测数据 $x(1), x(2), \dots, x(t)$ 所估计的 $n \times 1$ 参数向量, $\hat{\phi}(0) = 0$ 。由 UKF 算法推导过程得:

$$\hat{\phi}^{(i)}(t) = [\hat{\phi}(t) \cdot \hat{\phi}(t) + \sqrt{(n+\lambda)P(t)} \hat{\phi}(t) - \sqrt{(n+\lambda)P(t)}] \quad (22)$$

计算 $2n+1$ 个 Sigma 点集的一步预测, $i=1, 2, \dots, 2n+1$ 。

$$\hat{\phi}(t+1) = f(\hat{\phi}(t)) + \gamma(t) \quad (23)$$

计算系统状态量的一步预测和协方差矩阵:

$$\hat{\phi}(t) = \sum_{i=0}^{2n} \omega^{(i)} \hat{\phi}^{(i)}(t) \quad (24)$$

$$P(t) = \sum_{i=0}^{2n} \omega^{(i)} [\hat{\phi}(t) - \varphi(t)] [\hat{\phi}(t) - \varphi(t)]^T + Q \quad (25)$$

再次使用 UT 变换, 得到新的 Sigma 点集:

$$\hat{\phi}^{(i)}(t) = [\hat{\phi}(t) \cdot \hat{\phi}(t) + \sqrt{(n+\lambda)P(t)} \hat{\phi}(t) - \sqrt{(n+\lambda)P(t)}] \quad (26)$$

将新的 Sigma 点集代入观测方程。

$$x^{(i)}(t) = \hat{\phi}(t)\mathbf{X}^T(t) + \varepsilon(t) \quad (27)$$

式中: \mathbf{X} 为系统输入向量, 其值为:

$$\mathbf{X} = \begin{pmatrix} x(n) & x(n-1) & \cdots & x(1) \\ x(n+1) & x(n) & \cdots & x(2) \\ \vdots & \vdots & & \vdots \\ x(N-1) & x(N-1) & \cdots & x(N-n) \end{pmatrix}$$

计算系统预测均值和协方差。

$$\bar{x}(t) = \sum_{i=0}^{2n} \omega^{(i)} x^{(i)}(t) \quad (28)$$

$$P_{x^{x_t}} = \sum_{i=0}^{2n} \omega^{(i)} [x^{(i)}(t) - \bar{x}(t)] [x^{(i)}(t) - \bar{x}(t)]^T + \sigma_\varepsilon^2 \quad (29)$$

$$P_{\phi^{x_t}} = \sum_{i=0}^{2n} \omega^{(i)} [\hat{\phi}^{(i)}(t) - \bar{x}(t)] [x^{(i)}(t) - \bar{x}(t)]^T \quad (30)$$

计算 Kalman 滤波增益。

$$\mathbf{K}(t+1) = P_{\phi^{x_t}} P_{x^{x_t}}^{-1} \quad (31)$$

式中: $\mathbf{K}(1, 0) = c\mathbf{I}$, \mathbf{I} 为单位矩阵, c 取 2。

系统状态和协方差更新。

$$\hat{\phi}(t+1) = \hat{\phi}(t) + \mathbf{K}(t) [x(t+1) - \hat{x}(t)] \quad (32)$$

$$P(t+1) = P(t) - \mathbf{K}(t) P_{x^{x_t}} \mathbf{K}^T(t+1) \quad (33)$$

式(22) - 式(33)为 UKF 算法对 AR(n) 模型参数实时更新和修正过程, 与 AR 模型构成自适应 AR 模型。自适应 AR 模型预测过程主要包括: 参数估计、模型定阶、模型参数更新及修正、参数预测。以下为稳定巡航飞行参数预测流程如图 1 所示。

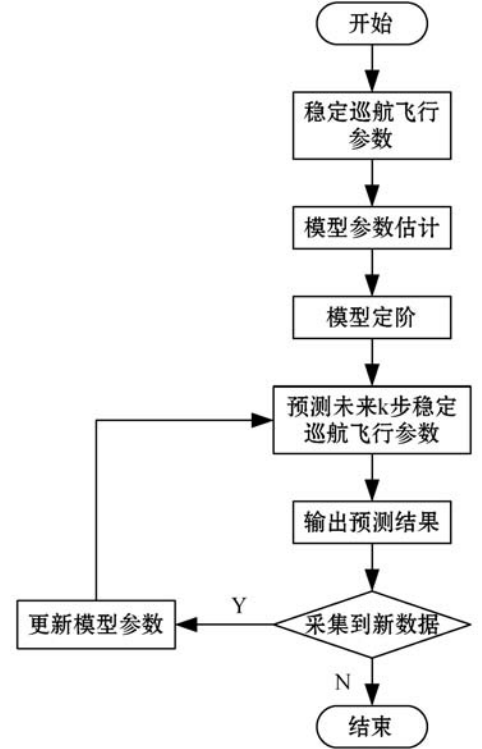


图 1 稳定巡航飞行参数预测流程

3 曲线拟合模型与灰色模型数据预测

3.1 曲线拟合模型

设 n 阶多项式函数^[15] 为:

$$f(x) = a_0 + a_1 \times x + \cdots + a_n \times x^n \quad (34)$$

将已知点代入多项式函数得:

$$\begin{cases} y_1 = a_0 + a_1 \times x_1 + \cdots + a_n \times x_1^n \\ y_2 = a_0 + a_1 \times x_2 + \cdots + a_n \times x_2^n \\ \vdots \\ y_n = a_0 + a_1 \times x_n + \cdots + a_n \times x_n^n \end{cases} \quad (35)$$

式(35)中的所有等式不一定全有解, 换言之, 在 n 阶多项式的曲线下不能拟合每个点, 因此须求出多项式函数中的 y 与真实的 y 之间最小来实现尽量拟合每个点。

将多项式函数代入 $\min[\sum_{i=1}^n (f(x_i) - y_i)^2]$ 得:

$$\min \left[\sum_{i=1}^n (a_0 + a_1 \times x_i + a_2 \times x_i^2 + \dots + a_n \times x_i^n - y_i)^2 \right] \quad (36)$$

对式(36)中的 a_0, a_1, \dots, a_n 求偏导,并令偏导式为 0 求解所有 a ,用矩阵来表达得:

$$\mathbf{X} = \begin{pmatrix} 1 & x_1 & \dots & x_1^n \\ 1 & x_2 & \dots & x_2^n \\ \vdots & \vdots & & \vdots \\ 1 & x_n & \dots & x_n^n \end{pmatrix} \quad \mathbf{Y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$$

矩阵可简化为 $\mathbf{X}^T \mathbf{X} \mathbf{a} = \mathbf{X}^T \mathbf{Y}$,所以得到:

$$\mathbf{a} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \quad (37)$$

3.2 灰色预测模型 GM(1,1)

灰色预测模型^[16-17]通常由 $GM(a, b)$ 表示, a 表示阶数, b 表示维数。目前工程中应用最多的是 $GM(1, 1)$ 模型,下面是 $GM(1, 1)$ 的具体推导过程。

原始数据如下:

$$x^{(0)} = \{x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(m), \dots, x^{(0)}(n)\}$$

对原始数据一次累加处理得

$$x^{(1)}(m) = \sum_{i=1}^m x^{(0)}(i) \quad (38)$$

得到新数据列为

$$x^{(1)} = \{x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(m), \dots, x^{(1)}(n)\}$$

对所得新数据列建立一阶微分方程,计为 $G(1, 1)$:

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = u \quad (39)$$

式中: a 为发展系数; u 为灰色作用量。设 \hat{a} 为带估计参数向量, $\hat{a} = [a, u]^T$,利用最小二乘法求解待估计向量:

$$\hat{a} = (\mathbf{B}^T \mathbf{B})^{-1} \mathbf{B}^T \mathbf{y}_n \quad (40)$$

$$\mathbf{B} = \begin{pmatrix} -\frac{1}{2}[x^{(1)}(2) + x^{(1)}(1)] & 1 \\ \vdots & \vdots \\ -\frac{1}{2}[x^{(1)}(n) + x^{(1)}(n-1)] & 1 \end{pmatrix}$$

$$\mathbf{y}_n = [x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(n)]^T$$

求解式(39)可得 a 和 u ,并代入式(38),求解微分方程:

$$\hat{x}^{(1)}(m+1) = \left[x^{(0)}(1) - \frac{u}{a} \right] e^{-am} + \frac{u}{a} \quad (41)$$

对 $\hat{x}^{(1)}(m+1)$ 做累减还原数据:

$$\hat{x}^{(0)}(m+1) = \hat{x}^{(1)}(m+1) - \hat{x}^{(1)}(m) \quad (42)$$

当 $m < n$ 时, $\hat{x}^{(0)}(m)$ 为模型的模拟值;当 $m > n$ 时, $\hat{x}^{(0)}(m)$ 为模型的预测值。

3.3 GM(1,1) 模型精度检验

精度检验通常采用后验差法,即后验差比 $C =$

S_2/S_1 ,小误差概率 $P = P\{|e(m) - \bar{e}| < 0.674 5S_1\}$,其中 e 为残差, S_1, S_2 分别为原始数据列和残差数据列的均方差。模型的精度由 C 和 P 决定。

表 2 精度检验等级参照表

模型精度等级	均方差比值 C	小误差概率 P
1 级(好)	$C < 0.35$	$P > 0.95$
2 级(合格)	$C < 0.45$	$P > 0.80$
3 级(勉强)	$C < 0.50$	$P > 0.70$
4 级(不合格)	$C \geq 0.65$	$P \leq 0.70$

4 仿真算例

根据数据筛选标准对两组发动机样本数据进行筛选,最终选择满足筛选条件部分数据作为研究所需数据源,共计 200 s 即 200 步,取前 180 步的数据即前 180 s 为 AR 模型输入数据。分别利用 LS、RLS、自适应 Kalman 滤波及 UKF 算法对 AR 模型参数进行估计。

本着计算速度、阶次不要太高且符合实际的原则,确定采用搜索阶次为 60 的方案进行模型适用性检验,采用 AIC 准则确定模型的最适阶数结果如表 3 所示。


表 3 AIC 准则确定模型阶数

参数名称	LS	RLS	自适应 Kalman	UKF
燃油流量	10	4	2	1
EGT	11	5	2	1

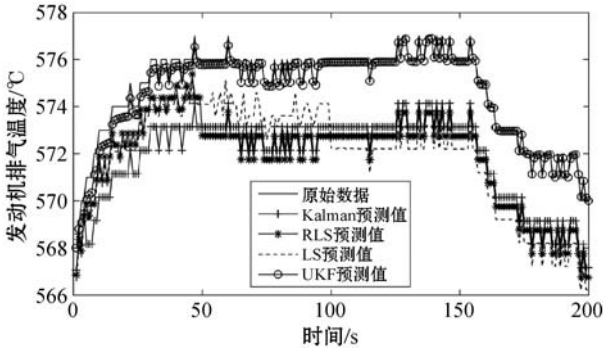
通过筛选获取稳定巡航数据,首先需验证其特性,研究采用逆序法,在显著性水平在 0.05 的条件下,得到燃油流量、EGT 这两组数据的标准正态分布统计量 $|u|$ 值分别为 1.549 6、1.200 1,均小于 1.96,说明样本数据列可作为 AR 模型输入的稳定时间序列。

4.1 LS、RLS、自适应 Kalman 及 UKF 仿真对比

从图 2 可以看出,由上述四种算法估计模型参数所建立的 AR 模型拟合效果良好,可充分说明所建模型的准确性;同时看到 UKF 算法拟合曲线更接近原始数据曲线,说明由 UKF 算法所建自适应 AR 模型最优。因为稳定时间为 60 s,将 200 s 的时间分为四段,同时参考表 1 飞机稳定工作状态下的筛选标准,由两组发动机参数预测曲线可以看出,模型的预测值在稳定时间内燃油流量的波动小于 150 kg/h,EGT 的波动范围也小于 18 °C,说明提出的自适应 AR 模型可有效预测飞行参数,且当前时间段内飞机性能良好,为监控飞机状况提供准确的依据。



(a) 燃油流量预测曲线



(b) 发动机排气温度预测曲线

图2 稳定巡航数据样本预测曲线

通过前 180 步的预测曲线拟合效果可以估计到后 20 步的预测也应该比较理想,为了验证猜想的正确性,研究采用相对均方误差 $\xi(i = N + 1, \dots, N + k)$ 作为预测评价指标对后 20 步的预测效果进行评估,不同预测步数的相对均方误差结果如表 4 所示。

$$\xi = \frac{\sqrt{\frac{1}{k} \sum_{l=N+1}^{N+k} [\hat{x}(t+l) - x(t+l)]^2}}{\max\{|x(i)|\}} \times 100\% \quad (43)$$

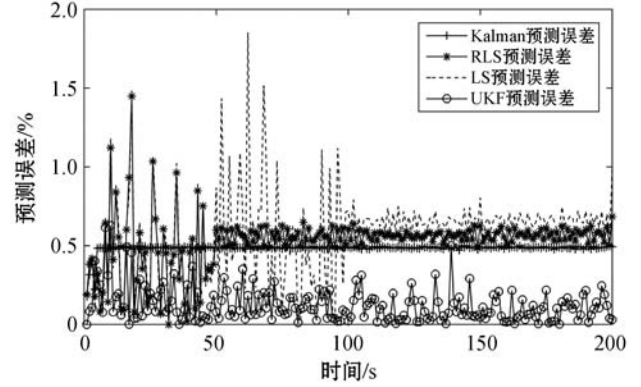
式中: k 为预测数据个数, $k = \{5, 10, 15, 20\}$,预测步数 $l = \{1, 2, \dots, k\}$ 。

表 4 不同步数预测结果相对均方误差对比

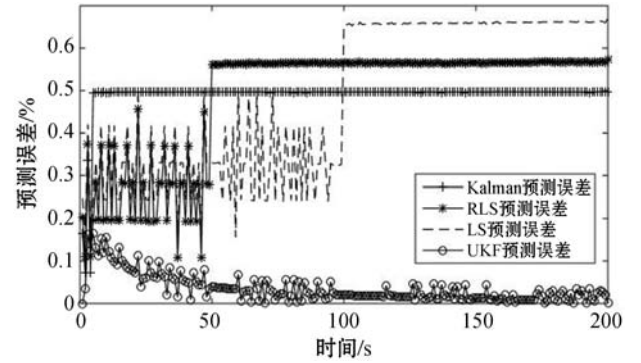
稳定巡航参数	算法	时间 t 内的相对均方误差%		
		5 s	10 s	15 s
燃油流量	LS	0.278 3	0.580 7	0.577 1
	RLS	0.248 8	0.551 1	0.545 6
	Kalman	0.130 5	0.232 3	0.230 8
	UKF	0.097 4	0.115 8	0.114 1
EGT	LS	0.334 3	0.333 5	0.344 7
	RLS	0.273 4	0.272 8	0.284 0
	Kalman	0.145 6	0.145 5	0.145 3
	UKF	0.186 1	0.121 4	0.108 2

大量时序模型在工程上的应用结果表明,预测误差在 15% 以内说明模型可用,超过该值则认为预测不可靠,需要重新建模。从图 3 可以看出,两组数据预测

误差均远小于 15%, EGT 预测误差最大值小于 0.2%, 燃油流量预测误差最大值小于 0.5%, 说明模型预测数据精度非常高。UKF 算法所得系统的预测误差明显小于其他三种算法,说明 UKF 算法更优,可以有效地提高模型预测精度。另外从预测误差曲线可以看出,预测误差曲线趋于平稳的步数不同,分别为 UKF 算法 < 自适应 Kalman 滤波算法 < RLS 算法 < LS 算法,由此说明算法收敛的速度分别为 UKF 算法 > 自适应 Kalman 滤波算法 > RLS 算法 > LS 算法。



(a) 燃油流量预测误差曲线




(b) 发动机排气温度预测误差曲线


图3 稳定巡航数据样本预测误差曲线

4.2 自适应 AR 模型、曲线拟合模型及灰色模型仿真对比

利用三种预测模型对两组样本数据进行仿真验证,这里只对比基于 UKF 算法建立的自适应 AR 模型,两组数据基于三种预测模型的拟合曲线如图 4 所示。



(a) 燃油流量



(b) 发动机排气温度

图4 稳定巡航数据样本各模型预测拟合曲线

曲线拟合模型对于不同阶数预测效果不同,阶数太低误差较大,阶数太高反而也不好,在实际的仿真过程中最终确定两组数据采用阶数为33效果最佳。

灰色模型预测精度检验是通过均方差比值 C 和小误差概率 P 值来确定, C 值越小, P 值越大说明灰色预测精度越高。两组样本数据精度检验结果如表5所示。

表5 样本数据灰色模型预测精度检验

参数名称	均方差比值 C	小误差概率 P
燃油流量	0.442 3	1
EGT	0.573 6	0.88

由图4可以看出,自适应AR模型的预测效果最优,灰色模型的预测效果最差,通过与曲线拟合模型和灰色模型对比,本文提出的自适应AR模型预测精度最高,可有效实现稳定巡航飞行参数的趋势预测。

5 结 语

仿真结果表明,研究提出的基于UKF算法建立的自适应AR模型在预测的准确性、算法收敛速度方面均优于其他三种算法。此外和另外两种QAR数据预测模型相比,也明显占优。

1) UKF算法在AR模型参数估计的递推过程中,利用了系统输入的全部数据信息且对于非线性系统有着更高的预测精度,预测误差较其他三种算法更小;在模型阶数方面,基于UKF算法建立的自适应AR模型阶数更低,由此说明,在预测过程中模型所需的数据量少,计算量少,运行速率更快,算法的收敛速度也更高。

2) 在数据预测方面,基于UKF算法的自适应AR模型准确性更高,它有很好的预测性,且较传统的预测模型精度更高。QAR数据在记录过程中,难免会受到各种因素导致部分数据缺失,此时可以由模型当前时刻的预测值来代替这些缺失值,这样可以很好地解决

由于数据缺失所带来的数据预测精度降低的问题。准确的飞行数据趋势预测可以有效地监控与该数据对应的子系统是否处于健康状态。因此,本研究在飞机维修保障、状态监控与预测方面具有重要意义。

参 考 文 献

- [1] 陈聪,师利中,高洁,等. 基于QAR数据的飞机燃油流量预测[J]. 控制工程,2019(4):752-758.
- [2] 张建业,张鹏. 飞行数据的时间序列分析方法及其应用[M]. 北京:国防工业出版社,2013:51-67.
- [3] 马深漂,罗正华,胡德昆. 融合型AR模型在雷达故障预测中的应用[J]. 现代电子技术,2020,43(11):20-23.
- [4] Sim K S, Lim M S, Yeap Z X. Performance of signal-to-noise ratio estimation for scanning electron microscope using auto-correlation Levinson-Durbin recursion model[J]. Journal of Microscopy 016.
- [5] 黄颖,施清平,任延群. 多普勒信号的Burg算法优化研究[J]. 测控技术,2019,38(3):84-87.
- [6] 谷乐,陈志云. 加权最小二乘法与卡尔曼滤波实时稳像技术[J]. 计算机应用研究,2019,36(10):3121-3123.
- [7] 李良,李友年,陈星阳. 基于广义最小二乘法的空空导弹幅值滤波器设计方法[J]. 航空兵器,2020,27(1):46-51.
- [8] 杨明,屈婉莹,陈扬祥,等. 基于变周期递推最小二乘法与卡曼观测器的伺服系统在线惯量辨识[J]. 电工技术学报,2018,33(S2):367-376.
- [9] 罗琴琴,苏建徽,林志光,等. 基于递推最小二乘法的虚拟同步发电机参数辨识方法[J]. 电力系统自动化,2019,43(1):215-221.
- [10] 汪龚,魏民祥,赵万忠,等. 基于递推最小二乘法与模糊自适应扩展卡尔曼滤波相结合的车辆状态估计[J]. 中国机械工程,2017,28(6):750-755.
- [11] Wang Qianxin, Hu Chao, Xu Tianhe, et al. Impacts of Earth Rotation Parameters on GNSS Ultra-rapid Orbit Prediction: Derivation and Real time Correction[J]. Advances in Space Research, 2017, 60(12):2855-2870.
- [12] 彭秀艳,王茂,刘长德. AR模型参数自适应估计方法研究及应用[J]. 哈尔滨工业大学学报,2009(9):12-16.
- [13] 侯敏,甄子洋,龚华军. 基于自适应AR模型的甲板运动预估技术[J]. 飞行力学,2018,36(3):33-36.
- [14] 崔锦泰,陈关荣. 卡尔曼滤波及其实时应用[M]. 北京:清华大学出版社,2013:73-85.
- [15] 刘立坤,霍幸莉,王东森,等. 曲线拟合频域分解法在颤振试飞中的应用[J]. 飞行力学,2019,37(1):85-88.
- [16] 陈农田,张宏钰,曹玉宽. 基于灰色马尔科夫理论的进近着陆不安全事件预测[J]. 数学的实践与认识,2020(4):306-314.
- [17] 王涛,刘建华,杨亚磊,等. 基于灰色组合模型的飞机地面面积霜预测[J]. 计算机仿真,2020,37(7):72-77.