

基于粒子滤波与线性自回归的故障预测算法

龙 凤¹, 薛冬林², 陈桂明¹, 杨 庆¹

(1. 第二炮兵工程学院 装备管理工程系, 陕西 西安 710025;

2. 第二炮兵 96604 部队, 北京 100192)

摘 要:粒子退化是粒子滤波在故障预测应用中存在的主要问题。针对粒子滤波算法样本贫化问题,提出一种基于粒子滤波与线性自回归的故障预测算法。在算法的状态估计阶段,使用混合状态系统模型和粒子滤波算法对系统状态的概率密度函数进行估计,并实时给出故障发生概率;在算法的状态预测阶段,采用线性自回归模型对故障征兆随时间的演化情况进行估计及修正,同时给出剩余使用寿命的概率密度函数。故障预测仿真实验结果证明了算法的有效性。

关键词:粒子滤波;线性自回归模型;故障预测

中图分类号:TP206+.3

文献标识码:A

文章编号:1673-629X(2011)11-0133-04

Fault Prediction Algorithm Based on Particle Filter and Linear Autoregressive Models

LONG Feng¹, XUE Dong-lin², CHEN Gui-ming¹, YANG Qing¹

(1. Dept. of Equipment Management Eng., The Second Artillery Eng. College, Xi'an 710025, China;

2. Troops NO. 96604, Beijing 100192, China)

Abstract: Particle degeneracy is the main problem when a particle filter is applied to fault prediction. Focusing on the problem of sample impoverishment of particle filter algorithm, the fault prediction algorithm based on particle filter and linear autoregressive models is proposed. At the state estimation stage, the algorithm uses hybrid system state models and particle filter to estimate probability density function of the system state and support the real-time fault prognosis. At the state prediction stage, the algorithm estimates and corrects the system fault evolution process using linear autoregressive models. Simulation results demonstrate that the fault prediction algorithm based on particle filter and linear autoregressive models is feasible.

Key words: particle filter; linear autoregressive models; fault prediction

0 引 言

粒子滤波算法是一种基于蒙特卡罗方法和递推贝叶斯估计的滤波方法,核心思想是利用一系列随机样本的加权和表示所需的后验概率密度,得到状态的估计值,近年来成为一种用作非线性动态系统参数估计的工具^[1-3]。粒子滤波算法存在的主要问题是粒子退化问题,即经过若干次递推之后,除了很少的几个粒子以外,大部分粒子的权值几乎等于零,从而严重影响了粒子滤波的跟踪能力,对于估计那些较长时间维持不变的量时,样本贫化现象尤为严重,致使大量的计算资源浪费在对结果毫无意义的粒子上^[4,5]。

针对电子系统非线性非高斯的特点,文中提出一

种基于粒子滤波的故障诊断与预测结构,同时给出相应环节的实现算法。该结构包含两个模块:故障检测与识别(FDI, Fault Diagnosis and Identification)模块和剩余寿命评估(RULP, Remaining Usage Life Prediction)模块^[6]。前者使用混合状态系统模型和粒子滤波算法对系统状态的概率密度函数(PDF, Probability Density Function)进行估计,并实时给出故障发生概率;后者基于危险区域,采用线性自回归(LAR, linear autoregression)模型对故障征兆随时间的演化情况进行估计及修正,同时给出剩余使用寿命的PDF,最后给出例证。

1 基于粒子滤波的动态故障诊断组合模型

在某种意义上,故障诊断应当包括故障检测与识别和故障严重程度分析两种功能。以此为目的,文中提出了基于粒子滤波的非高斯噪声和非线性过程动态模型的故障诊断组合模型。为满足实时性,在该结构

收稿日期:2011-04-22;修回日期:2011-07-27

基金项目:军队科研项目(2010066)

作者简介:龙 凤(1972-),男,博士研究生,从事机械设备状态监测与故障诊断技术研究;陈桂明,教授,博士生导师,从事机械设备状态监测与故障诊断教学与研究工作。

中使用简化的粒子群来表示状态 PDF,同时支持对特征向量(测量结果)所含的所有信息进行融合,并根据融合结果确定系统的工作状态以及异常原因。另外,使用一个建立在非线性动态状态模型上的粒子滤波模块,并将基于模型和基于数据驱动的故障诊断技术进行优化组合^[7]。组合模型用式(1)表示如下:

$$\begin{cases} x_d(t+1) = f_d(x_d(t) + n(t)) \\ x_c(t+1) = f_c(x_d(t), x_c(t), \omega(t)) \\ \text{Features}(t) = h_t(x_d(t), x_c(t), \nu(t)) \end{cases} \quad (1)$$

其中, f_d , f_c 和 h_t 都是非线性函数。 $x_d(t)$ 是离散状态集合,与系统中的某一特定工作状态有关(如正常状态、故障状态 #1、故障状态 #2 等)。 $x_c(t)$ 是连续状态集合,描绘系统在给定工作条件下的演化情况。 $\omega(t)$ 和 $\nu(t)$ 是非高斯分布函数,分别描述过程噪声和特征噪声(测量噪声)。由于噪声信号 $n(t)$ 是与离散状态有关的不确定性的一种度量,因此用有界域上一个随机变量来定义它的概率密度。为简便,假设 $n(t)$ 是零均值、独立同分布的均匀白噪声。

基于式(1),文中提出的粒子滤波方法针对离散状态和连续状态都可以进行统计特征分析,能够给出任一给定时刻与某个故障模式有关的概率估计,以及系统中所关心物理变量的 PDF 估计。FDI 模块因此就可以对这些估计信息进一步进行处理,进行故障报警并给出检测过程的置信度。再者,系统连续状态的 PDF 估计(在故障检测时计算出来)也可以用作故障预测程序的初始状态,实现从 FDI 模块到预测模块的平滑衔接,在故障报警之后的若干个工作周期之内,给出可靠的预测信息。这也是文中所提出的基于粒子滤波的故障预测结构的一个主要优点。

2 基于粒子滤波的实时故障预测算法

为减小长期预测的不确定性,文中提出基于粒子滤波的预测算法使用的信息包括:当前状态的 PDF 估计信息、过程噪声模型和对先前预测进行修正的记录信息^[8]。算法分为三个阶段:

第一阶段基于先验估计和噪声模型对有关概率进行调整,得到 p -step 后的预测信息。

第二阶段使用第一级预测信息,根据定义的阈值,对 RUL(以故障时间 TTF 表示,Time To Failure)的 PDF 进行估计,同时进一步提高预测准确性。

第三阶段使用设计的一种预测修正算法对第二级的 RUL 估计进行修正。

2.1 p-step 后的系统状态预测

第一阶段预测 p -step 后的系统状态,通过递归使用当前状态估计来实现。

$$\begin{aligned} \tilde{p}(x_{t+p} | y_{1:t}) &= \int \tilde{p}(x_t | y_{1:t}) \prod_{j=t+1}^{t+p} p(x_j | x_{j-1}) dx_{t:t+p-1} \\ &\approx \sum_{i=1}^N w_t^{(i)} \int \cdots \int p(x_{t+1} | x_t^{(i)}) \prod_{j=t+2}^{t+p} p(x_j | x_{j-1}) dx_{t+1:t+p-1} \end{aligned} \quad (2)$$

由于式(2)中的积分运算计算量很大,算法难以实现,因此考虑对状态概率密度分布函数 PDF 的预测: $\hat{p}(\hat{x}_{t+k}^{(i)} | \hat{x}_{t+k-1}^{(i)})$ 。当以粒子 $\hat{x}_{t+k-1}^{(i)}$ 作为初始条件时,它给出了将来某个时刻 $t+k$ ($k=1, \dots, p$) 时状态的分布情况。假设在时刻 t ,用来描述系统当前状态 PDF 使用的权重集合为 $\{w_t^{(i)}\}_{i=1, \dots, N}$,那么通过全概率定律以及 $t+k-1$ 时刻的粒子权重,可以给出 $t+k$ 时刻的系统状态 PDF 估计,如式(3)所示。

$$\begin{aligned} \hat{p}(x_{t+k} | \hat{x}_{t+k-1}) &\approx \sum_{i=1}^N w_{t+k-1}^{(i)} \cdot \hat{p}(x_{t+k}^{(i)} | x_{t+k-1}^{(i)}); \\ \hat{x}_t^{(i)} &= \tilde{x}_t^{(i)}; k=1, \dots, p \end{aligned} \quad (3)$$

为计算式(3),考虑到噪声和过程的非线性会随着时间改变状态 PDF 的形状,因此每个粒子的权重在每一时刻的预测步骤中都应当进行修正。但是,由于预测过程本身需要对权重进行修改,它不能依赖于获取的新测量数据。另外,在进行下一个时刻预测之前,还需要在概率分布的区域内对粒子进行重新分布。解决上述问题可以有以下两种方法。

2.1.1 p-step 后的系统状态预测的第一种方法

第一种方法即连续计算方法,对每一后续时刻都计算状态的期望值,也就是说 p 步就要计算 p 次,以这种方式来连续对每个粒子的随时间演化情况进行预测。将与该粒子有关的状态值作为初始条件,如式(4)所示。

$$\hat{x}_{t+p}^{(i)} = E[f_{t+p}(\tilde{x}_{t+p-1}^{(i)}, \omega_{t+p})]; \hat{x}_t^{(i)} = \tilde{x}_t^{(i)} \quad (4)$$

在这种方式下,就计算量而言,第一种长期预测方法比较简单。这种方法的潜在含义是:将后续时刻粒子权值视为不变所带来的误差,与模型误差甚至是与过程参数误差和噪声参数误差相比,其影响可以忽略。因此,当目前的粒子权重不随时间改变时,式(4)足以用来对粒子群 $\hat{x}_{0:t+k}^{(i)}$ 进行扩展。这种方法的计算量相对较小,比较适合于 p 值较小,即短期预测。

2.1.2 p-step 后的系统状态预测的第二种方法

与第一种方法相比,第二种方法不采用连续计算方式,而是直接考虑 p 步之后系统状态 PDF,因此,需要找到一种能够综合考虑从 t 时刻到 $t+p$ 时刻,时长为 p 步的系统状态变化的不确定性,给出 p 步之后系统状态 PDF 的方法。考虑到实时性需求,文中提出基于重采样的解决方法:即通过重采样得到 p 步之后系统状态 PDF,以重采样来解决 p 步时长的状态转换不确定性。这种方法简单有效,不需计算粒子权值,比较适

合长期预测^[9,10]。

从这种角度考虑,未来时刻的状态分布由粒子的位置决定,而不是由粒子权重决定。但是,此方法必须确保重采样后的粒子群能够较准确地表示式(3)。因此,考虑到实时性需求以及计算量大小,文中提出一种解决途径:基于过程噪声的无关性假设($\omega(t)$ 为对角协方差矩阵),并采用核函数来描述重采样之前的状态 PDF。

对式(3)采用式(5)的离散形式近似,其中的 K 函数是核函数,与过程噪声 PDF 相对应,它可以是一个高斯核或 Epanechnikov 核^[11]。

$$\hat{p}(x_{t+k} | x_{1:t+k-1}) \approx \sum_{i=1}^N w_{t+k-1}^{(i)} K_h(x_{t+k} - E[x_{t+k}^{(i)} | \hat{x}_{t+k-1}^{(i)}]) \quad (5)$$

$$K_h = \frac{1}{h^{n_x}} K\left(\frac{x}{h}\right), h_{opt} = A \cdot N^{\frac{1}{n_x+4}}, \quad A = (8C_{n_x}^{-1} \cdot (n_x + 4) \cdot (2\sqrt{\pi})^{n_x})^{\frac{1}{n_x+4}} \quad (6)$$

$$K(x) = \begin{cases} \frac{n_x + 2}{2C_{n_x}} (1 - \|x\|^2) & \text{if } \|x\| \leq 1 \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

其中, C_{n_x} 是 R^{n_x} 中单位球的体积。算法出发点为:寻找一种能够表示式(5)中不确定性的方法,这样做比第一种方法计算状态变量的条件期望值似乎更合理。为实现这个目的,一种方法是在时刻 $t+k$ ($1 \leq k \leq p$), 新生成一群权重相等的粒子,可以通过执行一次逆向变换重采样来实现。这种方法从满足(4-19)的分布中采集样本,按照均匀分布 $u^{(i)} \sim U(0,1)$ 选择 N 个粒子,并且从累积状态分布 $F(X_{t+k} \leq x_{t+k}) = \int_{-\infty}^{x_{t+k}} \hat{p}(x_{t+k} | \hat{x}_{1:t+k-1}) dx_{t+k}$ 中按照 $\hat{x}_{t+k}^{(i)} = F^{-1}(u^{(i)})$ 为每个 $\hat{x}_{t+k}^{(i)}$ 赋值。

但是,这种逆向变换重采样存在随机性,可能会导致累积状态分布函数的值域中出现未被表示的区域,由于长期预测是在没有测量数据的情况下进行的,因此这种错误很难得到改正。为解决这个问题,文中提出以下策略:

首先在重采样过程中执行一次简化的逆向变换重采样,仅将重点放在对式(5)中不确定性的变化表示上。这样,样本的选择使用 $u^{(i)} = i \cdot (N+1)^{-1}$ ($i=1, 2, \dots, N$) 来实现, $\hat{x}_{t+k}^{(i)}$ 的赋值仍按照上面的方式进行。

为避免减弱粒子差异性,可以采用 RPF 算法。这样,假设状态协方差矩阵 \hat{S}_{t+k} 等于 $\hat{x}_{t+k}^{(i)}$ 的经验协方差矩阵,并且相应于 $\hat{x}_{t+k-1}^{(i)}$ 的一组权重相等的粒子是已知的,那么采用 Epanechnikov 核进行 PDF 估计就可以达到最优效果。

综上所述, p 步预测的算法如下:

执行改进的逆向变换重采样:

$i = 1, 2, \dots, N, w_{t+k}^{(i)} = N^{-1}$, 计算 \hat{S}_{t+k} , $\{E[x_{t+k}^{(i)} | \hat{x}_{t+k-1}^{(i)}] w_{t+k}^{(i)}\}_{i=1}^N$ 的经验协方差矩阵;

计算 \hat{D}_{t+k} 使得 $\hat{D}_{t+k} \hat{D}_{t+k}^T = \hat{S}_{t+k}; i=1, 2, \dots, N$, 按照 $\varepsilon^i \sim K$ 采样,并且使 $\hat{x}_{t+k}^{(i)*} = \hat{x}_{t+k}^{(i)} + h_{t+k}^{opt} \hat{D}_{t+k} \varepsilon^i$, 其中 h_{t+k}^{opt} 按照式(6)计算。这里需要说明的是,假设过程噪声是无关的,但这仅仅是出于减轻计算量的角度。实际上即使没有这种假设,上述算法也不存在任何理论约束。

2.2 RUL 估计和统计特征描述

预测算法的最终输出结果是系统 RUL 的 PDF 估计,这和未来某个时刻系统的故障发生概率密切相关。如果根据经验知识将系统的临界状态以故障征兆的阈值形式(又称为危险区域)表示出来,那么根据预测结果,就可以得到这个概率。

在实际应用中,希望可以根据历史故障数据统计性地确定这个危险区域 $[H_b, H_w]$, 实际上这是故障征兆 PDF 的一个临界区间。

由于对于某一固定值的故障征兆,危险区域指明了故障发生概率,并且以加权的一组粒子来表示,因此对于未来任意的某一时刻,这个概率是可以计算的。可以通过全概率定律来计算,如式(8)所示。一旦 RUL 的 PDF 计算出来后,就可以很方便地得到预测的置信区间以及 RUL 的期望值。

$$\hat{P}_{TRF}(t|f) = \sum_{i=1}^N P_i(\text{Failure} | X = \hat{x}_{t+f}^{(i)}, H_b, H_w) \cdot w_{t+f}^{(i)} \quad (8)$$

式(8)适合实时应用,但由于它依赖于粒子权重,易受到不确定性的影响,并且还可能对模型误差敏感;再者,随着预测周期的加长,这种不确定性也会加大。考虑到在故障发生条件被检测出来后需要立即进行 RUL 估计,并且预测的时间跨度往往较长,这个问题需要特别引起注意。为减小基于粒子滤波的故障预测中存在的 uncertainty,同时提高 RUL 估计的准确性,文中提出一种基于线性自回归模型的修正方法。

2.3 基于线性自回归模型的修正

按照线性自回归模型的定义,这种方法本质上是一种数据驱动的学习过程。通过比较当前时刻 $t=j$ 的 RUL 与预测算法前一次迭代得到的 RUL 的差异,可以得到一组修正项 C_j ($j=1, 2, \dots, k$)。在 k 个修正项得到之后,建立线性自回归模型^[12]:

$$RUL^{(C)} = RUL - \sum_{j=k+1}^{j < RUL} \hat{C}_j \quad (9)$$

然后使用该模型对未来的修正项 $\hat{C}_{k+1}, \dots, \hat{C}_{RUL}$ 进行估计。如果故障发生之前能够得到测量数据,这些修正项就可以用来进行 RUL 估计,这里需要假设过程噪声和测量噪声都是广义平稳的。通过这种方式对当

前 RUL 进行修正,得到 $RUL^{(C)}$ 。基于线性自回归模型的修正方法的示意图如图 1 所示。




图 1 基于线性自回归模型的修正示意图

简单来说,这种修正方法实际上就是从 t 时刻以前的,根据测量结果对预测进行的修正中,得到用于对当前预测进行修正的参数,实现对当前预测的修正。通过这种不断迭代进行的学习过程,进一步提高预测的准确度。

3 仿真实例

考虑如下系统的 RUL 估计问题:

$$\begin{cases} x_1(t+1) = x_1(t) + 3 \cdot 10^{-4}(0.05 + 0.1 \cdot x_2(t))^3 + \omega_1(t) \\ x_2(t+1) = x_2(t) + \omega_2(t) \\ y(t) = x_1(t) + v(t) \end{cases}$$

$$\omega_1(t) \sim \text{Gamma}(0.15, 0.3)$$

$$v(t) \sim 0.25N(-0.5, 0.25) + 0.75N(0.5, 0.25)$$

(10)

式中, $\omega_2(t)$ 是零均值高斯噪声。另外,为对 RUL 估计中的模型误差和不确定性的影响进行分析,假设噪声是高斯噪声。这样,过程和测量噪声的前两阶矩可以使用历史数据进行估计,假设它们为:

$$\omega_1(t) \sim N(0.045, 0.1162), v(t) \sim N(0.25, 0.5)$$

(11)

实际应用中,根据实际需求说明或实测故障历史数据定义一个“危险区域”,这里将其 PDF 定义为正态分布 $\mu = 9.0, \sigma = 0.3$ 。目的是要在故障检测后的 40 周期后,生成 95% 的 RUL 置信区间。另外,除了使用前面两种预测方法外,还使用基于 EKF 的方法进行预测,以便和提出的基于 PF 的方法作比较。

比较结果如图 2 所示。图中的灰色线和黑色线分别表示使用 SIR 粒子滤波得到的噪声和过程的估计

值,点划线表示未来时刻故障演化的实际情况(在进行 RUL 估计时,这种信息是未知的)。

结果显示,文中提出的第二种基于 PF 的长期预测算法能够消除由模型误差带来的偏移,主要原因在于这种方法不仅能够表示状态概率空间,同时重采样技术与 Epanechnikov 核组合使用的方式也能消除模型误差的影响,使 RUL 估计的准确性得到提高。再者,实际的故障指示信息也落在预先定义的 95% 置信区间内,证实了对 RUL 的 PDF 估计正确性。如果在此基础上再采用修正算法, RUL 估计结果还可以进一步得到改善,如图中所示,几乎和实际值没有差别。




图 2 不同 RUL 估计方法的结果比较

4 结束语

文中提出的基于粒子滤波的故障检测识别与故障预测算法,适用于不同预测时长需求。基于重采样与 Epanechnikov 核的故障预测与修正方法,可以有效消除长期预测中因模型误差带来的预测误差,使 RUL 估计的准确度得到提高。

参考文献:

- [1] Arulampalam M S, Maskell S, Gordon N, et al. A Tutorial on Particle Filters for Online Nonlinear/non-Gaussian Bayesian Tracking[J]. IEEE Transactions on Signal Processing, 2002, 50:174-188.
- [2] 张 琪, 胡昌华, 乔玉坤, 等. 基于权值选优粒子滤波器的故障预测算法[J]. 系统工程与电子技术, 2009, 31(1): 221-224.

(下转第 140 页)

对比图,横坐标是仿真时间,纵坐标是汇聚节点收到的数据总量。从图 5 中可以看出,在所有传感器节点能量相等、网络总能量相等的情况下,HMP 算法汇聚节点收到的数据总量在整个仿真时间里比 LEACH 算法汇聚节点收到的数据总量要多。




图 5 HMP 和 LEACH 汇聚节点收到的数据总量

4 结束语

从以上仿真可以得出,HMP 算法通过结合迪杰斯特拉算法寻找簇首传输数据的最优路径,减少了簇首节点通信能耗,同时,为了防止靠近汇聚节点的最优路径上的簇首节点因为能量的过渡消耗而过早死亡,HMP 算法维护了多条路径,在簇首选择转发节点进行数据转发时,考虑了转发节点的当前剩余能量。仿真结果说明了 HMP 算法能够均衡网络能量消耗,提高能量的有效性,从而延长网络生命周期。

参考文献:

- [1] 王 殊,阎毓杰,胡富平,等.无线传感器网络的理论与应

用[M].北京:北京航空航天大学出版社,2007.

- [2] 宋 文,王 兵,周迎宾.无线传感器网络技术与应用[M].北京:电子工业出版社,2007.
- [3] 李善仓,张克旺.无线传感器网络原理与应用[M].北京:机械工业出版社,2008.
- [4] Yang Guang, Yin Guisheng, Yang Wu. Intra-Cluster Multi-Hop Routing Algorithm Based on Forwarding Restriction Angle in WSNs[C]//IEEE of Chinese of Control and Decision Conference (CCDC'08). [s. l.]: [s. n.], 2008:2035-2039.
- [5] 汪祥莉,李腊元,王文波.无线传感器网络中的路由协议研究[J].计算机科学,2008, 35(7):50-60.
- [6] 孙利民,李建中,陈 渝,等.无线传感器网络[M].北京:清华大学出版社,2005.
- [7] 石军锋,钟先信.一种无线传感器网络的跨层节能同步机制[J].计算机科学,2008, 35(2):42-46.
- [8] 陈慧南.算法设计与分析[M].北京:电子工业出版社,2006.
- [9] Kuorilehto M, Suhonen J, Kohvakka M, et al. Experimenting TCP/IP for Low-Power Wireless Sensor Networks[C]//IEEE of the 2006 International Colloquium on Personal, Indoor and Mobile Radio Communications. [s. l.]: [s. n.], 2006:1-6.
- [10] Farivar R, Fazeli M, Miremadi S G. Directed Flooding: A Fault-Tolerant Routing Protocol for Wireless Sensor Networks [C]//Proceeding of the 2005 Systems Communications. [s. l.]: [s. n.], 2005:395-399.
- [11] Yee R, Kleinrock L. Qos Control for Sensor Networks[C]//Proceedings of the IEEE International Conference on Communications. [s. l.]: [s. n.], 2003:517-521.
- [12] Hassanein H, Luo Jing. Reliable energy aware routing in wireless sensor networks[C]// Proceeding of the Second IEEE Workshop on Dependability and Security in Sensor Networks and Systems. [s. l.]: [s. n.], 2006:54-64.

(上接第 136 页)

- [3] 王林艳,李 蔚,王党利,等.非线性机械故障诊断的核分布粒子滤波方法[J].西安工业大学学报,2010,30(5):433-437.
- [4] 徐贵斌,周东华.非线性动态系统故障预测方法[J].华中科技大学学报(自然科学版),2009,37(S1):23-27.
- [5] 葛哲学,杨拥民,胡 政,等.非高斯噪声下基于 Unscented 粒子滤波器的非线性系统故障诊断方法[J].兵工学报,2007,28(3):332-335.
- [6] Kadirkamanathan V, Li P, Jaward M H, et al. Particle Filtering-Based Fault Detection in Non-linear Stochastic Systems[J]. International Journal of Systems Science, 2002, 33(4):259-265.
- [7] Lin D, Markis V. On-line parameter estimation for a failure-prone system subject to condition monitoring[J]. Journal of

Applied Probability, 2004, 41(1):211-220.

- [8] 葛哲学,杨拥民,胡 政,等.非高斯噪声下基于 U-粒子滤波器和似然比的非线性系统故障诊断[J].机械工程学报,2007,43(10):27-31.
- [9] 张 磊,李行善,于劲松,等.基于混合系统粒子滤波和二元估计的故障预测算法[J].航空学报,2009,30(7):1277-1283.
- [10] 莫以为,萧德云.基于进化粒子滤波器的混合系统故障诊断[J].控制与决策,2004,19(6):611-615.
- [11] 陈以超,洪汉玉,王 俊,等.一种鲁棒性的遥感图像地域分类新方法[J].计算机技术与发展,2007,17(8):136-138.
- [12] 武新乾,田 铮,李小斌.函数系数线性自回归模型的样条估计[J].数学研究与评论,2007,27(4):869-875.