

文章编号:1009-3087(2013)01-0169-06

基于 FNN-UKF 神经网络的氧化铝浓度动态预测模型

易 军¹,李太福^{1,2},侯 杰²,姚立忠³,田应甫⁴

(1. 重庆科技学院 电气与信息工程学院,重庆 401331;2. 重庆大学 自动化学院,重庆 400044;

3. 西安石油大学 电子工程学院,陕西 西安 710065;4. 重庆天泰铝业有限公司,重庆 401328)

摘 要:针对影响氧化铝浓度的因素较多,彼此相关性强,难以建立动态预测模型的问题,提出一种基于 FNN-UKF 神经网络的动态预测方法。首先考察各原始变量置零前后在特征空间主元投影上的相似度,判断其对氧化铝浓度的解释能力,由此进行原始变量选择;再将约简后的原始变量输入基于 UKF 算法的神经网络预测模型,通过更新状态估计值和方差矩阵提高模型的泛化能力。对取自某厂 160KA 大型预焙槽的 247 组样本数据进行检验;228 组样本的预测误差在 $\pm 1\%$ 之内,计算量减少 52.07%,表明该方法在保证预测精度的同时,有效降低了模型学习的计算量。

关键词:虚假最近邻法;核主成分分析法;预测;氧化铝浓度;神经网络

中图分类号:TP183;TF821

文献标志码:A

Dynamic Prediction Model Based on FNN-UKF Neural Networks for Alumina Concentration

YI Jun¹,LI Tai-fu^{1,2},HOU Jie²,YAO Li-zhong³,TIAN Ying-fu⁴

(1. College of Electronic and Info. Eng., Chongqing Univ. of Sci. and Technol., Chongqing 401331, China;

2. College of Automation, Chongqing Univ., Chongqing 400044, China;

3. College of Electronic Eng., Xi'an Shiyou Univ., Xi'an 710065, Shan'xi, China; 4. Chongqing Tiantai Aluminum Co. Ltd., Chongqing 401328, China)

Abstract:Based on false nearest neighbors and unscented kalman filter (FNN-UKF), a dynamic prediction method for alumina concentration was proposed. In the new KPCA feature subspace, it was inspired by FNN that interpretation of alumina concentration would be estimated by calculating the variables mapping distance in the KPCA space to select secondary variables. Selected variables were introduced into BP neural networks as input vector. UKF algorithm, in which estimated value and variance matrix of state were updated to improve the generalization capability of the networks, was used to train weight values and threshold values. By using 247 samples of 160KA operating aluminum cell from a factory, experimental results demonstrated that the forecast error of 228 samples was $\pm 1\%$, the computation was decreased to 52.07%. The method in which the computation time was reduced effectively can surely accuracy of parameter estimation.

Key words:false nearest neighbors;kernel principal components analysis;prediction;alumina concentration;neural networks

在铝电解过程中,维持稳定的氧化铝浓度是获得较高电流效率的重要前提。由于电解质的高温强腐蚀性,无法直接测量氧化铝浓度^[1];同时受加料

速度、扩散速度、槽温以及其他槽况因素影响,浓度变化表现出非线性、时变、时滞等特征,建立精确的动态预测模型较为困难。因此,对氧化铝浓度的预测一直是相关领域研究的热点^[2]。李劼等^[3]提出 1 种综合应用在线智能辨识、多控制模式与自决策机制以及变论域技术的新型模糊专家控制方法,实现对氧化铝浓度的预测和实时控制。李界家等^[4]提出基于小波神经网络的预测模型,通过跟踪槽电阻参数调整下料量使氧化铝浓度控制在理想范围。张红亮等^[5]将 GM(1,1)模型引入到铝电解氧化铝浓度估算中,对基于 Kalman 滤波的氧化铝浓度自适应

收稿日期:2012-07-30

基金项目:国家自然科学基金资助项目(51075418;61174015);
重庆市教委科学技术研究项目(KJ121410);重庆市
自然科学基金资助项目(cstc2012jjB40006;
cstc2012jjA1475);重庆科技学院校内科研基金资助
项目(CK2011B04)

作者简介:易 军(1973—),男,副教授,博士。研究方向:复杂
系统建模。E-mail:laoyifreq@163.com

估算模型进行修正。林景栋等^[6]提出基于线性回归预测与正交变换预测法,提高氧化铝浓度判定的准确度。以上方法都只选取了与氧化铝浓度直接相关的槽电阻、下料间隔等作为参考量,没有考察各种槽参数对氧化铝浓度预测的影响以及参数之间的强相关性问题;同时建立的预测模型多为静态,无法根据铝电解槽内部状态和环境条件进行动态调整,影响了实际应用。近年来,利用核主成分分析法(kernel principal components analysis, KPCA)对非线性数据的降维作用,结合其他建模方法被提出^[7-8],但获得的主成分仍然是原始变量在特征空间的线性组合,既无明确的物理含义,又无法对原始特征进行约简达到减少传感器从而降低成本的目的。

针对以上问题,提出一种基于 FNN-UKF 神经网络的氧化铝浓度动态预测模型。首先利用虚假邻点法(false nearest neighbors, FNN)考察各原始特征置零前后在特征空间内主成分投影上的相似度,选取对氧化铝浓度紧密相关的原始特征变量作为神经网络预测模型的输入向量,再利用 UKF 对网络模型的权值和阈值进行训练,提高泛化能力和预测精度。

1 基于特征空间的虚假最近邻点判别

1.1 重构相空间原理

按照相空间重构理论^[9],混沌时间序列是高维相空间混沌运动轨迹在 1 维空间上的投影。在高维空间并不相邻的两点在投影过程中,运动轨迹会被扭曲,其投影在 1 维空间轴上有可能相邻。重构相空间是从低维空间向高维空间展开,混沌运动的轨迹随着嵌入维数 m 的增大而逐步打开的过程,原本在 1 维空间轴上的虚假邻点也逐步被剔除,这种思想被称为虚假最近邻法^[10-11]。

假设在 d 维相空间中,每一个相点向量为 $\mathbf{P}(i) = (x(i), x(i+\tau), \dots, x(i+(d-1)\tau))$ 都有一个某距离内的最近邻点 $\mathbf{P}^{NN}(i)$, 其距离为:

$$R_d(i) = \|\mathbf{P}(i) - \mathbf{P}^{NN}(i)\| \quad (1)$$

当相空间的维数从 d 维增加到 $d+1$ 维时,这两个相点的距离就会发生变化,两者的距离称为 $R_{d+1}(i)$ 且有:

$$R_{d+1}^2(i) = R_d^2(i) + \|\mathbf{x}(i+\tau d) - \mathbf{x}^{NN}(i+\tau d)\|^2 \quad (2)$$

如果 $R_{d+1}(i)$ 比 $R_d(i)$ 大很多,可以认为这是由于高维混沌吸引 2 个不相邻的点投影到低维轨道上时变成相邻的两点造成的,因此这样的邻点是虚假的。

1.2 KPCA 法的局限性

KPCA 是一种基于核方法的主成分分析方法^[12-14], 首先要在要输入样本空间利用非线性映射 Φ 和 Ψ 将原始随机向量空间 $\bar{\mathbf{x}}_i$ 和 $\bar{\mathbf{y}}_i$ 映射到高维空间 $\mathbf{F}_x$ 和 $\mathbf{F}_y$, 使得数据在特征空间中成为线性数据, 再在特征空间中利用 PCA 法对变换后的数据提取主成分, 这对应于原始特征空间的非线性运算。因此, KPCA 实现了样本空间的非线性特征提取。

然而特征空间里的主成分仍然是原始变量在特征空间的线性组合, 只是达到了降维的目的, 并没有剔除原始变量, 无法通过减少传感器数量和种类达到降低生产成本的目的。

1.3 原始变量选择算法

受相空间重构的启发, 将原变量组 $\mathbf{X} = (x_1, x_2, \dots, x_i, \dots, x_n)$ 中的任意一变量 x_i 置为零, 得到一个新的变量组 $\mathbf{X}(i) = (x_1, x_2, \dots, x_{i-1}, 0, x_{i+1}, \dots, x_n)$, 并将其投影在特征空间, 按照式(1)、(2) 计算转换后两个点之间的距离 $d(i)$, 显然特征 x_i 是否被选择, 取决于 $R_d(i)$ 与 $R_{d+1}(i)$ 之间的变化是否显著, 即 $d(i)$ 的大小。把所得到的 n 个 $d(i)$ 按从小到大的顺序排列, 较小距离对应的原始变量即没什么贡献, 可以考虑删除。算法步骤:

1) 利用 KPCA 法将原始输入空间中的样本数据 $\mathbf{X}$ 通过核函数 $\Phi(\cdot)$ 映射到高维特征空间, 并求出前 m 个主元(中间过程略):

$$\mathbf{B}_k = \mathbf{u}_k \cdot \Phi(\mathbf{X}) = \sum_{i=1}^l \alpha_i^k (\Phi(x_i) \Phi(x_j)) = \sum_{i=1}^l \alpha_i^k \mathbf{K}(x_i, x_j) \quad (3)$$

其中, $k = 1, 2, \dots, m$, $\mathbf{u}_k$ 为特征空间中主元变换轴, $\mathbf{K}$ 为核矩阵。

2) 将原始输入空间 $\mathbf{X}$ 中的某一变量 x_i 置 0, 即 $\mathbf{X}(i) = (x_1, x_2, \dots, x_{i-1}, 0, x_{i+1}, \dots, x_n)$, 按照步骤 1) 求出前 m 个主元 $\mathbf{B}_k(i)$;

3) 考察第 k 主元中某一变量 x_i 置 0 前后的相似性测度 $\cos_k(i)$,

$$\cos_k(i) = \frac{\mathbf{B}_k \cdot \mathbf{B}_k(i)^T}{\|\mathbf{B}_k\| \cdot \|\mathbf{B}_k(i)\|} \quad (4)$$

若 $\cos_k(i)$ 值接近于 1, 则说明 $\mathbf{B}_k$ 与 $\mathbf{B}_k(i)$ 的相似度大, 变量 x_i 对样本影响小, 解释能力小; 若 $\cos_k(i)$ 较大地偏离 1, 说明 $\mathbf{B}_k$ 与 $\mathbf{B}_k(i)$ 相似性小, 变量 x_i 对样本解释能力较大, 此时 $\mathbf{B}_k(i)$ 即是 $\mathbf{B}_k$ 的虚

假最近邻点。

然后求出某一变量 x_i 置 0 前后在前 m 个主元投影总的相似度:

$$d(i) = 1 - \frac{1}{m} \sum_{k=1}^m \cos_k(i) \quad (5)$$

4) 依次考察原始特征 $x_1, x_2, \dots, x_n$ 的主元相似度, 通过比较相应 $d(i)$ 变化情况 (其中, $i = 1, 2, \dots, n$), 确定输入特征对原始数据结构的影响大小, 按变化由大到小的顺序排列, 较小距离对应的原始变量没什么贡献, 可以考虑剔除。原变量组为 $\mathbf{X} = (x_1, x_2, \dots, x_n)$, 剔除变量后的新自变量组为 $\mathbf{X} = (x_1, x_2, \dots, x_k)$, 维数减少了 $n - k$ 。

该算法不但达到降维的效果, 同时通过剔除原始变量, 对指导实际生产具有真正的物理意义。

2 基于 UKF 神经网络的氧化铝动态预测模型

将进行特征选择后的样本作为神经网络模型的输入向量, 利用 UKF 算法将神经网络的权值和阈值当成系统状态变量, 系统观测变量为网络的输出, 则神经网络的预测模型就转化成状态参数的估计, 由于输入的变量不断随环境噪声、工况和设备状态而动态变化, 由此建立的氧化铝浓度演化模型具有动态时变性。

2.1 UKF 算法

UT 变换是用来计算经过非线性变换后的随机变量统计特性的方法。UT 变换首先根据先验分布特性确定性地给出一组采样点 (Sigma 点), 再将每一个 Sigma 点代入非线性变换, 得到一组变换点, 通过真实非线性系统的传播后, 其捕获的均值和方差能精确到非线性系统的 Taylor 展开的二次项^[15-16]。

2.2 动态预测模型

设有一 N 层 BP 网络, 每层神经元数为 S_k ($k = 1, 2, \dots, N$), 记输入层为第 1 层, 输出层为第 N 层。第 k 层神经元的连接权值 w_{ij}^k ($i = 1, 2, \dots, S_{k-1}; j = 1, 2, \dots, S_k$)。为使上述问题中连接权值 w_{ij}^k 的计算转化为滤波递推估计形式, 将网络中的所有权值和阈值组成状态向量:

$$\mathbf{W} = [w_{11}^1 \quad \dots \quad w_{s_1 s_2}^2 b_{11}^1 w_{11}^{N-1} \quad \dots \quad w_{s_1 s_2}^{N-1} b_1^1 \quad \dots \quad b_{s_{N-1}}^{N-1}]^T,$$

则系统的状态方程和观测方程可表示为:

$$\begin{cases} \mathbf{W}_k = \mathbf{W}_{k-1}, \\ \mathbf{Y}_{ek} = h(\mathbf{W}_k, \mathbf{X}_k) + \mathbf{V}_k \end{cases} \quad (6)$$

其中,

$$h(\mathbf{W}_k, \mathbf{X}_k) = F^N(\mathbf{W}_k^N, F^{N-1}(\mathbf{W}_k^{N-1} \dots F^2(\mathbf{W}_k^2, \mathbf{X}_k)))。$$

式中: F^N 为神经网络第 N 层传递函数, 一般选取 Sigmoid 函数; $\mathbf{Y}_{ek}$ 为期望输出; $\mathbf{X}_k$ 为输入矢量; $\mathbf{Y}_{rk}$ 为实际输出; $\mathbf{V}_k$ 为观测噪声, 它是随机白噪声, 在 UKF 神经网络中设为 0。由无迹卡尔曼滤波基本公式得到无迹卡尔曼神经网络算法如下:

1) 初始化 $k = 1$: 构造估计值 $\hat{x}_0$ 和估计方差 P_0 ;

2) 计算采样点的状态向量:

$$\mathbf{X}_{k-1} = \lfloor \hat{x}_{k-1} \quad \hat{x}_{k-1} \pm \sqrt{(n + \lambda)P_{k-1}} \rfloor \quad (7)$$

3) 分别进行状态和观测状态一步预测:

$$\mathbf{X}_{k/k-1} = \mathbf{X}_{k-1}; \hat{x}_k^- = \sum_{i=0}^{2n} w_i^{(m)} \chi_{i,k/k-1} \quad (8)$$

$$P_k^- = \sum_{i=0}^{2n} w_i^{(c)} [\chi_{i,k/k-1} - \hat{x}_k^-] [\chi_{i,k/k-1} - \hat{x}_k^-]^T \quad (9)$$

$$\mathbf{y}_{k/k-1} = h(\mathbf{X}_{k/k-1}); \hat{y}_k = \sum_{i=0}^{2n} w_i^{(m)} y_{i,k/k-1}$$

$$P_y = \sum_{i=0}^{2n} w_i^{(c)} [y_{i,k/k-1} - \hat{y}_k] [y_{i,k/k-1} - \hat{y}_k]^T \quad (10)$$

状态变量与测量变量的协方差:

$$P_{xy} = \sum_{i=0}^{2n} \hat{w}_i^{(c)} [\chi_{i,k/k-1} - \hat{x}_k^-] [y_{i,k/k-1} - \hat{y}_k]^T \quad (11)$$

4) 滤波增益: $\mathbf{K} = \mathbf{P}_{xy} \mathbf{P}_y^{-1}$ 。

更新状态估计值: $\hat{x}_k = \hat{x}_k^- + \mathbf{K}(y_k - \hat{y}_k)$ 。

更新状态方差阵: $\mathbf{P}_k = \mathbf{P}_k^- - \mathbf{K} \mathbf{P}_y \mathbf{K}^T$ 。

5) $k = k + 1$, 转到步骤 2) 重复计算。

由算法可知, UKF 神经网络的学习过程即是权值和阈值的估计过程: 首先根据式 (6) 建立状态方程和观测方程, 采用 UKF 算法训练 k 时刻神经网络权值; 再利用训练好的权值计算出神经网络的输出, 建立新的观测方程; 依据该观测方程和系统方程更新状态估计值和方差, 进行 UKF 训练最终得到 $k + 1$ 时刻的权值和阈值。如此循环至达到滤波收敛条件为止。

3 应用分析

3.1 预测模型的输入变量选择

通过对铝电解槽异常槽况的影响因素分析, 并综合考虑现场采集数据的实际难度, 筛选出的输入特征变量包括: 系列电流 (x_1); 氟化盐用量 (x_2); 分子比 (x_3); 出铝量 (x_4); 铝水平 (x_5); 电解质水平 (x_6); 槽温 (x_7); NB 间隔 (x_8); 槽电压 (x_9)。以重庆某铝业有限公司 160KA 系列铝电解槽中的 223 号槽数据为样本, 获得共计 9 种原始数据 247 组样本

类型。

3.2 输入变量的累计解释能力和相关性分析

根据 KPCA 的算法,可以计算出提取后的主成分、与主成分对应的各特征值以及特征值的累积贡献率,表 1 表示通过计算得到的各个特征值,表 2 表示特征值的累积贡献率。采用高斯核,核参 500。

表 1 KPCA 的主成分对应的特征值

Tab. 1 Eigenvalue of principal components in KPCA

主成分	B_1	B_2	B_3	B_4	B_5	B_6	B_7	B_8	B_9
特征值 λ	2.924	2.248	1.296	0.552	0.374	0.046	0.026	0.018	0.015

表 2 各主成分的贡献率及累积贡献率

Tab. 2 Contribution rate and cumulative contribution rate of principal components

主成分	B_1	B_2	B_3	B_4	B_5	B_6	B_7	B_8	B_9
贡献率	0.387	0.298	0.172	0.073	0.049	0.006	0.003	0.002	0.002
累积贡献率	0.387	0.685	0.857	0.930	0.979	0.985	0.989	0.991	0.994

表 3 FNN 计算相似度

Tab. 3 Calculating the similarity by FNN

x_i	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9
d	0.051 2	$8.187\ 9 \times 10^{-8}$	0.011 6	$2.246\ 0 \times 10^{-5}$	0.108 9	$1.073\ 1 \times 10^{-4}$	0.001 5	$3.367\ 2 \times 10^{-4}$	0.042 3

根据虚假最近邻点法的定义可知,平均距离越大,则可说明剔除该变量对整个样本影响越大;反之,平均距离越小,则说明该变量对整个样本的影响较小,解释能力较弱,因而可剔除。由表 3 可知,系列电流 x_1 、分子比 x_3 、铝水平 x_5 、槽温 x_7 、槽电压 x_9 共 5 种变量贡献较大,将作为神经网络的输入变量得以保留,其他 4 种被剔除。需要指出的是:从铝电解工艺上看 NB 间隔对氧化铝浓度的影响是较大的,但是由于本例中 NB 间隔较固定,其贡献率占的比重相对较小,故仍然被剔除。

3.3 氧化铝动态预测模型及结果分析

选取 3 层 BP 神经网络构建预测模型,氧化铝浓度作为唯一输出向量,隐层神经元数目选取 9 个,由此构建的 UKF 状态向量维数为 1×64 ,传递函数采用 Sigmoid 函数,其他参数 $k = 0, \alpha = 0.06, \beta = 4$,输出层采用 purelin 函数。氧化铝浓度的预测结果如图 1 所示。

由图 2 可知,除了初始阶段由于网络欠训练导致精度不够外,其他输出结果与期望结果基本一致。为更好考察预测结果,分别给出相对误差和样本分布如图 3、4 所示。

由图 2、3 以及图 4 的样本分布可知,245 个样本的预测误差在 $\pm 4\%$ 之内,其中,228 个样本的预测误差在 $\pm 1\%$ 之内,仅有 2 个样本误差较大,说明模型精度较高。

表 4 比较了 BP 神经网络预测模型、基于 EKF

通过表 2 可以看出,KPCA 提取出的前 5 个主成分的累积贡献率可达到 97.934 9%,利用 KPCA 提取出的前 5 个主成分贡献率远大于后 4 个,故选择在由 B_1 、 B_2 、 B_3 、 B_4 、 B_5 这 5 个主成分构成的新的空间里进行虚假邻点的计算,经计算所得 d 值如表 3 所示。




图 1 氧化铝浓度预测结果

Fig. 1 Prediction result of alumina concentration




图 2 预测绝对误差

Fig. 2 Absolute error of prediction




图3 预测相对误差

Fig. 3 Relative error of prediction




图4 误差样本分布

Fig. 4 Distribution of error sample

神经网络的预测模型、基于 UKF 神经网络的预测模型以及本模型的平均绝对误差 (*MAE*)、平均相对误差 (*MRE*)、均方误差 (*MSE*)、误差平方和 (*SSE*)、训练时间等 5 项指标。

表4 算法性能比较

Tab. 4 Comparison of algorithm performances

预测模型	<i>MAE</i>	<i>MRE</i>	<i>MSE</i>	<i>SSE</i>	训练时间/s
P	1.398	1.562 9	3.562	325.87	38.92
EKF	0.649	0.038 2	1.349	63.852	53.87
UKF	0.052	0.005 32	0.043 6	4.230 1	32.42
FNN-UKF	0.043	0.003 21	0.001 7	0.410 8	15.54

由表 4 可知,利用 UKF 算法训练神经网络后,各项误差指标显示预测精度较高,但是由于网络输入向量维度为 9,UKF 的状态向量维度 1×155 ,导致训练时间长达 32.42 s,而通过特征子空间的 FNN 变量选择后,其计算量减少 52.07%,同时剔除相关性强的冗余信息,有利于提高预测精确度。

4 结 论

1) 氧化铝浓度的影响因素较多,彼此之间相关

性强,要建立较准确的预测模型,必须进行变量选择。利用特征空间虚假最近邻的判别方法,通过计算某特征变量选择前后的主成分投影距离,可以有效地剔除冗余信息,提高预测精度并降低模型复杂度。

2) 利用 UKF 算法对神经网络的权值和阈值进行训练,计算简单且精度高,通过状态估计值更新提高了预测模型的泛化能力,使其能够适应外部条件和内部状态的变化,适合用于氧化铝浓度的动态预测。

参考文献:

[1]田应甫.大型预焙铝电解槽生产实践[M].长沙:中南大学出版社,2003.

[2]刘业翔,李劼.现代铝电解[M].北京:冶金工业出版社,2008.

[3]Li Jie,Zhang Wengen,Ding Fengqi,et al. Fuzzy expert control method based on on-line intelligent identification and its application[J]. Journal of Central South University of Technology:Natural Science,2004(6):911-914. [李劼,张文根,丁凤其,等.基于在线智能辨识的模糊专家控制方法及其应用[J].中南大学学报:自然科学版,2004(6):911-914.]

[4]Li Jiejia,Wu Chengdong,Li Ying. Application research on neural network predictive control technology in Aluminum electrolysis process[J]. Instrument Technique and Sensor, 2011(8):91-93. [李界家,吴成东,李颖.铝电解过程神经网络预测控制技术应用研究[J].仪表技术与传感器,2011(8):91-93.]

[5]Zhang Hongliang,Li Jie,Zhang Wengen,et al. Application of gray GM(1,1) model to alumina concentration estimation in aluminum electrolysis[J]. Chinese Journal of Scientific Instrument,2008(4):883-887. [张红亮,李劼,张文根,等. GM(1,1)模型在铝电解氧化铝浓度估计中的应用研究[J].仪器仪表学报,2008(4):883-887.]

[6]Lin Jingdong,Li Ling,Zhang Peng. Research of predicting alumina concentration based on orthogonal transformation[J]. Journal of Wuhan Institute of Technology, 2010, 32(9):9-13. [林景栋,李岭,张鹏.基于正交变换的氧化铝浓度预测[J].武汉工程大学学报,2010,32(9):9-

13.]
- [7] Jiang Shaohua, Gui Weihua, Yang Chunhua, et al. Method based on kernel principal component analysis and support vector machine and its application[J]. Journal of Central South University: Science and Technology, 2009, 40(5): 1323 – 1328. [蒋少华, 桂卫华, 阳春华, 等. 基于核主元分析与支持向量机的监控诊断方法及其应用[J]. 中南大学学报: 自科版, 2009, 40(5): 1323 – 1328.]
- [8] Tang Chunxia, Yang Chunhua, Gui Weihua, et al. KPCA and LSSVM model-based slag basicity prediction for silicomanganese smelting process[J]. Chinese Journal of Scientific Instrument, 2010, 31(3): 689 – 693. [唐春霞, 阳春华, 桂卫华, 等. 基于 KPCA_LSSVM 的硅锰合金熔炼过程炉渣碱度预测研究[J]. 仪器仪表学报, 2010, 31(3): 689 – 693.]
- [9] Hachair X, Braive R, Lippi G L, et al. Identification of the stimulated-emission threshold in high- β nanoscale lasers through phase-space reconstruction[J]. Physical Review A, 2011, 83(5): 1 – 4.
- [10] Carl R, Manfred M. The false nearest neighbors algorithm: An overview[J]. Computers & Chemical Engineering, 1997, 21: 1149 – 1154.
- [11] Ismael M C, Enrique A A, Casillo M M A, et al. Parallel implementations of the false nearest neighbors method for distributed memory architectures[J]. Concurrency and Computation: Practice and Experience, 2011, 23(1): 1 – 16.
- [12] Xu Yong, Zhang D, Song Fengxi, et al. A method for speeding up feature extraction based on KPCA[J]. Neurocomputing, 2007, 70(4/5/6): 1056 – 1061.
- [13] Cao L J, Chua K S, Chong W K. A comparison of PCA, KPCA and ICA for dimensionality reduction in support vector machine[J]. Neurocomputing, 2003, 55: 321 – 336.
- [14] Pang Yanwei, Wang Lei, Yuan Yuan. Generalized KPCA by adaptive rules in feature space[J]. International Journal of Computer Mathematics, 2010, 87(5): 956 – 968.
- [15] Sun Yao, Zhang Qiang, Wan Lei. Small autonomous underwater vehicle navigation system based on adaptive UKF algorithm[J]. Acta Automatica Sinica, 2011, 37(3): 342 – 353. [孙尧, 张强, 万磊. 基于自适应 UKF 算法的小型水下机器人导航系统[J]. 自动化学报, 2011, 37(3): 342 – 353.]
- [16] Liu Yu, Chen Xin, Wang Yunfeng, et al. An adaptive target error registration based on neural networks and UKF[J]. Journal of Sichuan University: Engineering Science Edition, 2012, 44(3): 101 – 105. [刘宇, 陈昕, 王运锋, 等. 一种基于神经网络和 UKF 的自适应目标误差配准方法[J]. 四川大学学报: 工程科学版, 2012, 44(3): 101 – 105.]

(编辑 杨 蓓)