基于多传感器不完全量测下的机动目标跟踪算法

李 松 胡振涛 李 晶 杨 昭 金 勇
(河南大学图像处理与模式识别研究所 开封 475001)

摘 要 针对传感器探测概率小于1的不完全量测情况下的非机动目标跟踪问题,提出一种基于多传感器不完全量测下的扩展Kalman滤波算法。首先,利用残差检测的野值剔除方法,确定目标状态估计过程中传感器是否接收到正确的量测数据;其次,基于每个传感器的量测数据,在不完全量测下采用改进的扩展卡尔曼滤波算法分别对目标运动状态进行估计;进而结合多传感器最优加权融合方法求解基于多传感器观测数据的状态估计;最后,将算法应用到光电跟踪系统中。仿真实验得到不完全量测下传感器探测概率对滤波效果的影响,验证了算法的有效性,其跟踪精度接近完全量测下的状态估计精度。

关键词 目标跟踪,不完全量测,扩展Kalman滤波,信息融合
中图法分类号 TP391 **文献标识码** A

Multi-sensor Information Fusion Motivate Target Tracking Algorithm Based on Missing Measurements

LI Song HU Zhen-tao LI Jing YANG Zhao JIN Yong
(Institute of Advanced Control and Intelligent Information Processing, Henan University, Kaifeng 475001, China)

Abstract In allusion to the situation with missing measurements in which the sensor detecting probability is less than 1, a multi-sensor information fusion motivate target tracking algorithm based on missing measurements was proposed. First of all, based on the algorithm of residual error detection, the wild values from the observed data are distinguished, and accuracy of the measurement data can be determined during the state estimation process of dynamic system. Secondly, according to the improved EKF algorithm based on the conditions with missing measurements, the target motion state is estimated by use of every sensor node's measurement data respectively, and then the multi-sensor optimal weighte fusion method is utilized to obtain the optimal estimation based on multi-sensor measurement data. Finally, the influence of the probability of the sensor detection on the filtering effect is obtained by simulation experiments using photoelectric sensors. And the simulation results demonstrate the effectiveness of the algorithm. Additionally, the algorithm's tracking accuracy is mostly approximate to the state estimation accuracy under the situation of complete measurements.

Keywords Maneuvering target tracking, Incomplete measurement, EKF, Multi-sensor information fusion

1 引言

机动目标跟踪领域的研究工作大都假设测量数据无缺失,但在实际应用中,由于障碍物遮挡、传感器本身故障、环境中一些不确定因素影响等原因,造成传感器的探测概率往往小于1,该情况下的目标跟踪问题便成为不完全量测下的目标跟踪问题。近年来,国内外一些学者针对不完全测量下的滤波器的设计进行了研究和探索,并取得了一定的成果。在不完全量测下滤波器性质的研究方面,Sinopoli等给出了不完全量测下的卡尔曼滤波的相关结果,讨论了滤波收敛的临界探测率和估计协方差的上下界问题[1];许志刚、盛安东等研究了离散系统修正Riccati差分方程(MRDE)与数据丢失位置之间的关系以及不完全量测下滤波方差的期望收敛性的问题[2,3],为不完全量测下的机动目标跟踪问题的研究提供了理论基础。针对不完全量测下的机动目标状态估计问题,Craig等研究了数据存在不规律丢失情况下的状态估计方法[4],Boers等则讨论了不完全测量下的最优估计问题[5],王国宏等基于最小均方差给出了不完全测量下的一个递归估计器[6],高会军等对不完全量测下非线性系统的模糊滤波问题进行了研究[7]。以上文献总结出不完全量测下的状态估计模型,并提出一些解决不完全量测问题的滤波算法。但以上算法均基于单传感器量测数据,若量测数据含扰动量较大,则滤波精度仍会受到影响。因而,闫丽萍等研究了基于不完全观测数据的异步多速率传感器时不变系统的信息融合问题,以期利用数据融合理论提高不完全量测下线性系统的状态估计精度[8]。由上述材料可以看出,对于不完全量测背景下滤波问题的研究,大多针对于线性问题,而对于非线性滤波问题的研究相对较少。然而,在实际应用中,非线性系统状态估计问

到稿日期:2012-11-02 返修日期:2013-01-28 本文受国家自然科学基金(60972119,61170243),河南省科技人才创新项目(114100510001)资助。

李 松(1988-),男,硕士生,主要研究方向为多源信息融合、最优估计,E-mail:lisonghenu@163.com;胡振涛(1979-),男,博士,副教授,主要研究方向为复杂系统建模与估计、多源信息融合、非线性滤波。

题广泛存在于飞行器导航、目标跟踪及工业控制等领域;并且对于非线性系统,上述的部分算法应用环境受限,因而此类问题的研究具有重要的理论意义和广阔的应用前景。

基于以上分析,本文针对实际工程中常见的量测不完全情况下非线性机动目标的跟踪问题,结合量测数据的野值剔除方法[9]以及多传感器信息融合理论,提出一种不完全量测下多传感器信息融合扩展 Kalman 滤波算法,并将其应用到非线性量测的光电机动目标跟踪系统中,在考虑到量测概率的情况下,充分利用多传感器量测中的冗余和互补信息,提高了非线性机动目标的状态跟踪精度。

2 问题描述

考虑下列不完全量测下的非线性系统离散动态方程:

$$\boldsymbol{x}_{k+1}=f(\boldsymbol{x}_k)+\Gamma_k\boldsymbol{w}_k \tag{1}$$

$$\boldsymbol{Z}_k=d_k\boldsymbol{h}_k(\boldsymbol{x}_k)+\boldsymbol{v}_k \tag{2}$$

式中,$\boldsymbol{x}_k\in\boldsymbol{R}^{n\times1}$ 为 k 时刻目标的状态向量。$f(\boldsymbol{x}_k)$ 为非线性的状态表达式,$\Gamma_k\in\boldsymbol{R}^{n\times m}$ 为过程噪声分布矩阵,过程噪声 $\boldsymbol{w}_k\in\boldsymbol{R}^{m\times1}$ 是均值为 0 且方差为 $\boldsymbol{Q}_k$ 的高斯白噪声向量。$\boldsymbol{Z}_k\in\boldsymbol{R}^{m\times1}$ 是传感器在 k 时刻的量测向量,$\boldsymbol{h}_k(\boldsymbol{x}_k)$ 为非线性的测量方程表达式,量测噪声向量 $\boldsymbol{v}_k\in\boldsymbol{R}^{m\times1}$ 服从高斯分布,均值为 0、方差阵为 $\boldsymbol{R}_k$。d_k 是取值为 0 或者 1 的离散随机变量,$d_k=1$ 表示传感器量测到完整数据信号,$d_k=0$ 表示量测数据信号丢失或量测数据误差过大。λ 表示系统的数据量测概率,即传感器获得有效量测数据的概率,满足 $Prob\{d_k=1\}=\lambda$;量测噪声 $\boldsymbol{v}_k$ 与 d_k 满足:

$$p(\boldsymbol{v}_k\mid d_k)=\begin{cases}N(0,\boldsymbol{R}_k), & d_k=1\\ N(0,\delta^2\boldsymbol{I}), & d_k=0\end{cases} \tag{3}$$

式中,$d_k=0$ 对应 δ 取极限形式,即 $\delta\to\infty$。

3 多传感器不完全量测下的机动目标跟踪

为解决非线性机动目标跟踪系统中量测不完全的工程问题,提出基于多传感器不完全量测下的扩展 Kalman 滤波算法。在不完全量测下,针对非线性机动目标跟踪系统,采用探测概率小于 1 的多个传感器,融合利用各传感器的量测信息,获得较高精度的目标运动状态估计值。

3.1 不完全量测下的扩展卡尔曼算法

针对目标跟踪中传感器量测不完全的情况,在 k 时刻,对于任何一个传感器,由于传感器本身质量以及外界环境影响等因素,会存在量测数据完整、无量测数据或量测数据误差过大这几种情况。引入 d_k 到非线性滤波过程中,修正非线性滤波算法,以期增强目标跟踪算法的稳定性和鲁棒性。

扩展卡尔曼滤波(Extended Kalman Filter,EKF)是常用非线性估计的代表,其基本思想是围绕状态估值对非线性模型进行一阶 Taylor 展开,然后应用到线性系统 Kalman 滤波公式中。一般的扩展卡尔曼滤波方程为:

$$\hat{\boldsymbol{x}}_{k+1|k}=f(\hat{\boldsymbol{x}}_{k|k}) \tag{4}$$

$$\boldsymbol{P}_{k+1|k}=\boldsymbol{f}_k\boldsymbol{P}_{k|k}\boldsymbol{f}_k^{\mathrm{T}}+\Gamma_k\boldsymbol{Q}_k\Gamma_k^{\mathrm{T}} \tag{5}$$

$$\boldsymbol{K}_{k+1}=\boldsymbol{P}_{k+1|k}\boldsymbol{h}_{k+1}^{\mathrm{T}}[\boldsymbol{h}_{k+1}\boldsymbol{P}_{k+1|k}\boldsymbol{h}_{k+1}^{\mathrm{T}}+\boldsymbol{R}_{k+1}]^{-1} \tag{6}$$

$$\tilde{\boldsymbol{Z}}_{k+1}=\boldsymbol{Z}_{k+1}-\boldsymbol{h}_{k+1}(\hat{\boldsymbol{Z}}_{k+1|k}) \tag{7}$$

$$\hat{\boldsymbol{x}}_{k+1|k+1}=\hat{\boldsymbol{x}}_{k+1|k}+\boldsymbol{K}_{k+1}\tilde{\boldsymbol{Z}}_{k+1} \tag{8}$$

$$\boldsymbol{P}_{k+1|k+1}=\boldsymbol{P}_{k+1|k}-\boldsymbol{K}_{k+1}\boldsymbol{h}_{k+1}\boldsymbol{P}_{k+1|k} \tag{9}$$

式中,$\boldsymbol{f}_k$ 是向量 $\boldsymbol{f}$ 的雅克比矩阵,在状态估计的最近值上取得:

$$\boldsymbol{f}_k=\left.\frac{\partial f_x(k)}{\partial\boldsymbol{x}}\right|_{x=\hat{x}_k} \tag{10}$$

$\boldsymbol{h}_{k+1}$是向量 $\boldsymbol{h}$ 的雅克比矩阵:

$$\boldsymbol{h}_{k+1}=\left.\frac{\partial\boldsymbol{h}_x(k+1)}{\partial\boldsymbol{x}}\right|_{x=\hat{x}_{k+1|k}} \tag{11}$$

在式(7)中,$\tilde{\boldsymbol{Z}}_{k+1}$表示 $k+1$ 时刻量测向量的预测残差。为确定 d_k 的值,根据量测数据的野值剔除方法,可以得到判别条件:

$$|\tilde{\boldsymbol{Z}}_{k+1}|\leqslant C\sqrt{\boldsymbol{h}_{k+1}\boldsymbol{P}_{k+1|k}\boldsymbol{h}_{k+1}^{\mathrm{T}}+\boldsymbol{R}_{k+1}} \tag{12}$$

若 $k+1$ 时刻满足上述条件,则 $d_{k+1}=1$,否则 $d_{k+1}=0$。C 为常数,是残差检测的门限,若 C 选得过大,则检测结果存伪的可能性过大;若 C 选得过小,则检测结果剔除正常值的可能性过大。工程上检测门限 C 的取值范围为 3 到 4[9]。

对于 $k+1$ 时刻,若传感器接收到量测数据,则符合一般的扩展卡尔曼滤波算法,可得到 $k+1$ 时刻的状态估计值和其相应的误差协方差阵。若传感器未接收到量测数据,即该时刻的量测 $\boldsymbol{Z}_{k+1}$为野值,无法对状态预测值进行修正,因而采用扩展卡尔曼滤波算法中的状态一步预测和一步预测均方误差作为该时刻的状态估计和估计均方误差,可近似认为 $k+1$ 时刻的状态估计值和其相应的误差协方差阵为:

$$\hat{\boldsymbol{x}}_{k+1|k+1}=\hat{\boldsymbol{x}}_{k+1|k}=\boldsymbol{f}(\hat{\boldsymbol{x}}_{k|k}) \tag{13}$$

$$\boldsymbol{P}_{k+1|k+1}=\boldsymbol{P}_{k+1|k}=\boldsymbol{f}_k\boldsymbol{P}_{k|k}\boldsymbol{f}_k^{\mathrm{T}}+\Gamma_k\boldsymbol{Q}_k\Gamma_k^{\mathrm{T}} \tag{14}$$

综合上述两种情况,引入 d_k 作为表征传感器是否接收到有效量测信息的量,可得到不完全量测下的 $k+1$ 时刻的状态估计和估计均方误差:

$$\hat{\boldsymbol{x}}_{k+1|k+1}=\begin{cases}\hat{\boldsymbol{x}}_{k+1|k}+\boldsymbol{K}_{k+1}[\boldsymbol{Z}_{k+1}-\boldsymbol{h}_{k+1}(\hat{\boldsymbol{x}}_{k+1|k})], & d_{k+1}=1\\ \hat{\boldsymbol{x}}_{k+1|k}, & d_{k+1}=0\end{cases} \tag{15}$$

$$\boldsymbol{P}_{k+1|k+1}=\begin{cases}\boldsymbol{P}_{k+1|k}-\boldsymbol{K}_{k+1}\boldsymbol{h}_{k+1}\boldsymbol{P}_{k+1|k}, & d_{k+1}=1\\ \boldsymbol{P}_{k+1|k}, & d_{k+1}=0\end{cases} \tag{16}$$

将 d_{k+1}作为参数代入滤波算法中,则不完全量测下的 $k+1$时刻的状态估计和估计均方误差可总结为:

$$\hat{\boldsymbol{x}}_{k+1|k+1}=\hat{\boldsymbol{x}}_{k+1|k}+d_{k+1}\boldsymbol{K}_{k+1}\tilde{\boldsymbol{Z}}_{k+1} \tag{17}$$

$$\boldsymbol{P}_{k+1|k+1}=\boldsymbol{P}_{k+1|k}-d_{k+1}\boldsymbol{K}_{k+1}\boldsymbol{h}_{k+1}\boldsymbol{P}_{k+1|k} \tag{18}$$

式(4)—式(7)、式(17)、式(18)即为不完全量测下推广的扩展卡尔曼滤波算法。

3.2 基于多传感器不完全量测的机动目标跟踪

不完全量测下修正的扩展卡尔曼滤波算法中,若传感器在某时刻未接收到量测数据,虽然采用状态一步预测和一步预测均方误差作为该时刻的状态估计和估计均方误差,但数据缺失仍会对滤波精度造成部分影响。若采用多传感器信息融合方法,则任意时刻传感器获得有效量测数据的概率较高。将基于各传感器量测数据的状态估计值进行加权融合,可极

大减小量测不完全情况对状态估计精度的影响，提高了滤波算法的精确度和鲁棒性。

采用 n 个传感器探测数据进行分布式最优融合估计，某一时刻 $k+1$，有 n 个局部状态估计 $\hat{\boldsymbol{x}}^1_{k+1|k+1}$，$\hat{\boldsymbol{x}}^2_{k+1|k+1}$，…，$\hat{\boldsymbol{x}}^n_{k+1|k+1}$ 和相应的估计误差协方差阵 $\boldsymbol{P}^1_{k+1|k+1}$，$\boldsymbol{P}^2_{k+1|k+1}$，…，$\boldsymbol{P}^n_{k+1|k+1}$，定义变量 $\boldsymbol{P}_g^{k+1|k+1}=(\sum_{i=1}^{n}(\boldsymbol{P}^i_{k+1|k+1})^{-1})^{-1}$ 且满足 $\boldsymbol{P}_g^{k+1|k+1}<\boldsymbol{P}^i_{k+1|k+1}$[10]，则基于第 i 个传感器量测数据的状态估计和误差方差为：

$$\hat{\boldsymbol{x}}^i_{k+1|k+1}=\hat{\boldsymbol{x}}^i_{k+1|k}+d^i_{k+1}\boldsymbol{K}^i_{k+1}\tilde{\boldsymbol{Z}}^i_{k+1} \tag{19}$$

$$\boldsymbol{P}^i_{k+1|k+1}=\boldsymbol{P}^i_{k+1|k}-d^i_{k+1}\boldsymbol{K}^i_{k+1}\boldsymbol{h}^i_{k+1}\boldsymbol{P}^i_{k+1} \tag{20}$$

在状态估计互不相关的情况下，$k+1$ 时刻的全局最优估计可表示为：

$$\begin{aligned}\hat{\boldsymbol{x}}_{k+1|k+1}&=\boldsymbol{P}_g^{k+1|k+1}\sum_{i=1}^{n}\boldsymbol{P}^i_{k+1|k+1}\hat{\boldsymbol{x}}^i_{k+1|k+1}\\&=\boldsymbol{P}_g^{k+1|k+1}\sum_{i=1}^{n}(\boldsymbol{P}^i_{k+1|k}-d^i_{k+1}\boldsymbol{K}^i_{k+1}\boldsymbol{h}^i_{k+1}\boldsymbol{P}^i_{k+1|k})\\&\quad(\hat{\boldsymbol{x}}^i_{k+1|k}+d^i_{k+1}\boldsymbol{K}^i_{k+1}\tilde{\boldsymbol{Z}}^i_{k+1})\end{aligned} \tag{21}$$

式中，$\boldsymbol{P}^i_{k+1|k+1}$ 表示基于第 i 个传感器量测数据 $k+1$ 时刻状态估计的误差协方差阵，$\boldsymbol{P}_g^{k+1|k+1}\times\boldsymbol{P}^i_{k+1|k+1}$ 表示基于第 i 个传感器量测数据的状态估计在融合加权时的权重。当 $d^i_{k+1}=0$ 时，分布式数据融合采用有反馈的层次结构，$\hat{\boldsymbol{x}}^i_{k+1|k}=\boldsymbol{f}(\hat{\boldsymbol{x}}_{k|k})$，$\boldsymbol{P}^i_{k+1|k}=\boldsymbol{f}_k\boldsymbol{P}_g^{k|k}\boldsymbol{f}_k^{\mathrm{T}}+\Gamma_k\boldsymbol{Q}_k\Gamma_k^{\mathrm{T}}$；当 $d^i_{k+1}=0$ 时，则采用无反馈的层次结构，$\hat{\boldsymbol{x}}^i_{k+1|k}=f(\hat{\boldsymbol{x}}^i_{k|k})$，$\boldsymbol{P}^i_{k+1|k}=\boldsymbol{f}_k\boldsymbol{P}^i_{k|k}\boldsymbol{f}_k^{\mathrm{T}}+\Gamma_k\boldsymbol{Q}_k\Gamma_k^{\mathrm{T}}$。这种部分反馈的层次结构，可以在保证较小计算量和通信量的同时，减小某些传感器连续时刻丢失数据对状态融合估计造成的影响，从而提高估计精度。

又 $\boldsymbol{P}_g^{k+1|k+1}<\boldsymbol{P}^i_{k+1|k+1}$，说明该融合估计优于任何一个传感器的估计。

4 仿真实验分析

4.1 光电系统仿真实验环境

算法广泛适用于机动目标跟踪系统的传感器设备，仿真中选取由重频激光测距机和光电测角设备组成的光电跟踪系统对运动飞行器进行跟踪作为代表对算法性能进行说明。光电跟踪设备中，激光测距机利用发射并获取激光回波来测取目标的距离信息 r_k，光电测角设备利用图像取差原理测得目标的俯仰角 θ_k 和方位角 φ_k，从而获得 k 时刻球坐标下的量测向量 $[r_k\quad\theta_k\quad\varphi_k]^{\mathrm{T}}$。考虑到目标跟踪系统中，笛卡尔坐标系下的目标运动状态方程更便于对该领域问题进行研究，因而将球坐标下的位置量测通过修正的去偏量测转换[11]变换到笛卡儿坐标系，可以得到笛卡尔坐标系下的量测矩阵 $\boldsymbol{Z}_k=[x_k\quad y_k\quad z_k]^{\mathrm{T}}$。在光电跟踪系统中，跟踪系统获取的有效激光回波数与激光发射次数之比称为激光测距回波率，即为光电设备的探测概率 λ，并且满足 $\lambda=Prob\{d_k=1\}$，其中 d_k 是取值为 0 或者 1 的离散随机变量。

考虑具有代表性的运动模型二阶常速 CT 模型对机动目标进行表述，目标运动的系统方程为：

$$\boldsymbol{x}_{k+1}=\boldsymbol{F}\boldsymbol{x}_k+\Gamma_k\boldsymbol{w}_k \tag{22}$$

$$\boldsymbol{Z}_k=\boldsymbol{d}_k\boldsymbol{h}_k(x_k)+\boldsymbol{v}_k \tag{23}$$

其中

$$\boldsymbol{h}_k(\boldsymbol{x}_k)=\begin{bmatrix}\sqrt{x_k^2+y_k^2+z_k^2}\\\tan^{-1}(y_k/x_k)\\\tan^{-1}(z_k/\sqrt{x_k^2+y_k^2})\end{bmatrix}$$

式中，x_k，y_k，z_k 分别表示目标在笛卡尔直角坐标系中 x，y，z 轴上的位置。

仿真场景设定为采用 3 组探测概率光电设备作为传感器观测同一个运动目标，以实现对平面上机动目标的跟踪，传感器探测概率 λ_1、λ_2、λ_3 分别为 0.9、0.8、0.7。该目标在 x-y 平面上做角速度为 ω 的匀速转弯运动，因而 z 轴坐标为 0。相应地，过程噪声 $\boldsymbol{w}_k$ 是具有零均值和正定协方差阵 $\boldsymbol{Q}_k=\begin{bmatrix}1&0\\0&1\end{bmatrix}$ 的高斯白噪声向量，过程噪声分布矩阵 $\Gamma_k=\begin{bmatrix}T^2/2&1&0&0\\0&0&T^2/2&1\end{bmatrix}^{\mathrm{T}}$，$\boldsymbol{F}=\begin{bmatrix}1&\frac{\sin(\omega T)}{\omega}&0&-\frac{-\cos(\omega T)}{\omega}\\0&\cos(\omega T)&0&-\sin(\omega T)\\0&\frac{(1-\cos(\omega T))}{\omega}&1&\frac{\sin(\omega T)}{\omega}\\0&\sin(\omega T)&0&\cos(\omega T)\end{bmatrix}$，其中，采样间隔 $T=1$。$\boldsymbol{v}_k$ 是高斯分布的量测噪声向量，3 个传感器的量测噪声方差阵 $\boldsymbol{R}_1$、$\boldsymbol{R}_2$、$\boldsymbol{R}_3$ 均为 $\begin{bmatrix}25&0\\0&0.005^\circ\end{bmatrix}$。

4.2 实验分析

采用本文所提出的不完全量测下的 EKF 融合算法，分别得出不完全量测下基于单组光电传感器量测数据的状态估计以及三传感器融合的状态估计。其航迹跟踪效果如图 1 所示，验证了算法对于非线性目标跟踪的有效性。

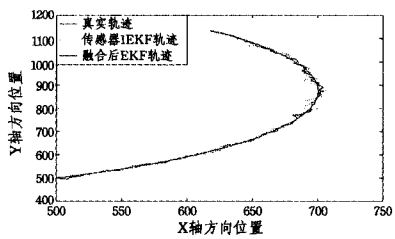

图 1 非线性机动目标航迹跟踪轨迹图

本文使用均方根误差(RMSE)作为目标跟踪性能的评价指标，它利用 Monte Carlo 仿真的采样值来统计逼近该期望值。通过 100 次的蒙特卡洛仿真，得出单传感器状态估计与多传感器融合状态估计的 RMSE 对比，以及两传感器融合状态估计与三传感器融合状态估计的 RMSE 对比，如图 2 所示。

图 2 中前 3 个图表分别对比了探测概率 λ_1、λ_2、λ_3 分别为 0.9、0.8、0.7 的 3 组传感器与三传感器融合后的 x 轴位置估计的 RMSE，第 4 个图表则对比了传感器 1 和 2 融合与三传感器的 x 轴位置估计的 RMSE。可发现传感器探测概率直接影响位置估计的均方根误差，且探测概率越小，位置估计误差越大。两传感器和三传感器融合后 x 轴位置估计的 RMSE 要小于任何一个传感器滤波估计 x 轴位置的 RMSE，三传感器融合后的估计效果更好。

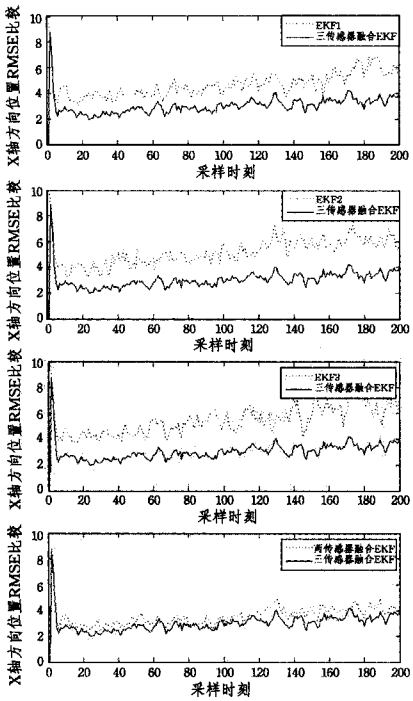

图 2　量测噪声方差相同时多传感器融合 x 轴位置估计 RMSE 对比

其他条件相同的状况下，取量测精度不一致的三组传感器，传感器的量测噪声方差阵 $\boldsymbol{R}_1$、$\boldsymbol{R}_2$、$\boldsymbol{R}_3$ 分别为 $\begin{bmatrix}25 & 0\\ 0 & 0.002^\circ\end{bmatrix}$、$\begin{bmatrix}2500 & 0\\ 0 & 0.003^\circ\end{bmatrix}$、$\begin{bmatrix}2500 & 0\\ 0 & 0.005^\circ\end{bmatrix}$。做融合估计以及 RMSE 对比得到图 3。

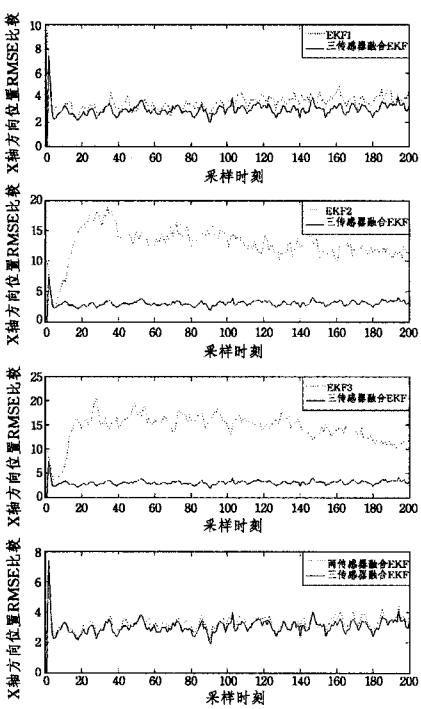

图 3　量测噪声方差不相同时多传感器融合 x 轴位置估计 RMSE 对比

由图 3 可以看出，精度较高的传感器 1 的 x 轴位置估计 RMSE 小于其他两个精度较低的传感器，并接近多传感器融合后估计的 RMSE 曲线，且三传感器融合后 x 轴的位置估计优于各单传感器及两传感器融合后的 x 轴位置估计。

图 4 给出了新算法与不完全量测下的标量加权最优信息融合方法的 x 轴位置估计 RMSE 对比图，针对非线性机动目标跟踪问题，图(a)反映了新算法与野值剔除后再进行融合的 EKF 跟踪方法的状态估计精度对比；图(b)则反应了新算法与不完全量测下无反馈融合算法[8]的精度对比，并且右图中新算法各个时刻 RMSE 的均值为 2.3367，对照算法 RMSE 均值为 2.4318，从而可以看出新算法在位置估计精度上的效果更好。

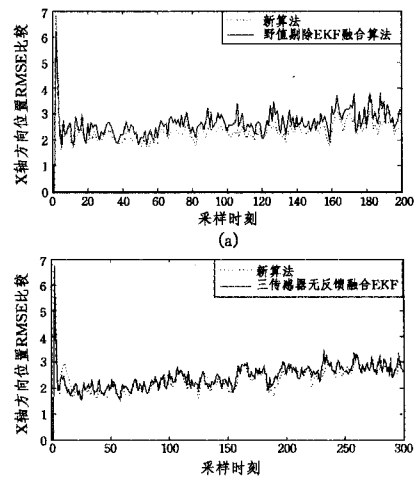

图 4　新算法与多传感器标量加权最优信息融合稳态 Kalman 滤波算法 RMSE 对比

因而，以上仿真验证了针对不完全量测下的非线性目标跟踪系统，本文提出的融合估计算法可以有效地改善滤波性能，提高目标跟踪精度。

结束语　本文结合多传感器信息融合理论，针对工程上由于障碍物遮挡、传感器本身故障、环境中一些不确定因素影响等原因造成的传感器探测概率小于 1 的实际问题，提出一种适用于非线性情况的基于不完全量测的多传感器扩展卡尔曼滤波算法，并将该算法应用于光电系统跟踪机动目标的实际工程问题中进行实验验证。算法将多传感器融合的 EKF 算法推广到不完全量测情况下，基于最优融合理论，采用部分反馈的分布式层次结构进行状态融合，获得了基于所有量测信息的最优状态估计。

相对现有滤波算法，本文算法具有以下优势：1)算法针对非线性目标跟踪，将 EKF 算法扩展到传感器不完全量测的物理背景下，解决了工程中切实存在的量测缺失这一实际问题。2)采用多传感器信息融合方法来提高跟踪精度，充分利用了多传感器两侧中的冗余和互补信息。3)不同于传统融合算法中将传感器量测数据中为野值的一部分直接剔除，本算法利用上一时刻融合后的状态估计、误差方差以及系统方程，得到当前时刻的一步估计和一步均方误差作为状态估计和误差方差送入融合中心进行信息融合，提高了融合的信息量，更加充分地利用了系统的先验信息。4)基于变量 d_k，采用部分反馈融合，在考虑算法复杂度的情况下，提高了融合估计的精度。算法解决了以往目标跟踪问题中传感器由于丢失量测数据而引起的目标状态估计存在较大波动的问题，提高了状态估计精度以及滤波器鲁棒性，对非线性机动目标跟踪领域的研究具有一定的应用价值和工程意义。

参 考 文 献

[1] Sinopoli B, Schenato L, Fransceschetti L M, et al. Kalman filtering with intermittent observations [J]. IEEE Translation on Automatic Control, 2004, 49(9): 1453-1464

[2] 许志刚，盛安冬，郭治. 基于不完全量测下离散线性滤波的修正Riccati方程 [J]. 控制理论与应用，2009，26(6)：673-677

[3] 许志刚，盛安东. 不完全量测下航迹辨识系统中滤波方差的期望收敛性问题 [J]. 兵工学报，2010，31(2)：261-267

[4] Craig S S, Seiler P. Estimation with lossy measurements: jump estimators for jump systems [J]. IEEE Transactions on Automatic Control, 2003, 48(12): 2163-2171

[5] Boers Y, Driessen H. Results on the modified Riccati equation: target tracking applications [J]. IEEE Transactions on Aerospace and Electronic Systems, 2006, 42(1): 379-384

[6] 王国宏，钟晓军. 雷达跟踪目标中的非线性滤波技术 [J]. 海军航空工程学院学报，2004，19(5)：541-545

[7] Gao Hui-jun, Zhao Yan, Lam J, et al. H_∞ fuzzy filtering of nonlinear systems with intermittent measurements [J]. IEEE transactions on Fuzzy System, 2009, 17(2): 291-300

[8] Yan L P, Shi H, Du M S, et al. Asynchronous Multirate Multisensor State Fusion Estimation with Incomplete Measurements [C]// Proceeding of Wireless Communications, Networking and Mobile Computing, WICOM'08. Dalian: IEEE, Oct. 2008: 1-4

[9] 周宏仁，敬忠良，王培德. 机动目标跟踪 [M]. 北京：国防工业出版社，1991

[10] 秦永元，章洪钺，汪舒华. 卡尔曼滤波与组合导航原理 [M]. 西安：西北工业大学出版社，1998

[11] 陈黎，许志刚，盛安东. 不完全量测下一类非线性光电跟踪系统滤波器设计[J]. 航空学报，2009，30(9)：1745-1753

(上接第 267 页)

损以及气穴故障条件下的性能测试数据，并将其作为云神经网络的输入，利用正态云神经网络进行故障诊断；为了能够验证正态云神经网络的有效性，同时也利用 BP 神经网络和 RBF 神经网络对齿轮泵进行故障诊断，相应的故障诊断仿真曲线如图 2 所示。

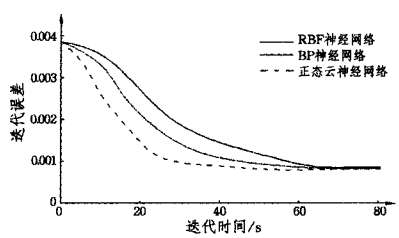

图 2 故障诊断的迭代仿真曲线

将不同状态下齿轮泵的状态参数作为正态云神经网络的输出，对云神经网络的故障诊断性能进行判别。为了能够验证正态云神经网络在故障诊断精度上的优势，同时也利用 BP 神经网络以及 RBF 神经网络对齿轮泵进行故障诊断，各种类型的神经网络可以采用相同的输入和输出，利用不同故障诊断技术对齿轮泵故障诊断的结果见表 2。

表 2 齿轮泵的故障诊断结果

齿轮泵状态测试样本	齿轮泵的状态	故障诊断正确数		
		BP 神经网络	RBF 神经网络	正态云神经网络
1—5	正常工作	3	4	5
6—10	齿轮磨损	4	4	5
11—15	侧板磨损	3	4	5
16—20	气穴故障	4	4	5

从表 2 可以看出，利用正态云神经网络获得的齿轮泵故障诊断正确率最高，没有发生漏判和误判，其次是 RBF 神经网络，故障诊断正确数最少的是 BP 神经网络，从而表明了正态云神经网络在齿轮泵诊断诊断中的有效性。

为了能够验证该正态云神经网络的故障诊断效率，针对相同的故障测试样本采用不同类型的神经网络进行仿真时间的对比。分别利用 BP 神经网络、RBF 神经网络对该齿轮泵进行故障诊断，比较了各种方法在诊断时间方面的性能表现，故障诊断的性能比较见表 3。

表 3 不同故障诊断方法的性能对比

故障诊断算法	故障诊断时间/s		
	齿轮磨损	侧板磨损	气穴故障
BP 神经网络	1.38	0.74	0.62
RBF 神经网络	1.40	0.70	0.94
正态云神经网络	1.35	0.21	0.31

从表 3 可以看出，正态云神经网络在获得正确诊断结果的同时还缩减了实际诊断时间，从而表明该方法具有较高的故障诊断效率。

结束语 针对齿轮泵故障时振动信号的不确定性，利用正态云神经网络对齿轮泵进行故障诊断，构造了正态云神经网络的基本结构，并且确定了网络的算法。通过故障诊断的仿真研究可以看出，正态云神经网络能够得到较为准确的故障诊断精度，在齿轮泵故障诊断中具有较为广阔的发展前景。

参 考 文 献

[1] 施俊侠，杨兆建，张日红. 小波包分析方法在齿轮泵故障诊断中的应用[J]. 机床与液压，2010，38(17)：126-129

[2] 贾文铜，周瑞祥，张忠，等. 基于 Elman 神经网络的齿轮故障诊断研究[J]. 计算机测量与控制，2012，20(2)：1173-1175

[3] 徐宗本，樊忠泽. 基于云神经网络的空间推进系统故障检测与诊断[J]. 兵工学报，2009，30(6)：727-732

[4] 黄强，吴建军. 基于云-神经网络的液体火箭发动机故障检测方法[J]. 国防科技大学学报，2010，32(1)：11-15

[5] 秦跃，卢强，黄土坦. 基于云理论和信息融合理论的系统性能评估方法研究[J]. 计算机工程与科学，2012，34(2)：181-185

[6] 张晔，马彦恒，李刚. 基于云理论在雷达发射机 BIT 测试性能评价[J]. 计算机测量与控制，2012，20(10)：2742-2745

[7] 石晓伟，张会清，邓贵华. 基于 BP 神经网络的距离损耗模型室内定位算法研究[J]. 计算机测量与控制，2012，20(7)：1944-1947

[8] 蓝集明，熊刚，张海燕. 基于 RBF 神经网络的润滑油自动识别系统设计[J]. 计算机测量与控制，2012，20(2)：484-487