

基于灰色预测的粒子滤波算法^①王天真^{②***} 汤天浩* 张圣杰* Christophe Claramunt**

(* 上海海事大学电气自动化系 上海 200135)

(** 法国海军学院研究所 布雷斯特 29240)

摘要 针对标准粒子滤波(SPF)算法在目标机动时跟踪滤波性能不高的问题,引入灰色预测理论,提出了一种基于灰色预测的粒子滤波(PFGF)算法,给出了算法的具体描述和运算流程。当预先建立的状态模型不再适用于目标的真实运动状态时,该方法具有良好的预估性能,减少了对事先假定目标状态模型的依赖性。与 SPF 方法进行了蒙特卡洛仿真比较分析,实验结果证明,PFGF 算法在不增加计算复杂度的情况下,提高了跟踪精度,能够很好地克服粒子退化现象。

关键词 信息融合,粒子滤波,状态空间模型,灰色预测,粒子退化

0 引言

多传感器数据融合的主要任务之一是利用多传感器数据进行目标的状态估计。状态估计是对目标过去的运动状态进行平滑,对目标现在的状态进行滤波以及对目标未来的运动状态进行预测。实时处理能力差的滤波器在跟踪机动目标时很容易产生丢失跟踪的现象,而一个快收敛性的滤波器就能很好地解决锁定目标跟踪目标的任务。自适应 $\alpha - \beta$ 滤波具有一定的检测、跟踪机动目标的能力,其优点是运算量小,对目标跟踪的实时性好。但是自适应 $\alpha - \beta$ 滤波的滤波性能较差,即跟踪精度较差^[1]。粒子滤波算法是一种典型的非线性跟踪滤波方法,是基于蒙特卡洛仿真的最优回归贝叶斯滤波算法。该方法将状态矢量表示为一组带有相关权值的随机样本,并且基于这些样本和权值可以计算出状态估值^[2,3]。与其他滤波算法,如扩展卡尔曼滤波(EKF)算法、无轨迹卡尔曼滤波(unscented Kalman filtering, UKF)算法相比,粒子滤波方法不受线性化误差或高斯噪声假定的限制,适用于任何环境下的任何状态或者模型。但其滤波性能依赖于事先假定的目标状态模型,随着时间推移,当预先建立的状态模型不再适用于目标的真实运动状态时,会产生严

重的粒子退化现象。为了改善这种粒子退化现象,本文将具有良好预估性能且不需要精确状态模型的灰色预测理论^[4,5]引入到粒子滤波算法中,提出了一种基于灰色预测(gray forecast)的粒子滤波(particle filtering)算法,称为 PFGF 算法,该算法具有良好的预估性能,减少了对事先假定目标状态模型的依赖性。

1 粒子滤波的基本原理

粒子滤波算法最先由 Gordon 提出^[6-8],其基本思想是构造一个基于样本的后验概率密度函数。用 $\{x_{0:k}^i, w_k^i\}_{i=1}^N$ 表示系统后验概率密度函数 $p(x_{0:k}|z_{1:k})$ 的粒子集合,其中 $\{x_{0:k}^i, i = 1, \dots, N\}$ 是支持样本集,相应的权值为 $\{w_k^i, i = 1, \dots, N\}$,且满足 $\sum_{i=1}^N w_k^i = 1$,而 $x_{0:k} = \{x_i, j = 0, \dots, k\}$ 表示到 k 时刻系统所有状态的集合,所以时刻 k 的后验概率密度可以近似表示为 $p(x_{0:k}|z_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(x_{0:k} - x_{0:k}^i)$ 。

数学期望为

$$E(g(x_{0:k})) = \int g(x_{0:k}) p(x_{0:k}|z_{1:k}) dx_{0:k} \quad (1)$$

式(1)可以近似为

① 国家自然科学基金(51007056),交通部资助项目(2009-329-810-030)和上海市教育委员会重点学科建设(J50602)资助项目。

② 女,1978年生,博士,副教授;研究方向:智能信息处理与智能控制;联系人,E-mail: wtz0@sina.com

(收稿日期:2010-10-09)

$$E(g(x_{0,k})) = \sum_{i=1}^N w_k^i g(x_{0,k}^i) \quad (2)$$

粒子滤波依赖于重采样技术,粒子权值就是根据重采样技术来选择的。如果根据重要密度 $q(x_{0,k} | z_{1:k})$ 选择粒子,那么粒子的权值可以定义为

$$w_k^i \propto \frac{p(x_{0,k}^i | z_{1:k})}{q(x_{0,k}^i | z_{1:k})} \quad (3)$$

如果已经得到 $k-1$ 时刻后验密度 $p(x_{0,k-1}^i | z_{1:k-1})$ 的近似表示的粒子集合,接着就是用一个新的粒子集合来近似表示 k 时刻的后验密度 $p(x_{0,k}^i | z_{1:k})$ 。为了得到一种递归的表示方法,可以将选择的重要密度函数因式分解为

$$q(x_{0,k} | z_{1:k}) = q(x_k | x_{0,k-1}, z_{1:k}) q(x_{0,k-1} | z_{1:k-1}) \quad (4)$$

然后,通过将获得的新状态 $x_k^i \sim q(x_k | x_{0,k-1}, z_{1:k})$ 加入到已知的粒子集合 $x_{0,k-1}^i \sim q(x_{0,k-1} | z_{1:k-1})$ 中,得到新的粒子集合 $x_{0,k}^i \sim q(x_{0,k} | z_{1:k})$ 。根据贝叶斯规则,可以得到权值更新方程如下:

$$\begin{aligned} p(x_{0,k} | z_{1:k}) &= \frac{p(z_k | x_{0,k}, z_{1:k-1}) p(x_{0,k} | z_{1:k-1})}{p(z_k | z_{1:k-1})} \\ &= \frac{p(z_k | x_{0,k}, z_{1:k-1}) p(x_k | x_{0,k-1}, z_{1:k-1}) p(x_{0,k-1} | z_{1:k-1})}{p(z_k | z_{1:k-1})} \\ &= p(x_{0,k-1} | z_{1:k-1}) \frac{p(z_k | x_k) p(x_k | x_{k-1})}{p(z_k | z_{1:k-1})} \\ &\propto p(z_k | x_k) p(x_k | x_{k-1}) p(x_{0,k-1} | z_{1:k-1}) \end{aligned} \quad (5)$$

将式(5)和(4)代入式(3),得到权值更新方程

$$\begin{aligned} w_k^i &\propto \frac{p(z_k | x_k^i) p(x_k^i | x_{k-1}^i) p(x_{0,k-1}^i | z_{1:k-1})}{q(x_k^i | x_{0,k-1}^i, z_{1:k}) q(x_{0,k-1}^i | z_{1:k-1})} \\ &\propto w_{k-1}^i \frac{p(z_k | x_k^i) p(x_k^i | x_{k-1}^i)}{q(x_k^i | x_{0,k-1}^i, z_{1:k})} \end{aligned} \quad (6)$$

为得到一种更简单的形式,假设 $q(x_k | x_{0,k-1}, z_{1:k}) = (x_k | x_{k-1}, z_k)$, 那么重要密度只取决于 x_{k-1} 和 z_k , 因此,修正的权值为

$$w_k^i \propto w_{k-1}^i \frac{p(z_k | x_k^i) p(x_k^i | x_{k-1}^i)}{q(x_k^i | x_{k-1}^i, z_k)} \quad (7)$$

这样可以估算后验概率密度可以近似为

$$p(x_{0,k} | z_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(x_{0,k} - x_{0,k}^i) \quad (8)$$

当 $N \rightarrow \infty$ 时,上式估计式接近于真实的后验概率密度 $p(x_{0,k} | z_{1:k})$ 。

2 PFGF 算法

在目标的状态议程和量测方程为预先假定的数

学模型的情况下,使用标准粒子滤波器对该目标进行跟踪滤波时,抽样粒子是根据目标状态议程来计算的,权值是根据量测方程计算得到的。如果模型能够很好的表征目标的状态和量测,那么标准的粒子滤波算法也许能够达到很好的效果。然而,在目标机动的情况下,真实的动态特性很难用精准的数学模型表示,经过几个迭代周期后,大多数的粒子权值趋近于零,而导致粒子退化,这意味着那些包含少量目标状态信息的粒子最后将退化。为了改善这种粒子退化现象,本文利用灰色预测 GF(1,1)^[9] 良好的预估性能,提出一种基于灰色预测的粒子滤波算法,即 PFGF 算法。灰色预测的基本要求是,通过建立灰色预测模型,预测系统的状态变化,并控制与协调变化的方向与速度,使之向着人们所期望的目标发展^[10]。预测所采用的基本数学方法是建立状态方程。

灰色预测模型的设计思想是:原始数据序列(假设所有数据为正数)经过一次累加后,形成一个递增数列,这个新数列数据点的连线接近于指数函数 ($y = a \cdot e^{bx}$) 曲线,累加的次数越多,形成的数据点的连线也就越接近某个指数函数。那么根据这个指数函数可以外推到下一个(即第一个预测期)累加和,最后经过累减还原得到原序列预测值。

定义 1: 设初始序列为 $\{x^{(0)}(k)\} = \{x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)\}$, 其中 k 表示数据序列时刻,初始数据是 0 次累加数据,原始数据一次累加序列定义为

$$x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i) \quad (9)$$

n 次累加序列定义为

$$x^{(n)}(k) = \sum_{i=1}^k x^{(n-1)}(i) \quad (10)$$

定义 2: 经过 r 次累加数据序列 $x^{(r)}(k)$ 的 0 次数据累减为

$$a^{(0)}(x^{(r)}(k)) = x^{(r)}(k) \quad (11)$$

一次数据累减定义为

$$\begin{aligned} a^{(1)}(x^{(r)}(k)) &= x^{(r)}(k) - x^{(r)}(k-1) \\ &= x^{(r-1)}(k) \end{aligned} \quad (12)$$

n 次数据累减定义为

$$\begin{aligned} a^{(n)}(x^{(r)}(k)) &= a^{(n-1)}(x^{(r)}(k)) \\ &\quad - a^{(n-1)}(x^{(r)}(k-1)) \end{aligned} \quad (13)$$

$r = 1, 2, \dots$

设一个灰色系统中有 h 个变量,其中 x_1 为因变量, $x_2, x_3, \dots, x_h$ 为自变量, $x_1^{(1)}(k)$ 为原始数据序列

的一次累加序列,则描述该系统的模型为一个 n 阶微分方程

$$\frac{d^{(n)}x_1^{(1)}(t)}{dt^n} + a_1 \frac{d^{(n-1)}x_1^{(1)}(t)}{dt^{n-1}} + \cdots + a_n x_1^{(1)}(t) = b_1 x_2^{(1)}(t) + b_2 x_3^{(1)}(t) + \cdots + b_{h-1} x_h^{(1)}(t) \quad (14)$$

该方程称为 $GF(n, h)$ 模型,当 $n = 1$ 且 $h = 1$ 时, $GF(n, h)$ 模型退化为 $GF(1, 1)$ 模型,它是一种单序列的一阶线性动态模型,其微分方程为

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = u \quad (15)$$

令

$$X = \begin{bmatrix} -\frac{1}{2}(x^{(1)}(1) + x^{(1)}(2)) \\ -\frac{1}{2}(x^{(1)}(2) + x^{(1)}(3)) \\ \vdots \\ -\frac{1}{2}(x^{(1)}(n-1) + x^{(1)}(n)) \end{bmatrix}, E = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} \quad (16)$$

从而有

$$y_n = aX + uE \quad (17)$$

用最小二乘法求得方程的待定系数 a, u 。

由一阶线性微分方程的通解离散化可得 $GF(1, 1)$ 模型的响应函数(时间序列)为

$$\hat{x}^{(1)}(k+1) = \left(\hat{x}^{(1)}(1) - \frac{\hat{u}}{\hat{a}} \right) e^{-\hat{a}k} + \frac{\hat{u}}{\hat{a}} \quad (18)$$

系统还原值为

$$\hat{x}^{(0)}(k) = \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1) \quad (19)$$

初始条件为

$$\hat{x}^{(1)}(1) = x^{(1)} = x^{(0)}(1) \quad (20)$$

故而有

$$\hat{x}^{(0)}(k) = (1 - e^{\hat{a}}) \left(x^{(0)}(1) - \frac{\hat{u}}{\hat{a}} \right) e^{-\hat{a}(k-1)} \quad (21)$$

其中 a 称为发展灰数,它反映了数据序列估计值(包括预测值)的发展态势, u 称为灰作用量,它的大小反映了数据的变化关系,在系统中相当于作用量,将 $k = 2, 3, \dots, n$ 代入方程,便可求出未来任意时刻的系统原始序列的估计值,当 $k > n$ 时,便得到灰色模型的预测值 $\hat{x}^{(0)}(k)$ 。

2.1 算法描述

灰色预测不需要建立先验的运动状态模型,而是通过建立灰色预测模型(即上面所述的 $GF(1, 1)$ 模型)预测系统的状态变化,它能够在获得一些历

史测量数据的情况下预测系统的状态趋势。灰色预测的建模过程可以归结为以下 5 个步骤:

- (1) 求累加生产数据序列 $\hat{x}^{(1)}(k)$;
- (2) 确定数据矩阵 X, y_n ;
- (3) 用最小二乘法求参数列 a, u ;
- (4) 建立生产数据序列模型,求得 $\hat{x}^{(1)}(k)$ 的表达式;

(5) 代入初始条件,建立原始数据序列模型,求得 $\hat{x}^{(0)}(k)$ 的表达式。

PFGF 算法描述如下:

步骤 1: 构建一组包含最近量测的数据序列

$$z^{(0)} = \{z^{(0)}(1), z^{(0)}(2), \dots, z^{(0)}(n)\} = \{z^{(0)}(k); k = 1, 2, \dots, n\} \quad (22)$$

式中 $z^{(0)}(k)$ 是在 k 时刻的传感器量测数据, n 为数据序列长度。

步骤 2: 生成一阶累加序列(1-AGO)

$$z^{(1)} = \{z^{(1)}(1), z^{(1)}(2), \dots, z^{(1)}(n)\} = \{z^{(1)}(k); k = 1, 2, \dots, n\} \quad (23)$$

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

步骤: 构建微分方程

$$\frac{dz^{(1)}}{dt} + az^{(1)} = b \quad (24)$$

初始值 $z^{(1)}(1) = z^{(0)}(1), a, b$ 可由式

$$\hat{a} = \begin{bmatrix} a \\ b \end{bmatrix} = (B^T B)^{-1} B^T Y_N \quad (25)$$

得到。

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

$\alpha z^{(1)}(k) + (1 - \alpha)z^{(1)}(k-1), k = 2, 3, \dots, n, \alpha$ 为权值因数。

步骤 4: 获得预测值

一旦 a, b 值已知,那么可用微分方程预测状态 z 在 $k+1$ 时刻的值。1-AGO 灰色预测模型如下:

$$\hat{z}^{(1)}(k+1) = [z^{(0)}(1) - \frac{b}{a}]e^{-ak} + \frac{b}{a}, \quad k = 0, 1, \dots \quad (26)$$

状态的预测值可由对上式求逆得到:

$$\begin{aligned} \hat{z}^{(0)}(k+1) &= \hat{z}^{(1)}(k+1) - \hat{z}^{(1)}(k) \\ &= (1 - e^{-a})[z^{(0)}(1) - \frac{b}{a}]e^{-ak} \end{aligned} \quad (27)$$

2.2 算法流程

PFGF 算法的核心思想是通过两种途径获得新

粒子:一是通过抽样,二是通过灰色预测。这就是说在每个时刻 k , 一些粒子通过对 $k-1$ 时刻的状态转换抽样得到;同时,其他的粒子通过对新近的量测 $z_{(k-L):(k-1)}^x$ 和 $z_{(k-L):(k-1)}^y$ 进行灰色预测得到。所有的粒子由这两部分粒子构成,然后根据标准粒子滤波 (standard particle filtering, SPF) 算法进行加权,估计和重抽样。PFGF 算法流程如图 1 所示。




图1 PFGF 算法流程图

初始化时, $k=0, j=1, \dots, N_p$, 生成粒子 $\{x_0^j \sim p(x_0)\}$, 计算权值 $w^j = 1/N_p$ 。灰色预测算法计算时, $k=1$ 时刻开始, 计算公式如下:

$$X_k^{grey} = grey_pre(z_{(k-L):(k-1)}^x), \quad k = L+1, L+2, \dots$$

$$Y_k^{grey} = grey_pre(z_{(k-L):(k-1)}^y), \quad k = L+1, L+2, \dots$$

在抽样计算时, 生成粒子 1 的方程如下:

$$x_k^j = \begin{bmatrix} X_k^{grey} \\ v_{xk} \\ Y_k^{grey} \\ v_{yk} \end{bmatrix} + B(T)\omega_k^j$$

其中, $v_{xk} = (X_k^{grey} - X_{k-1}^{grey})/T, v_{yk} = (Y_k^{grey} - Y_{k-1}^{grey})/T, \omega_k^j \sim N(0, Q)$ 。

在归一化抽样时生成粒子 2 的方程如下:

$$x_k^j = A(T)x_{k-1}^j + B(T)\omega_k^j$$

计算重要粒子的权值的方程如下:

$$w_k^j = w_{k-1}^j p(z_k | x_k^j)$$

$$\bar{w}_k^j = w_k^j / \sum_{j=1}^{N_p} w_k^j$$

状态估计的方程如下:

$$\hat{x} = E[x_k | z_{1:k}] = \sum_{j=1}^{N_p} \bar{w}_k^j x_k^j$$

其中 $p(x_0)$ 是状态向量的初始概率; N_p 为粒子总数, N_p^{grey} 是由灰色预测生成的粒子数; L 是用于灰色预测算法的数据序列长度。 $X_k^{grey}, Y_k^{grey}, v_{xk}, v_{yk}$ 分别表示 k 时刻目标在 X 坐标轴、 Y 坐标轴上的位置、速度信息。

3 仿真分析

使用本文提到的标准粒子滤波算法 (SPF 算法) 和 PFGF 算法对非线性系统的状态估计进行仿真比较。系统模型如下:

$$x_k = A(T)x_{k-1} + B_u(T)u_k + B_w(T)w_k$$

$$z_k = Hx_k + v_k$$

式中

$$A = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix} \text{ 是状态转移矩阵;}$$

$$B_u = \begin{bmatrix} \frac{T^2}{2} & 0 \\ T & 0 \\ 0 & \frac{T^2}{2} \\ 0 & T \end{bmatrix} \text{ 是输入矩阵;}$$

$u_k = [u_{xk}^*, u_{yk}^*]'$ 为加速度输入向量, 不同的 u_k 构成不同的机动模型;

w_k 是零均值, 协方差为 Q 的白噪声输入向量, $Q = [4^2, 0; 0, 4^2]^T; H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$ 为测量矩阵;

v_k 是零均值, 协方差为 R 的高斯噪声向量, $R = [20^2, 0; 0, 20^2]^T$;

$T=0.5s$ 为采样间隔, $\alpha=0.4, L=10$, 总的粒子数 $N_p=1000$ 。

目标从坐标原点开始运动, X 轴和 Y 轴的初始速度都是 $10m/s$ 。用于灰色预测的粒子数 $N_p^{grey} = N_p/10$, 表 1 给出了目标运动的详细情况, 包含了物体运动的各个过程。

表 1 目标运动详细情况

时间(s)	运动状态
0 ~ 60	匀速
61 ~ 70	加速度($8\text{m/s}^2, 0\text{m/s}^2$)
71 ~ 85	匀速
86 ~ 106	加速度($-8\text{m/s}^2, 0\text{m/s}^2$)
107 ~ 110	加速度($0\text{m/s}^2, 8\text{m/s}^2$)
111 ~ 120	匀速

试验进行了 100 次的蒙特卡罗仿真。系统目标状态的真实值与两种滤波算法对系统状态的估计如图 2 – 图 5 所示。比较这 4 幅图可以看出,当目标处于机动状态时,SPF 算法已不能很好地维持跟踪精度,这是因为当目标的运动状态发生突变时,状态模型已不再满足目标的运动状态,这时,大多数粒子的权值将衰减,在这种情况下 SPE 算法不能达到理想的效果。相反,PFGE 算法相对于 SPF 算法则具有较好的效果,这是因为PFGE算法结合了预设模




图 2 X 轴方向目标轨迹




图 3 X 轴方向的误差




图 4 Y 轴方向目标轨迹




图 5 Y 轴方向的误差

型和自由模型的特点。即使那些由预设模型采样得到的粒子失去效用,但由灰色预测模型产生的粒子仍然维持着目标状态的信息,从而保证了跟踪精度。从表 2 中可以明显地看出,虽然两种方法的计算复杂度(用计算用时表示)接近,但是 SPF 算法的均方根误差要比 PFGE 算法的大很多,而且存在漏跟踪的问题。

表 2 仿真结果性能比较

	X 方向均方误差(m)	Y 方向均方误差(m)	复杂度(计算用时)(s)	跟踪丢失数目
SPF	10.1240	8.1256	2.1256	6
PFGE	5.7636	4.0364	2.1324	0

4 结 论

当目标机动的情况下,真实的动态特性很难用精准的数学模型表示,标准粒子滤波方法经过几个迭代周期后,大多数的粒子权值趋近于零,而导致粒

子退化,这意味着那些包含少量目标状态信息的粒子最后将退化。为了改善这种粒子退化现象,本文将具有良好预估性能的灰色预测引入到标准的粒子滤波算法中,提出了一种基于灰色预测的粒子滤波算法,给出理论推导和具体算法描述。并将其与标准粒子滤波方法进行了仿真比较,实验结果表明新算法在不增加计算复杂度的情况下,提高了跟踪精度,能够很好地克服粒子退化现象。

参考文献

- [1] 刘凯,李辉等. 一种新的含噪混沌信号降噪算法. 电子与信息学报, 2008, 30(8):1849-1852
- [2] Bouaynaya N, Schonfeld D. On the optimality of motion-based particle filtering. *Circuits and Systems for Video Technology, IEEE Transactions on*, 2009, 19(7): 1068 - 1072
- [3] Derek Yee, Reilly J P, Kirubarajan T. Approximate conditional mean particle filtering for linear/nonlinear dynamic state space models. *Signal Processing, IEEE Transactions on*, 2008, 56(12): 5790 - 5803
- [4] Laska B N M, Bolic M, Goubran R A. Particle filter enhancement of speech spectral amplitudes. *Audio, Speech, and Language Processing, IEEE Transactions on*, 2010, 18(8): 2155-2167
- [5] Nordlund P J, Gustafsson F. Marginalized particle filter for accurate and reliable terrain-aided navigation. *Aerospace and Electronic Systems, IEEE Transactions on*, 2009, 45(4): 1385-1399
- [6] Givon D, Stinis P, Weare J V. Reduction for particle filters of systems with time scale separation. *Signal Processing, IEEE Transactions on*, 2009, 57(2): 424-435
- [7] Kim K J, Pun M O, Iltis R A. Joint carrier frequency offset and channel estimation for uplink MIMO-OFDMA systems using parallel schmidt rao-blackwellized particle filters. *Communications, IEEE Transactions on*, 2010, 58(9): 2697-2708
- [8] El-Fouly T H M, El-Saadany E F, Salama M M A. Grey predictor for wind energy conversion systems output power prediction. *Power Systems*, 2006, 21(3): 1450-1452
- [9] Chang E C, Liang T J, Chen J F. Real-time implementation of grey fuzzy terminal sliding mode control for PWM DC-AC converters. *Power Electronics, IET*, 2008, 1(2): 235-244
- [10] Oniz Y, Kayacan E, Kaynak O A. Dynamic method to forecast the wheel slip for antilock braking system and its experimental evaluation. *Systems, Man, and Cybernetics, Part B: Cybernetics*, 2009, 39(2): 551-560

A particle filter algorithm based on gray forecast

Wang Tianzhen^{* **}, Tang Tianhao^{*}, Zhang Shengjie^{*}, Christophe Claramunt^{**}

(^{*} Department of Electrical Automation, Shanghai Maritime University, Shanghai 200135)

(^{**} Naval Academy Research Institute of France, Brest 29240)

Abstract

The standard particle filter (SPF) algorithm's problem of low target-tracking performance due to the serious granule degeneration that occurs when the state model deviates the target's motion state is paid attention, and aiming at this, a particle filter algorithm based on the gray forecast theory, called the PFGF algorithm is presented with the detailed description of it. When the condition model established in advance is no longer suitable for the goal's proper motion condition, this new algorithm is with the good estimate performance. It reduces the dependence on the beforehand target condition model. The Monte-Carlo simulation results show that the new algorithm increases the tracking accuracy without increasing the computation complexity compared with the SPF algorithm. It can overcome the phenomenon of granule degeneration effectively.

Key words: information fusion, particle filter, state - space model, gray forecast, granule degeneration