

QAR 数据的数据融合算法^①

谷润平^{1,2}, 黄磊^{1,2}, 赵向领¹

¹(中国民航大学 空中交通管理学院, 天津 300300)

²(天津市空管运行规划与安全技术重点实验室, 天津 300300)

摘要: 分析了 QAR 数据中影响飞机性能衰减的主要因素, 采用自适应加权数据融合算法和扩展卡尔曼滤波算法对相关性能参数进行了状态参数的估计, 并验证了自适应加权融合算法在外界环境影响较小时的便捷性和外界环境影响过大时的局限性. 引入扩展卡尔曼滤波算法, 加入高斯噪声的计算, 提高了状态估计值的精确度, 为航空公司改善飞机运行提供了参考.

关键词: QAR; 融合算法; 最适应加权融合; 扩展卡尔曼滤波; 飞机性能

Data Fusion Algorithm Based on QAR Data

GU Run-Ping^{1,2}, HUANG Lei^{1,2}, ZHAO Xiang-Ling¹

¹(College of Air Traffic Management, Civil Aviation University of China, Tianjin 300300, China)

²(Tianjin Key Laboratory of Operation Programming and Safety Technology of Air Traffic Management, Tianjin 300300, China)

Abstract: This paper analyses the main factors affecting aircraft performance degradation in QAR data, uses the optimal weighted data fusion algorithm and the extended Kalman filter algorithm for the estimation of state parameter which are related to aircraft performance parameters. When there is less external environment effect, the convenience of the optimal weighted fusion algorithm is verified, and when the effect is overlarge, the precision of this algorithm is limited. Thus we use the extended Kalman filter algorithm, take Gauss noise into account, and improve the accuracy of state estimate for the airline to improve the operation of the aircraft provides a reference.

Key words: QAR; data fusion algorithm; adaptive weighted fusion; extended Kalman filter; aircraft performance

1 引言

QAR(Quick Access Recorder)数据是飞机飞行品质和发动机状态监控的重要数据来源^[1]. 其记录容量为 128MB, 可连续记录时间高达 600 小时, 可以同时采集上百个飞行数据, 涵盖了飞机飞行操纵品质监控的绝大部分参数^[2]. 正是因为 QAR 数据庞大而复杂, 如何从这些数据里面提取到所需的可靠而精确的数据, 就显得至关重要. 这也是飞机性能研究人员进行飞机性能分析的前提与基础.

多传感器融合算法是充分利用多个传感器观测的数据, 通过对观测数据的合理支配和使用, 将多传感器在空间或时间上冗余或互补信息依据某种准则来进

行组合, 使系统得到的数据更加完整与可靠. 增强系统的生存能力, 提高了系统的鲁棒性和可靠性^[3].

传统多传感器融合方法有加权平均法, 卡尔曼滤波法, 贝叶斯估计, 统计决策理论, 神经网络, 模糊推理等方法. 由于机载 QAR 数据量庞大, 随飞机性能衰减而变化. 贝叶斯决策与模糊推理融合方法不适宜在动态环境运行, 统计决策理论的使用范围在高层数据. 利用神经网络方法虽然可以得到更精确的数据估计值, 但是时间成本较高. 所以本文利用自适应加权数据融合算法和扩展卡尔曼信息滤波算法两种方法, 对 QAR 数据进行处理, 得出飞机性能相关参数的状态估计值, 对两种方法进行对比分析与综合利用, 得到

① 基金项目: 国家科技支撑计划(2011BAH24B10); 中国民航大学科研基金(08CAUC-E08); 中国民航大学科研启动基金(08QD16X); 中央高校基本科研业务费(3122014D042)

收稿时间: 2015-04-17; 收到修改稿时间: 2015-06-08

可以用来研究和监控的飞行数据。

2 自适应加权数据融合算法

自适应加权融合算法可以根据各个传感器所得到的测量值自适应地寻找其对应的权值来达到最优的融合结果^[4]。由于机载 QAR 数据具有时间和空间上的连续性，对于影响飞机性能的燃油里程、所需推力、燃油流量以及发动机转速等参数进行最优状态估计值^[5]，这些估计结果会更接近于飞机当前所状态值，可以作为性能工作人员研究分析的依据。

2.1 算法定义

本文假定共有四个观测目标，即四个与性能相关的参数：燃油流量、所需推力、燃油里程、发动机转速。

定义 $s_i, i=(1,2,...n)$ 为第 i 个信息传感器， $X_{i,j}, i=(1,2,...n), j=(1,2,3,4)$ 为第 i 个传感器对应于第 j 个目标的观测信息，各传感器均方误差为 $\sigma_{i,j}^2, i=(1,2,...n)$ ，其中 σ_i^2 代表了第 i 个传感器观测信息的精度， $\sigma_{i,j}^2$ 越大，表明这个传感器精度越差，反之， $\sigma_{i,j}^2$ 越小，表明这个传感器精度越好。表 1 为观测信息表。

表 1 多传感器观测值

s_1	$X_{1,1}$	$X_{1,2}$	$X_{1,3}$	$X_{1,4}$
s_2	$X_{2,1}$	$X_{2,2}$	$X_{2,3}$	$X_{2,4}$
...
s_n	$X_{n,1}$	$X_{n,2}$	$X_{n,3}$	$X_{n,4}$

假设真实值 $X_{\bullet,j} = (X_{1,j}, X_{2,j}, \dots, X_{n,j})$ 的状态估计量 $\hat{X}_{\bullet,j}$ 满足以下两个条件：

1) $\hat{X}_{\bullet,j}$ 是 $X_{\bullet,j}$ 的无偏估计，

$$E(X_{\bullet,j}) = \hat{X}_{\bullet,j} \quad (1)$$

2) $\hat{X}_{\bullet,j}$ 的均方误差最小，即

$$esp(\hat{X}_{\bullet,j}) = E((\hat{X}_{\bullet,j} - X_{\bullet,j})(\hat{X}_{\bullet,j} - X_{\bullet,j})^T)_{min} \quad (2)$$

此时，我们可以定义 $\hat{X}_{\bullet,j}$ 是真实值 $X_{\bullet,j}$ 的最优状态量估计。由多传感器融合算法定义可知，状态估计量 $\hat{X}_{\bullet,j}$ 是各传感器观测值的线性组合：

$$\hat{X}_{\bullet,j} = \sum_{i=1}^n W_{i,j} X_{i,j} \quad (j=1,2,3,4) \quad (3)$$

$$\sum_{i=1}^n W_{i,j} = 1, (W_{i,j} \in (0,1), j=(1,2,3,4)) \quad (4)$$

下图为自适应数据融合算法模型图：




图 1 自适应数据融合算法模型图

2.2 证明权值的唯一性

由 $\hat{X}_{\bullet,j}$ 的均方误差：

$$esp(\hat{X}_{\bullet,j}) = E((\hat{X}_{\bullet,j} - X_{\bullet,j})(\hat{X}_{\bullet,j} - X_{\bullet,j})^T)_{min} = E[\sum_{i=1}^n W_{i,j}^2 (X_{i,j} - X_{\bullet,j})(X_{i,j} - X_{\bullet,j})^T + \sum_{i=1, j=1}^n W_{i,j}^2 (X_{i,j} - X_{\bullet,j})(X_{i,j} - X_{\bullet,j})^T] \quad (5)$$

由于传感器之间相互独立，且是 $X_{\bullet,j}$ 的无偏估计，所以有：

$$\sum_{i=1, j=1}^n W_{i,j}^2 (X_{i,j} - X_{\bullet,j})(X_{i,j} - X_{\bullet,j})^T J = 0 \quad (6)$$

$$esp(\hat{X}_{\bullet,j})_{min} = E[\sum_{i=1}^n W_{i,j}^2 (X_{i,j} - X_{\bullet,j})(X_{i,j} - X_{\bullet,j})^T] = \sum_{i=1}^n W_{i,j}^2 \sigma_i^2 \quad (7)$$

此时，对于第 j 个观测目标来说，根据

$$f(W_1, W_2, \dots, W_n) = \sum_{i=1}^n W_i^2 \sigma_i^2 \quad (8)$$

最小原则，对函数求偏导：

$$\begin{cases} \frac{\partial f}{\partial W_i} = 0 \\ \sum_{i=1}^n W_i = 1 \end{cases}, i=(1,2,\dots,n) \quad (9)$$

解上述方程组可得：

$$W_i = \frac{1}{\sigma_i^2 \sum_{i=1}^n \frac{1}{\sigma_i^2}} \quad (10)$$

此时最优估计量 $\hat{X}_{\bullet,j}$ 的值为：

$$\hat{X}_{\bullet,j} = \sum_{i=1}^n \frac{X_{i,j}}{\sigma_i^2 \sum_{i=1}^n \frac{1}{\sigma_i^2}} \quad (11)$$

从这个公式可以看出，只要确定每个传感器的测量误差，第 j 个目标的最优估计值 $\hat{X}_{\bullet,j}$ 就只与每个传感器的测量值有关，而且是唯一的。

2.3 计算 QAR 参数最优估计值

由于在 QAR 中数据是每隔四秒记录一次, 每次记录四个数据, 假设飞机上有四个记录相关飞机性能参数的传感器. 如果飞机巡航高度一定, 由公式:

$$F_n = D = 1/(2\rho S V^2 C_D) \quad (12)$$

其中 F_n 为所需推力, D 为飞机阻力, ρ 为此高度层空气密度, V 为此刻飞机真空速, S 是飞机翼展, C_D 是阻力系数. 此时由于飞机处于巡航阶段, 空气密度与阻力系数基本不变, 翼展固定, 此时飞机所需推力只与真空速平方成正比, 可以用 v^2 代表飞机所需推力. 飞机发动机转数用 $N1$ 来表示. 本文利用了 1776 组 QAR 数据对与飞机性能相关的四个参数进行最优估计. 表 2 为计算后各传感器权值的值.

表 2 各传感器权值大小

W	Ch	Fn	$N1$	SR
$s1$	0.2403	0.2517	0.2429	0.2442
$s2$	0.2499	0.2506	0.2495	0.2497
$s3$	0.2544	0.2494	0.2530	0.2526
$s4$	0.2555	0.2483	0.2545	0.2535

上表中 Ch 代表燃油流量, Fn 为所需推力, $N1$ 为发动机转速, SR 为燃油里程. $s1-4$ 为四个传感器. 此时可以得出上述四个参数的最优估计参数值, 如表 3 所示.

表 3 最适应参数估计值

	$Ch(KG/H)$	$Fn(V^2)$	$N1(转速)$	$SR(NAM/T)$
\hat{X}	1501.6	181243.2	86.8566	284.2406

下图第一个图形是关于燃油流量的测量值与估计值的曲线图, 第二个图形是飞机所需推力的测量值与估计值曲线图, 第三个图是发动机转速的测量值与估计值曲线图, 第四个图是飞机燃油里程的测量值与估计值的曲线图.

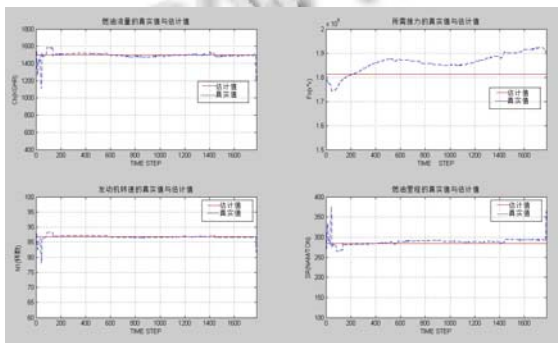


图 2 目标观测值与估计值曲线图

从图形中我们可以到, 飞机在巡航阶段, 飞机的燃油流量、燃油里程和发动机转速基本维持在一定的波动范围内, 可以用最适应加权算法进行最优评估. 但是由于飞机所需推力受到外界影响因子干扰, 对飞机所需推力进行最优加权时不能准确预测飞机所需推力大小. 为此, 为了评估噪声对所需推力的影响, 引入了卡尔曼滤波方法.

3 扩展卡尔曼滤波算法模型

卡尔曼滤波是一种利用线性系统状态方程, 通过系统输入输出观测数据, 对系统状态进行最优估计的算法^[6,7]. 它采用信号与噪声的状态空间模型, 利用前一时刻的估计值和当前时刻的观测值来进行对状态变量的估计, 得到当前时刻的估计值, 适合于实时处理和计算机运算.

而在实际的应用过程中, 有些传感器中的测量值会随着外界环境因素的变化, 发生一种非线性的变化, 这时候卡尔曼滤波的状态估计值也是非线性变化. 此时, 采取扩展卡尔曼滤波算法^[8].

3.1 算法定义

假设目标状态方程为如下:

$$X(k+1) = f[k, X(k)] + G(k)U(k) \quad (13)$$

其中状态矢量 $X(k)$ 为 4 维向量, 表示为燃油流量、所需推力、燃油里程、发动机转速在 k 时刻的状态值, $U(k)$ 是 k 时刻动态噪声, $G(k)$ 是系统控制矩阵. 满足高斯白噪声条件:

$$E(U(k)) = 0$$

$$E(U(k)U^T(j)) = Q(k)\sigma_{kj} \quad (14)$$

其中

$$\sigma_{kj} = \begin{cases} 0, & k \neq j \\ 1, & k = j \end{cases} \quad (15)$$

假设 k 时刻用于观测目标的观测矢量为 $Y(k)$, 此时定义:

$$Y(k) = h[k, X(k)] + N(k) \quad (16)$$

$N(k)$ 是 k 时刻 n 维动态过程噪声, 满足高斯白噪声条件:

$$E(N(k)) = 0$$

$$E(N(k)N^T(j)) = R(k)\sigma_{kj} \quad (17)$$

其中

$$\sigma_{kj} = \begin{cases} 0, & k \neq j \\ 1, & k = j \end{cases} \quad (18)$$

3.2 模型建立

假设已知 k 时刻目标状态 $X(k)$ 的状态值为 $\hat{X}(k/k)$, 协方差矩阵为 $C(k/k)$, 为了得到 $(k+1)$ 时刻的目标状态预测值, 本文对式(13)进行泰勒级数展开^[7], 取二阶项, 来产生二阶扩展卡尔曼方程式:

$$X(k+1/k) = f[k, \hat{X}(k/k)] + f_x(k)[X(k) - \hat{X}(k)] + \frac{1}{2} \times \sum_{i=1}^n e_i [X(k) - \hat{X}(k)] f_{xx}^i(k) [X(k) - \hat{X}(k)]^T + (\text{高阶项}) + G(k)Q(k)G^T(k) \quad (19)$$

其中, e_i 是第 i 个基向量,

$$f_x(k) = [\nabla_x f(k, X)]_{X=\hat{X}(k/k)} \quad (20)$$

$$f_{xx}^i(k) = [\nabla_x \nabla_x^T f^i(k, X)]_{X=\hat{X}(k/k)} \quad (21)$$

此时, 从 k 时刻到 $k+1$ 时刻的状态估计是通过取以观测矢量 $Y(k)$ 为条件的期望值, 并略去高阶项得到的, 此时有

$$\hat{X}(k+1/k) = f[k, \hat{X}(k/k)] + \frac{1}{2} \times \sum_{i=1}^n e_i \text{tr}[f_{xx}^i(k)C(k)] \quad (22)$$

计算预估协方差矩阵:

$$C(k+1/k) = f_x(k)C(k)f_x^T(k) + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n [e_i e_j^T \text{tr}(f_{xx}^i(k)C(k)f_{xx}^j(k)C(k))] + G(k)Q(k)G^T(k) \quad (23)$$

同理, 可以知道, 对于二阶滤波, 观测矢量的预测值

$$Y(k+1/k) = h[k+1, \hat{X}(k+1/k)] + \frac{1}{2} \times \sum_{i=1}^n e_i \text{tr}[h_{xx}^i(k+1)C(k+1)] \quad (24)$$

与其相伴的协方差是:

$$S(k+1/k) = h_x(k+1)C(k+1)h_x^T(k+1) + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n [e_i e_j^T \text{tr}(h_{xx}^i(k+1)C^2(k+1)h_{xx}^j(k+1))] + R(k+1) \quad (25)$$

计算卡尔曼增益矩阵:

$$K(k+1) = C(k+1/k)h^T(k+1)S^{-1}(k+1) \quad (26)$$

状态滤波值:

$$\hat{X}(k+1/k+1) = \hat{X}(k+1/k) + K(k+1)(Y(k+1) - \hat{Y}(k+1/k)) \quad (27)$$

计算后更新的滤波协方差矩阵为:

$$C(k+1/k+1) = C(k+1/k) - K(k+1)S(k+1)K^T(k+1) \quad (28)$$

重复以上步骤, 就可以建立卡尔曼滤波模型。

3.3 利用扩展卡尔曼滤波模型处理数据

在研究影响飞机性能参数变化规律的过程中, 如图 2 所示, 飞机的所需推力大小一直受水平风、外界温度和大气压强等干扰因子的影响, 并不像飞机燃油流量与燃油里程一样维持在一个恒定的波动范围内。采用扩展卡尔曼滤波算法, 加入外界干扰因子作为随机噪声, 可以很好的预测参数值变化规律。

下图中第一副图是扩展卡尔曼滤波下的燃油流量的真实值与预测值对比曲线图。第二幅图是飞机所需推力的真实值与卡尔曼滤波估计值对比曲线图。第三幅图是飞机发动机转速的真实值与预测值曲线图。第四幅图是飞机燃油里程随时间变化的真实值与预测值曲线图。




图 3 卡尔曼滤波下的目标观测值与估计值曲线图

通过对比分析图 2 与图 3, 可以看出, 飞机在巡航阶段, 飞机的燃油流量、燃油里程与发动机转速基本维持在一个非常小的波动范围内, 受到外界环境因素影响不是特别明显。可以用最适应加权融合算法预测出最优估计值。但是飞机所需推力和外界环境因子联系紧密, 只用最适应加权算法不能准确预测出其变化。而采用扩展卡尔曼滤波算法可以较好的预测出其变化规律。下图为自适应加权融合方法与卡尔曼滤波算法得出的估计值与真实值之间的关系图。




图 4 两种算法下的目标观测值与估计值曲线图

本文对四个传感器的 1667 组 QAR 数据过程中,对两种算法的运算时间代价进行了对比,如表 4 所示。

表 4 3 种融合方法的时间代价

方法	OWDF	EKF
运行时间(s)	0.741	0.751

由上表可知,对于飞机性能人员来说,在处理数十上百万的底层 QAR 数据时,从时间代价和精确度上来说,综合考虑最优加权和扩展卡尔曼算法是比较合适的。

4 分析与结论

本文采用最适应加权融合建模方法和扩展卡尔曼滤波算法对影响飞机性能的四个基本参数进行了处理与分析。经过证明,在外界干扰较小的情况下,采用自适应加权融合算法和卡尔曼滤波算法两种方法,目标参数的预测和更新收敛较快,对目标参数的跟踪没有发散。但是在外界环境因子影响较大情况下,采用自适应加权融合算法的目标参数会逐渐发散,而采用扩展卡尔曼滤波算法时目标参数依旧收敛较快。

飞机性能人员在研究与性能相关参数时,可以根据性能参数与外界环境因子相关度的大小选取适当的

估计模型来进行研究。为飞机衰减状况监控、飞机燃油预测、飞行计划制定等方案提供高效准确的数据支撑。

参考文献

- 1 曹惠玲,贾超.基于 QAR 的民航发动机燃油流量控制规律研究.科学技术与工程,2013,(13):3814-3817,3827.
- 2 周百政.QAR 数据处理系统的设计与实现[硕士学位论文].天津:中国民航大学,2009.
- 3 Hal DL, Llinas J. An introduction to multisensor data fusion. Proc. IEEE, 2004, 85(1): 6-23.
- 4 王炯琦,周海银.最优估计的数据融合理论.应用数学, 2007,(2):392-399.
- 5 孔成安,李文华.利用 QAR 数据实施飞机性能监控.中国民用航空,2008,(10):54,56.
- 6 程琤.多传感器目标跟踪中的数据融合理论与算法[硕士学位论文].西安:西北工业大学,2007.
- 7 肖雷.多传感器最优估计与融合算法[硕士学位论文].西安:西安电子科技大学,2009.
- 8 潘丽娜.基于扩展卡尔曼滤波的多传感器目标跟踪.舰船电子工程,2010,(12):71-72,154.