

# 一种基于灰色粒子滤波算法的机动 AUV 航深内测方法\*

李 婷, 赵德鑫, 黄芝平, 苏绍璟

(国防科技大学 机电工程与自动化学院, 湖南 长沙 410073)

**摘 要:**提出了一种将灰色预测和小波变换与标准粒子滤波相结合的灰色粒子滤波算法(GPF),并将其应用于机动 AUV 的航深内测。GPF 针对机动 AUV 航深内测过程中由于 AUV 运动状态未知和测量噪声不断变化而导致的滤波失效问题,在粒子采样过程中结合了标准采样和灰色预测采样,保证了采样得到充分多的有效粒子。在计算粒子权重时,利用小波变换跟踪测量噪声统计特性的变化,提高了各粒子似然概率计算和权重分配的正确性。最后以外测法测得的高精度的机动 AUV 航深作为真实航深,对该 GPF 算法进行了实验对比验证,并与 EKF 和 MMPF 算法的结果作对比,实验结果表明了本文方法的有效性和实用性。

**关键词:**粒子滤波;灰色预测;小波变换;机动 AUV;航深内测

**中图分类号:**TN911 **文献标志码:**A **文章编号:**1001-2486(2013)05-0185-06

## A method for self-estimating the depth of maneuvering AUV based on the grey particle filter

LI Ting, ZHAO Dexin, HUANG Zhiping, SU Shaojing

(College of Mechatronics Engineering and Automation, National University of Defense Technology, Changsha 410073, China)

**Abstract:** A grey particle filter (GPF) that incorporates the grey prediction algorithm and wavelet transform into the particle filter (PF) is presented. The GPF self-estimates the depth of maneuvering autonomous underwater vehicle (AUV) using the data measured by sensors equipped in the AUV under the condition that the prior maneuvering information is unknown and the measurement noise is time-varying. To implement the proposed method, the particles were sampled by standard sampling and grey prediction to insure the particles contain enough information about the true state of the maneuvering AUV. In addition, the measurement noise covariance was modified by wavelet transform in real time. Therefore, the GPF can effectively correct the prior distribution and likelihood function of the particles and then alleviate the sample degeneracy problem which is common in the particle filter. A high accuracy depth trajectory, which tracks by the outside position sensor as the true depth of the maneuvering AUV, was employed. Then the performance of the EKF, MMPF and GPF was evaluated through the experimental data. The results show the effectiveness and robustness of the GPF.

**Key words:** particle filter; grey prediction; wavelet transform; maneuvering AUV; depth self-estimation

AUV(Autonomous Underwater Vehicle)航深测试是 AUV 航迹研究中的重要组成部分之一,它不仅能够对 AUV 航深数学模型进行验证与修正,而且还能对 AUV 分系统特性或综合性能进行验证与评价<sup>[1]</sup>。AUV 航深测试方法分为外测法和内测法两大类:外测法利用 AUV 外部的、固定的或移动的测试设备,通过跟踪运动中的 AUV,测得 AUV 的航行深度、速度和航向等。由于外测法直接跟踪 AUV 的运动,因而测得的 AUV 运动轨迹精度较高,但外测法需耗费较大的人力、物力,在实际应用中实施难度较大。内测法的测试仪表装于 AUV 内部,在 AUV 航行过程中,各种测试传感器实时地测量并记录下 AUV 的航行深度、速度及

姿态角等参量,并利用这些参量,通过解算运动方程获得 AUV 的航深。内测法设备简单、易于实现,航深的解算方法极大地影响着 AUV 航深的测试精度<sup>[2-3]</sup>。

在进行机动 AUV 航深内测时,AUV 的运动模型是非线性的。对于非线性滤波问题,目前比较常用的方法是扩展卡尔曼滤波(EKF)和无先导卡尔曼滤波(UKF)。而当系统具有较强的非线性或噪声分布服从非高斯时,EKF 和 UKF 算法都可能导致滤波发散<sup>[4-5]</sup>。随着计算机处理能力的提高,一类称为粒子滤波的非线性方法得到了广泛的关注和研究,并成功地应用于目标航迹测试领域,特别是在动态非线性航迹测试方面。粒子

\* 收稿日期:2013-01-29

基金项目:国家留学基金委资助项目(2011611091)

作者简介:李婷(1987—),女,湖南郴州人,博士研究生,E-mail:kdt2010@163.com;

黄芝平(通信作者),男,教授,博士,博士生导师,E-mail:kdhuangzp@163.com

滤波算法在处理非线性非高斯滤波问题时,通过非参数化的蒙特卡罗模拟方法实现递推贝叶斯滤波,用样本形式对状态的先验信息和后验信息进行描述,利用状态空间中一组随机的自适应演化粒子探索状态的发展变化,每个粒子代表状态的一条可能轨迹,具有较好的鲁棒性。

多模型(Multiple Model, MM)方法是在模型不确定情况下进行航迹测量的常用方法,其基本思想是使用多个模型来近似目标的运动特性,同时有多个滤波器并行工作,通过计算每个模型的有效概率,然后对每个子滤波器的估计值进行加权,得到目标状态的最终估计<sup>[6]</sup>。一些学者将粒子滤波与多模型方法相结合,应用于机动目标航迹测量中,称之为 MMPF<sup>[7]</sup>。然而,机动 AUV 的运动方式的确定和运动方式改变时刻的不确定,以及实际中对于系统先验信息的匮乏,导致很难设计较好的运动模型。当运动模型与目标真实运动状态不匹配时, MMPF 不仅增加了计算复杂度,而且将引起粒子退化问题。

另一需要解决的问题是, AUV 在机动航行过程中,由于海洋环境非常复杂,各个传感器随时都可能受到各种外界干扰,导致观测噪声发生变化。而不准确的观测噪声统计特性描述往往会导致各粒子似然概率函数计算错误,从而引起粒子退化问题,最终导致航深内测误差增大或滤波算法失效<sup>[8]</sup>。

本文针对上述机动 AUV 航深内测方法中存在的问题,提出了一种基于灰色粒子滤波(Grey Particle Filter, GPF)算法的机动 AUV 航深内测方法。灰色预测法是一种对含有不确定因素的系统进行预测的与模型无关的方法,它不需要知道具体的系统模型和参数,只需要少量的测量数据就可以对系统未来的状态作出较为有效的预测<sup>[9]</sup>。将灰色预测与基于状态模型的预测相结合来产生粒子,综合了基于模型和模型无关这两种方法的优势,克服了 MMPF 方法中的模型与真实模型失配的问题,能有效地修正粒子的先验分布。另一方面,运用小波变换实现观测噪声方差的实时估计,跟踪粒子似然概率函数的变化,从而避免了粒子权值分配出现大的误差。综上所述,该灰色粒子滤波算法通过修正粒子的先验分布和似然概率,能获得较准确的粒子后验分布,解决了粒子退化问题。通过实验,将本文提出的 GPF 得到的 AUV 航深与外测法测得的高精度的航深以及 EKF, MMPF 得到的航深进行对比,实验结果表明了本文方法的有效性。

## 1 粒子滤波

序贯重要性采样和重采样构成了标准粒子滤波算法,其基本思想是从目标概率分布取出样本来近似目标函数的积分。目标状态的后验分布可表示为

$$p(x_k | z_{1:k}) = \sum_{j=1}^N \bar{w}_k^j \delta(x_k - x_k^j) \quad (1)$$

其中  $N$  为粒子数,  $k$  表示第  $k$  个离散时间点, 可认为  $k$  即时间,  $\{x_k^j\}_{j=1}^N$  为粒子集合,  $\{\bar{w}_k^j\}_{j=1}^N$  为粒子归一化权重。粒子滤波算法的原理为:在得到前一时刻的粒子后,进行预测即从先验分布中采样,得到新的粒子集,并根据权重计算公式(即似然概率函数)利用测量值计算各个粒子的权重,然后,进行重采样,复制权重高的粒子,舍去低权重的粒子,重采样结束后把粒子权重归一化为  $1/N$ ,接着再重复下一次迭代。综合上述分析,可简要归纳粒子滤波算法具体步骤如下:

### (1) 初始化

当  $k = 0$  时, 采样  $\{x_0^j\}_{j=1}^N \sim p(x_0)$ , 即根据  $p(x_0)$  分布采样得到  $\{x_0^j\}_{j=1}^N$ 。

### (2) 采样

从先验分布  $\pi(x_k | x_{k-1}^j, z_{1:k})$  中取出  $N$  个样本  $x_k^j \sim \pi(x_k | x_{k-1}^j, z_{1:k})$ ,  $j = 1, \dots, N$ , 为了简化, 令  $\pi(x_k | x_{k-1}^j, z_{1:k}) = p(x_k | x_{k-1}^j)$ 。

### (3) 粒子加权

计算各粒子权重,如下式:

$$w_k^j = w_{k-1}^j \frac{p(z_k | x_k^j) p(x_k^j | x_{k-1}^j)}{\pi(x_k^j | x_{k-1}^j, z_{1:k})} \quad (2)$$

并将权重归一化,  $\bar{w}_k^j = w_k^j / \sum_{j=1}^N w_k^j$ 。

### (4) 输出

状态估计:

$$\hat{x}_k = E[x_k | z_{1:k}] = \sum_{j=1}^N x_k^j \bar{w}_k^j \quad (3)$$

### (5) 重采样

根据重采样算法对粒子进行采重样,即根据粒子权重从粒子集  $\{x_k^j\}_{j=1}^N$  中获得新的粒子集  $\{\bar{x}_k^j\}_{j=1}^N$ 。

(6) 迭代。令  $k = k + 1$ , 返回步骤(2)。

粒子滤波算法中涉及 AUV 运动状态模型与测量模型。粒子的先验分布依赖于 AUV 运动状态模型,而粒子的权重计算则是基于测量模型的。然而 AUV 的运动状态和测量噪声方差都是未知的,因此粒子的先验分布和似然函数都较难获知,这就引起了粒子退化问题<sup>[10]</sup>。粒子退化意味着大量

的计算工作都被用来更新那些对  $p(\mathbf{x}_k | \mathbf{z}_{1:k})$  的估计几乎没有作用的粒子上,这表示能代表 AUV 真实运动状态的粒子数是非常小的。

为了减轻粒子退化问题,GPF 算法利用灰色预测方法来采样一部分粒子,而另一部分粒子仍然利用标准的基于状态模型的采样方法获得,并通过小波变换实时估计测量噪声方差,修正粒子权值,从而克服基于模型的粒子滤波算法中存在的上述问题。

## 2 基于灰色粒子滤波(GPF)的机动 AUV 航深内测

### 2.1 问题描述

机动 AUV 航深内测利用的数据有置于 AUV 内部的深度、速度和俯仰角传感器的测量量。机动 AUV 的航深状态模型为

$$\begin{cases} z_k = z_{k-1} + (v_{k-1} + u_k^v) \sin(\varphi_{k-1} + u_k^\varphi) \cdot T + u_k^z \\ v_k = v_{k-1} + u_k^v \\ \varphi_k = \varphi_{k-1} + u_k^\varphi \end{cases} \quad (4)$$

其中,  $z_k, v_k, \varphi_k$  分别为 AUV 航深,航速和俯仰角;  $u_k^z, u_k^v, u_k^\varphi$  分别为  $z_k, v_k, \varphi_k$  的状态噪声;令  $\mathbf{x}_k = [z_k, v_k, \varphi_k]^T$ ; 状态噪声向量  $\mathbf{u}_k = [u_k^z, u_k^v, u_k^\varphi]^T$  均值为0,协方差为  $\mathbf{Q}_k$ ;  $T$  为采样时间间隔。式(4)可简写为如下形式:

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_k) \quad (5)$$

AUV 航深内测的测量模型为

$$\mathbf{z}_k = \mathbf{x}_k + \mathbf{w}_k = \begin{bmatrix} z_k \\ v_k \\ \varphi_k \end{bmatrix} + \begin{bmatrix} w_k^z \\ w_k^v \\ w_k^\varphi \end{bmatrix} \quad (6)$$

式中,  $w_k^z, w_k^v, w_k^\varphi$  分别  $z_k, v_k, \varphi_k$  的测量噪声;  $w_k = [w_k^z, w_k^v, w_k^\varphi]^T$  均值为0,协方差为  $\mathbf{R}_k$ 。

$$a = \frac{\sum_{k=2}^n Z^{(1)}(k) \sum_{k=2}^n z^{(0)}(k) - (n-1) \sum_{k=2}^n Z^{(1)}(k) z^{(0)}(k)}{(n-1) \sum_{k=2}^n [Z^{(1)}(k)]^2 - [\sum_{k=2}^n Z^{(1)}(k)]^2}$$

$$b = \frac{\sum_{k=2}^n [Z^{(1)}(k)]^2 \sum_{k=2}^n z^{(0)}(k) - \sum_{k=2}^n Z^{(1)}(k) \sum_{k=2}^n Z^{(1)}(k) z^{(0)}(k)}{(n-1) \sum_{k=2}^n [Z^{(1)}(k)]^2 - [\sum_{k=2}^n Z^{(1)}(k)]^2}$$

(4) 将解得的  $a, b$  代入式(9),得到  $k+1$  时刻  $z^{(1)}$  的预测值如下式:

$$\hat{z}^{(1)}(k+1) = \left[ z^{(0)}(1) - \frac{b}{a} \right] e^{-ak} + \frac{b}{a} \quad (11)$$

(5) 通过逆累加得到  $k+1$  时刻状态的预测值为

### 2.2 基于灰色预测的粒子采样

灰色预测是一种对含有不确定性的系统进行预测的方法,即在系统结构、参数和测量系统特性都未知的情况下,用观测到的反映预测对象特征的时间序列来构造灰色预测模型,预测未来某一时刻系统的特征量。其基本步骤为<sup>[11]</sup>:

(1) 构造原始观测数据序列:

$$\begin{aligned} z^{(0)} &= \{z^{(0)}(1), z^{(0)}(2), \dots, z^{(0)}(n)\} \\ &= \{z^{(0)}(k); k = 1, 2, \dots, n\} \end{aligned} \quad (7)$$

式中,  $z^{(0)}(k)$  为  $k$  时刻传感器的测量值,  $n$  为数据长度。

(2) 对原始数据序列进行处理,以使数据体现出更加明显的变化规律,常用一阶累加生成方式进行数据处理,得到生成序列为

$$\begin{aligned} z^{(1)} &= \{z^{(1)}(1), z^{(1)}(2), \dots, z^{(1)}(n)\} \\ &= \{z^{(1)}(k); k = 1, 2, \dots, n\} \end{aligned} \quad (8)$$

式中,  $z^{(1)}(k) = \left\{ \sum_{i=1}^k z^{(0)}(i), k = 1, 2, \dots, n \right\}$ 。

(3) 建立一阶灰微分方程

$$\frac{dz^{(1)}}{dt} + az^{(1)} = b \quad (9)$$

式(9)的初始条件为  $z^{(1)}(1) = z^{(0)}(1)$ 。根据最小二乘法,式(9)中的参数  $a, b$  可由下式得到:

$$\hat{a} = \begin{bmatrix} a \\ b \end{bmatrix} = (B^T B)^{-1} B^T Y_N \quad (10)$$

式中:

$$Z^{(1)}(k) = \alpha z^{(1)}(k) + (1 - \alpha) z^{(1)}(k-1),$$

$$k = 2, 3, \dots, n$$

$$B = \begin{bmatrix} -Z^{(1)}(2) & 1 \\ -Z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -Z^{(1)}(n) & 1 \end{bmatrix}, Y_N = \begin{bmatrix} z^{(0)}(2) \\ z^{(0)}(3) \\ \vdots \\ z^{(0)}(n) \end{bmatrix}$$

$\alpha$  为权值,一般设为  $\alpha = 0.5$ 。由此可得

$$\begin{aligned} \hat{z}^{(0)}(k+1) &= \hat{z}^{(1)}(k+1) - \hat{z}^{(1)}(k) \\ &= (1 - e^{-a}) [z^{(0)}(1) - b/a] e^{-ak} \end{aligned} \quad (12)$$

### 2.3 基于小波变换估计系统测量噪声

小波变换可以实时分离信号和噪声,跟踪测

量噪声的变化,实现对测量噪声方差的实时估计<sup>[12-13]</sup>。从而可以根据估计出的测量噪声的方差,实时修正粒子的似然概率函数。根据 Weierstrass 逼近定理,任一有界闭区间的连续函数都可以由该区间内的多项式以任意精度一致逼近。因此,任意测量信号,如 AUV 航行深度  $z_k$ , 在一个观测区间内总可以由一个低阶或分段的低阶多项式来逼近到任意精度,设该多项式为

$$z_k = a_0 + a_1 k + \dots + a_M k^M \quad (13)$$

$\varphi(k)$  为小波函数,并且其尺度变换和时间平移为

$$\varphi_{s,\tau}(k) = \frac{1}{\sqrt{s}} \varphi\left(\frac{k-\tau}{s}\right) \quad (14)$$

则含有噪声的测量信号  $z_k$  的小波变换为

$$W_{z_k}(s,\tau) = z_k * \varphi_{s,\tau}(k) = W(s,\tau) + W_w(s,\tau) \quad (15)$$

其中,  $(*)$  表示卷积,  $W(s,\tau)$  为小波系数的近似部分,  $W_w(s,\tau)$  为小波系数的细节部分。如果  $\varphi(k)$  的消失矩为  $a(a > M)$ , 一般地,  $a = M + 1$ <sup>[8]</sup>, 则  $z_k$  的小波变换就抑制了信号而保留了噪声分量  $w$ 。于是式(15) 可以写为

$$W_{z_k}(s,\tau) = |W_w(s,\tau)| \quad (16)$$

如果信号  $z_k$  在一个区间内是分段多项式, 选取小波的消失矩为  $a$  大于分段多项式中最高多项式的阶, 那么噪声的标准差可以通过小波系数最细节部分绝对值的中值估计出来<sup>[14]</sup>, 即

$$\sigma \approx \frac{1}{0.6745} \text{Med}(|W_w(s,t_h)|) \quad (17)$$

其中, 尺度  $s$  为 0.5,  $t_h$  为  $\tau$  在最细节尺度的离散表示,  $0 \leq h \leq K/2$ ,  $W_w(s,t_h)$  为  $\{z_k | k = 0, 1, \dots, K\}$  的  $K/2$  小波系数,  $\text{Med}$  表示序列  $\{|W_w(s,t_h)|\}$  的中间值。

因此,在测量噪声未知时,可首先选择长度为  $L^*$  的一段信号,即相当于在一个观测区间的序列上加上一个长度为  $L^*$  的滑窗( $L^*$  的选择参见文献[8])。式(13) 的阶数应小于  $L^*$ ,  $M$  越大,逼近精度越高,但计算越复杂。为简化计算,假设多项式阶数不随时间变化,设  $M = 5$ , 并选择消失矩  $a = 6$  的 Daubechies 小波<sup>[8]</sup>。在窗内对观测序列进行小波变换,再根据式(17) 估计出噪声的标准差  $\sigma(k)$ , 并根据  $\sigma(k)$  计算测量噪声协方差矩阵为

$$\mathbf{R}_k = \text{diag}(\sigma_{z_k}^2, \sigma_{v_k}^2, \sigma_{\varphi_k}^2) \quad (18)$$

式中,  $\text{diag}(\cdot)$  表示对角矩阵;  $\sigma_{z_k}^2, \sigma_{v_k}^2, \sigma_{\varphi_k}^2$  分别为  $z_k, v_k, \varphi_k$  的测量噪声标准差。由式(18) 和测量方程式(6) 可得粒子的似然概率函数:

$$p(z_k | x_k) \propto \exp\left\{-\frac{1}{2}(z_k - x_k)^T \mathbf{R}_k^{-1}(z_k - x_k)\right\} \quad (19)$$

## 2.4 灰色粒子滤波算法

灰色粒子滤波的主要特征为:(i) 采样得到的粒子由两部分组成,一部分由标准粒子滤波采样得到,即根据状态方程进行采样;而另一部分根据灰色预测算法采样得到。两部分粒子比例可优选为  $N^{\text{grey}} : N^{\text{std}} = 1 : 9$ <sup>[11]</sup> ( $N^{\text{grey}}$  为灰色粒子数,  $N^{\text{std}}$  为标准粒子数,  $N^{\text{grey}} + N^{\text{std}} = N$  为总粒子数)。(ii) 各粒子的权值计算是基于似然概率函数的,而似然概率函数又取决于由小波变换实时估计的测量噪声方差。算法主要流程如下:

### (1) 初始化

$k = 0$  时,从初始先验分布  $p(x_0)$  中抽取粒子集  $\{x_0^j\}_{j=1}^N$ , 每个粒子的初始权值为  $w^j = 1/N$ 。

### (2) 采样

$k = 1, 2, \dots$  时,融合标准粒子采样和灰色预测采样。

#### (2.1) 标准粒子采样

当  $j = 1 : N^{\text{std}}$  时,由 AUV 运动状态方程式(5) 产生粒子:

$$\mathbf{x}_k^j = f(\mathbf{x}_{k-1}^j, \mathbf{u}_k^j) \quad (20)$$

式中,  $\mathbf{u}_k^j \sim N(0, \mathbf{Q}_k)$ 。

#### (2.2) 灰色预测采样

由 2.2 节给出的灰色预测得

$$\begin{aligned} z_k^{\text{grey}} &= \text{grey} - \text{sample}(z_{(k-L):(k-1)}) \\ v_k^{\text{grey}} &= \text{grey} - \text{sample}(v_{(k-L):(k-1)}) \\ \varphi_k^{\text{grey}} &= \text{grey} - \text{sample}(\varphi_{(k-L):(k-1)}) \end{aligned} \quad (21)$$

式中,  $\text{grey} - \text{sample}$  为灰色预测算法,  $L$  为用于灰色预测的测量数据长度。由此得基于灰色预测的粒子采样如下:

$$\begin{cases} z_k^j = z_k^{\text{grey}} + (u_k^z)^j \\ v_k^j = v_k^{\text{grey}} + (u_k^v)^j \\ \varphi_k^j = \varphi_k^{\text{grey}} + (u_k^\varphi)^j \end{cases} \quad (22)$$

式中,  $\mathbf{u}_k^j = [(u_k^z)^j, (u_k^v)^j, (u_k^\varphi)^j]^T \sim N(0, \mathbf{Q}_k)$ ,  $j = N^{\text{std}} + 1 : N$ 。

### (3) 粒子加权

当  $k = 1, 2, \dots$  时,由 2.3 节,采用具有 6 阶消失矩的 Daubechies 小波,基于小波变换实时估计测量噪声方差  $\mathbf{R}_k$ 。然后由下式计算各粒子( $j = 1 : N$ ) 的权值:

$$\begin{aligned} w_k^j &= w_{k-1}^j p(z_k | x_k^j) \\ &\propto w_{k-1}^j \exp\left\{-\frac{1}{2}(z_k - x_k^j)^T \mathbf{R}_k^{-1}(z_k - x_k^j)\right\} \end{aligned} \quad (23)$$

将其归一化,  $\bar{w}_k^j = w_k^j / \sum_{j=1}^N w_k^j$ 。

(4) 估计后验状态

$$\hat{x}_k = E[x_k | z_{1:k}] = \sum_{j=1}^N x_k^j \bar{w}_k^j \quad (24)$$

(5) 重采样

根据粒子权值,按比例复制权值高的粒子,舍去权值低的粒子,从粒子集  $\{x_k^j\}_{j=1}^N$  中获得新的粒子集  $\{\bar{x}_k^j\}_{j=1}^N$ ,更新各粒子权值均为  $1/N$ 。

(6) 令  $k = k + 1$ ,返回步骤(2)进行迭代。

### 3 实验结果及分析

为了验证本文提出的基于灰粒子滤波算法的航深内测方法的有效性,进行了湖试实验,使用外测法测得的高准确度的机动 AUV 航深作为真实航深,并将本文方法测得的机动 AUV 航深以及 EKF、MMPF<sup>[15]</sup> 算法测得的机动 AUV 航深与真实航深作对比。设 GPF、EKF、MMPF 三种滤波算法中状态噪

$$Q_k = \begin{bmatrix} 0.2^2 & 0.8^2 & 0.6^2 \\ 0.8^2 & 1^2 & 0 \\ 0.6^2 & 0 & 0.5^2 \end{bmatrix}, \text{EKF、}$$

MMPF 中的测量噪声协方差为  $R_k = \text{diag}(0.2^2, 5^2, 0.5^2)$ ; 采样时间间隔  $T = 0.05\text{s}$ ; GPF 和 MMPF 中总粒子数  $N = 1000$ ; GPF 中灰色粒子数  $N^{\text{grey}} = 100$ ; 灰色预测序列长度  $L = 30$ ; 小波变换中用来估计测量噪声方差的滑窗长度  $L^* = 50$ ; 多项式阶数  $M = 5$ ; Daubechies 小波消失矩  $a = 6$ 。

图 1 ~ 图 3 分别为利用 MMPF、EKF 和 GPF 三种滤波算法估计得到的机动 AUV 航深、航速和俯仰角的内测值,并将外测法测得的结果作为相应的真实值。相应的航深、航速和俯仰角估计值的 RMSE 曲线如图 4 ~ 图 6 所示。可以看出,当 AUV 机动时,EKF 的性能最差,这是由于发生机动时




图 1 MMPF、EKF 和 GPF 的机动 AUV 航深估计  
Fig. 1 Estimated depth by MMPF, EKF and GPF




图 2 MMPF、EKF 和 GPF 的机动 AUV 航速估计  
Fig. 2 Estimated velocity by MMPF, EKF and GPF




图 3 MMPF、EKF 和 GPF 的机动 AUV 俯仰角估计  
Fig. 3 Estimated pitch angle by MMPF, EKF and QPF




图 4 MMPF、EKF 和 GPF 的机动 AUV 航深估计均方根误差  
Fig. 4 Depth RMSE by MMPF, EKF and GPF




图 5 MMPF、EKF 和 GPF 的机动 AUV 航速估计均方根误差  
Fig. 5 Velocity RMSE by MMPF, EKF and GPF




图6 MMPF、EKF 和 GPF 的机动 AUV 俯仰角估计均方根误差

Fig. 6 Pitch angle RMSE by MMPF, EKF and GPF

AUV 的真实运动特性发生变化,而 EKF 采用的状态模型不再能很好地描述这种运动特性,并且时变的测量环境使测量噪声特性也不断变化,引起测量模型也有所失真,导致了 EKF 的失效。MMPF 性能优于 EKF,但劣于 GPF,这是因为 MMPF 中使用多个模型来描述 AUV 机动,当 AUV 机动情况未知,模型不能较好地符合真实运动时,算法性能受损,且多模型引入的模型竞争使 MMPF 需要更多的计算量,同样地,测量噪声特性的变化也影响了 MMPF 的性能。GPF 的估计性能最佳,这是因为灰色预测是基于实际测量值序列的,因此它采样得到的灰色粒子包含了机动 AUV 真实的运动状态信息,这样即使状态模型与真实运动模型失配,仍然有足够多有效的灰色粒子,而不至于使算法失效,且 GPF 不需要预设各种机动模型信息,计算量较小。此外,GPF 实时跟踪测量噪声统计特性的变化,提高了粒子权值的准确性。与传统方法相比,关于状态模型和测量模型的信息越缺乏,本算法的优势越明显,具有更强的稳健性。

#### 4 结论

本文提出了一种测量噪声时变和 AUV 机动状态未知的情况下,应用于 AUV 航深内测的灰色粒子滤波算法(GPF)。GPF 将灰色预测和小波变换融入粒子滤波算法中,利用灰色预测与基于状态模型的预测相结合来产生粒子,使粒子的先验分布有效地覆盖 AUV 的真实运动状态;并利用小波变换对测量噪声方差进行实时估计,从而修正粒子的权值,提高了粒子后验分布的正确性,克服了粒子滤波算法在解决动态问题时常出现的粒子退化问题。GPF 算法的性能通过实验进行了验证,并与 EKF 和 MMPF 算法进行了对比,实验结果表明了该 GPF 算法在机动 AUV 航深内测精度和算法稳健性上都具有一定的优势。

#### 参考文献 (References)

- [1] 张铭钧. 水下机器人[M]. 北京: 海洋出版社, 2000. ZHANG Mingjun. Underwater robot [M]. Beijing: Ocean Press, 2000. (in Chinese)
- [2] 卢健, 徐德民, 张立川, 等. AUV 同时定位与跟踪研究[J]. 计算机工程与应用, 2011, 47(16): 4-7. LU Jian, XU Demin, ZHANG Lichuan, et al. Research on simultaneous localization and tracking for AUVs[J]. Computer Engineering and Application, 2011, 47(16): 4-7. (in Chinese)
- [3] 刘正元, 王磊, 崔维成. 国外无人潜器最新进展[J]. 船舶力学, 2011, 15(10): 1182-1193. LIU Zhengyuan, WANG Lei, CUI Weicheng, State-of-the-art development of the foreign unmanned submersibles [J]. Journal of Ship Mechanics, 2011, 15(10): 1182-1193. (in Chinese)
- [4] Tanizaki H. Nonlinear filters: Estimation and application[M]. Berlin: Springer, 1996.
- [5] Chen J M, Cao X, Xiao Y, et al. Simulated annealing for optimisation with wireless sensor and actuator networks [J]. Electronics Letters, 2008, 44(20): 1208-1209.
- [6] Li X, Jilkov V. A survey of maneuvering target tracking-Part V: multiple-model methods [J]. IEEE Transaction on Aerospace and Electronic Systems, 2003, 41(4): 1255-1321.
- [7] Du S C, Shi Z G, Zang W, et al. Using interacting multiple model particle filter to track airborne targets hidden in blind doppler[J]. Journal of Zhejiang University-Science A, 2007, 8(8): 1277-1282.
- [8] Xu L J, Zhang J Q, Yan Y. A wavelet-based multisensor data fusion algorithm [J]. IEEE Transactions on Instrumentation and Measurement, 2004, 53(6): 1539-1545.
- [9] 邓聚龙. 灰色系统基本方法[M]. 武汉: 华中科技大学出版社, 2005. DENG Julong. The primary methods of grey system theory [M]. Wuhan: Press of Huazhong University of Science and Technology, 2005. (in Chinese)
- [10] Arulampalam M S, Maskell S, Gordon N J. A tutorial on particle filters for online nonlinear/non-gaussian Bayesian tracking [J]. IEEE Transaction of Signal Processing, 2002, 50: 174-188.
- [11] 陈俊丰. 基于粒子滤波的机动目标跟踪算法研究[D]. 杭州: 浙江大学, 2005. CHEN Junfeng. The target tracking algorithm research based on the particle filtering [D]. Hangzhou: Zhejiang University, 2005. (in Chinese)
- [12] Mallat S. A wavelet tour of signal processing [M]. San Diego, CA: Academic, 1998.
- [13] 高羽, 张建秋. 小波变换估计观测噪声方差的 Kalman 滤波算法及其在数据融合中的应用 [J]. 电子学报, 2007, 35(1): 108-111. GAO Yu, ZHANG Jianqiu. Kalman filter with wavelet-based unknown measurement noise estimation and its application for information fusion [J]. ACTA Electronica Sinica, 2007, 35(1): 108-111. (in Chinese)
- [14] Donoho D, Johnstone I. Ideal spatial adaptation via wavelet shrinkage [J]. Biometrika, 1994, 81: 425-455.
- [15] McGinnity S, Irwin G W. Multiple model bootstrap filter for maneuvering target tracking [J]. IEEE Transaction on Aerospace and Electronic Systems, 2000, 36(3): 1006-1012.