

基于自适应 MCMC 采样的新型 UPFNN 铝电解能耗模型

丁 伟¹, 姚立忠^{2,1}, 龙 伟¹, 李炎炎¹

(1. 四川大学机械工程学院, 成都 610065;
2. 重庆科技学院电气工程学院, 重庆 401331)

摘 要: 针对铝电解过程中噪声密集、分布类型未知且参数特征高维而导致建模精度不佳的问题, 提出一种基于自适应 MCMC 采样的新型无迹粒子滤波神经网络(AMCMC-UPFNN)建模方法. 该方法首先利用无迹变换(UT)中 κ 参数的平方项代替 UPFNN 算法中对应的常规项, 避免因维数过高而导致 UT 矩阵出现非正定情况, 保证 UPFNN 中 Sigma 点采样的合理性; 然后, 在传统 MCMC 方法基础上引入自适应采样策略来保持粒子的多样性, 使所建立概率密度分布更接近真实分布; 最后, 与相关建模方法开展铝电解工业应用验证实验. 结果表明, AMCMC-UPFNN 模型预测精度的相对误差百分比不超过 1%, 取得了比 PFNN、UPFNN 和 MCMC-UPFNN 更优的性能指标.

关键词: 马尔科夫链蒙特卡洛; 无迹粒子滤波; 铝电解; 神经网络; 能耗建模

中图分类号: N945.12 **文献标识码:** A **DOI:** 10.19907/j.0490-6756.2021.033004

The modeling based on AMCMC-UPFNN for aluminum electrolysis energy consumption

DING Wei¹, YAO Li-Zhong^{2,1}, LONG Wei¹, LI Yan-Yan¹

(1. School of Mechanical Engineering, Sichuan University, Chengdu 610065, China;
2. School of Electrical Engineering, Chongqing University of Science & Technology, Chongqing 401331, China)

Abstract: The accuracy of the energy consumption models for aluminum electrolysis is poor due to the intensive noise, unknown distribution types and high-dimensional parameter characteristics in the aluminum electrolysis process. In order to solve the problem, a novel modeling method based on Adaptive Markov Chain Monte Carlo Unscented Particle Filter Neural Network (AMCMC-UPFNN) is proposed. This method firstly used the square term of the κ parameter in the Unscented Transformation (UT) to replace the corresponding regular term in the UPFNN algorithm, avoiding the non-positive definite situation of the UT matrix due to high dimension, and ensuring the reasonableness of Sigma point sampling in UPFNN; then, an adaptive sampling strategy was introduced on the basis of the traditional MCMC method to maintain the diversity of particles and make the established probability density distribution closer to the true distribution. Finally, the verification experiment of aluminum electrolysis industrial application was carried out to compare the proposed method with related modeling methods. The results show that the relative error rate of the AMCMC-UPFNN model does not exceed 1%, and it has achieved

收稿日期: 2020-09-03

基金项目: 国家自然科学基金(51805059); 重庆市基础研究与前沿探索项目(cstc2018jcyjAX0350)

作者简介: 丁伟(1995-), 男, 安徽淮北人, 硕士研究生, 研究方向为复杂系统建模. E-mail: dingwei1995@stu.scu.edu.cn

通讯作者: 姚立忠. E-mail: yaolizhong225@163.com

better performance indicators than PFNN, UPFNN and MCMC-UPFNN.

Keywords: Markov chain Monte Carlo; Unscented particle filter; Aluminum electrolysis; Neural network; Energy consumption modeling

1 引言

电解铝产品已广泛应用于航天、交通、建筑、机械制造等重要领域,在世界工业发展过程中占有举足轻重的战略地位^[1]. 据统计结果分析,在消耗方面,2019 年我国电解铝消费量为 3 672 万吨,同比增长 2.4%^[2]. 然而,我国铝电解工业已进入到技术瓶颈期,其主要原因是铝电解能耗过高. 由于铝电解工艺制造系统具有波动性、动态时变以及不确定性等特征,故难以准确地建立相对动态平稳的铝电解能耗模型,从而导致部分企业无法根据此模型来对未来状况进行整体规划和技术优化. 因此,研究高精度铝电解能耗建模技术对工业生产提质增效具有重要意义.

铝电解系统存在一系列的物理化学反应,机理复杂不易量化. 因神经网络^[3]可处理系统机理未知的建模问题而备受关注. 文献[4]使用小波神经网络来研究分析铝电解槽过程中各状态阶段;文献[5]介绍了神经网络控制技术与预测技术结合来调整氧化铝浓度的控制策略. 然而,当传统神经网络建模完成时,其权值和阈值将保持不变. 当铝电解系统工艺参数因实时工况变化而改变时,基于先前数据所建立的静态神经网络模型将无法适应铝电解工艺条件动态优化的需求. 因此,为保证能耗模型对铝电解制造系统运行规律具有一定的渐进学习能力,可引进滤波技术来实时更新系统模型参数.

现如今大多数论文引入扩展卡尔曼滤波(Extended Kalman Filter, UKF)和无迹卡尔曼滤波(Unscented Kalman Filter, UKF)对神经网络的权值阈值进行动态调整. 相比于静态神经网络模型,EKFNN 与 UKFNN 所建立的模型能够随工艺条件的改变而实时变化,具有良好的渐进学习能力. 文献[6]采用改进无迹卡尔曼优化神经网络来提高建模精度;文献[7]将神经网络、扩展卡尔曼滤波器和递归最小二乘法结合进行参数估计;文献[8]提出一种基于自适应扩展卡尔曼滤波器的径向基函数神经网络;Yao 等^[9]提出一种基于强跟踪 UKF 的改进前馈神经网络算法,用于建立铝电解能耗模型;文献[10]将人工神经网络和 UKF 结合

对非线性系统进行状态估计.

根据上述文献分析可知,EKFNN 与 UKFNN 有效拓展了铝电解能耗建模技术,但上述技术往往限定了高斯、低维环境的假设条件,缺乏对高维非线性非高斯系统能耗建模技术的探讨,而实际上铝电解系统具有噪声密集、分布类型未知且参数高维等特征. 因无迹粒子滤波具有典型处理非线性非高斯问题的能力,故本文在无迹粒子滤波(Unscented Particle Filter, UPF)渐进更新神经网络权值阈值^[11]的构建框架下,为进一步使算法适应于高维数据,通过改善无迹变换(UT)中 κ 参数来优化采样过程. 同时,为避免该算法中粒子状态出现多样性损失,本文在传统马尔科夫链蒙特卡洛(MC-MC)方法^[12-13]基础上引入自适应采样策略来保持粒子的多样性,精调模型状态逼近真实运行系统的贴近程度.

综上所述,本文提出一种基于自适应马尔科夫链蒙特卡洛采样的新型无迹粒子滤波神经网络(Adaptive Markov Chain Monte Carlo Unscented Particle Filter Neural Network, AMCMC-UPFNN)算法,并用此来建立铝电解能耗模型. 该技术有望提高铝电解能耗建模精度不佳的难题,可作为铝电解未来能耗预测的有效方法. 最后,以重庆某铝厂电解车间工艺系统为例,采集 9 种主要决策变量数据进行铝电解能耗建模,验证了所研究的科学性与有效性.

2 基于自适应 MCMC 的新型无迹粒子滤波神经网络

2.1 滤波方程

在传统神经网络建模^[6]基础上,为动态描述滤波方法对神经网络权值阈值的更新过程,使用状态空间表示法建立滤波方程^[14-15],如式(1)所示.

$$\begin{cases} \omega_k = \omega_{k-1} + \theta_k \\ y_k = h(\omega_k, u_k) + v_k \end{cases} \quad (1)$$

其中, ω_k 表示 k 时刻状态变量(即神经网络权值阈值); u_k 表示 k 时刻某工业制造系统的输入变量; y_k 表示 k 时刻量测变量(即评价工业制造系统优劣的输出变量). 假设系统测量噪声 v_k 为 0 均值高斯噪声,方差为 R ;系统过程噪声为 0 均值高斯噪声,方

差为 Q . 第 k 时刻的网络权值依赖于 $k-1$ 时刻的网络权值以及系统随机过程噪声 θ_k , 而测量噪声主要来描述系统因传感器等装置导致的建模误差. 非线性测量函数 $h(\cdot)$ 使用一个多层感知器来近似, 其表达式如式(2)所示.

$$h_k(\omega, u) = \sum_{j=1}^9 \frac{\omega_{jk}^{**}}{1 + \exp\left[-\left(\sum_{i=1}^9 \omega_{ij}^* u_i + a_j\right)\right]} + b_k \quad (2)$$

式中, ω_{ij}^* 表示第 i 个输入层与第 j 个隐含层神经元间的连接权值; a_j 表示隐含层神经元的阈值; ω_{jk}^{**} 表示第 j 个隐含层与第 k 个输出层神经元间的连接权值; b_k 表示输出层神经元的阈值; u_i 为输入变量.

2.2 自适应 MCMC-UPFNN 算法描述

2.2.1 新型 UPFNN 算法描述 在工业系统过程建模中, 通常将环境扰动变量和内部状态变量简单地看成是相对稳定的. 但是, 在实际的工业过程中, 由于“人、机、料、法、环”等诸多不确定因素的存在, 使得由决策变量建立的静态神经网络模型难以适应真实工艺. 本文则以 UPFNN 为研究对象, 将神经网络的权值阈值作为 UPFNN 的状态变量, 将神经网络的输出作为 UPFNN 的量测变量, 具体 UPFNN 算法可参见文献[16].

UPFNN 的算法精度主要取决于无迹粒子滤波器, 然而在高维情况下会发生算法会发散现象, 从而导致算法精度显著下降. 为解决该问题, 本文改进了无迹变换 (Unscented Transformation, UT), 将常规项 κ 由平方项 κ^2 代替, 改进后的无迹变换能够有效地避免数据高维而导致 UT 矩阵出现负定情况, 进而保证 UT 采样的正确性. 其中, UPFNN 的 UT 采样过程, 如式(3)所示.

$$\chi_{k|k-1}^{(r)} = [\bar{\omega}_{k-1}^{(a)}, \bar{\omega}_{k-1}^{(a)} \pm \sqrt{(N+\lambda)P_{k-1}^{(a)}}] \quad (3)$$

式中, $\bar{\omega}_{k-1}^{(a)}$ 表示原采样点; $\chi_{k|k-1}^{(r)}$ 表示通过对称分布采样所得到的采样点; N 表示粒子数; $P_{k-1}^{(a)}$ 表示采样点的协方差矩阵.

$$\lambda = \alpha^2 (N + \kappa^2) - N \quad (4)$$

其中, λ 为缩放比例系数, 改进后的 λ 表达式如式(4)所示; κ^2 的取值决定采样点与均值之间的距离; α 的大小决定了选取的样本点围绕均值 $\bar{\omega}$ 的分布情况, 它越小则可以更大程度的降低高阶效应.

从改进后的 UT 表达式可以看出, 新型 UPFNN 算法通过调整 κ 参数, 确保在高维环境下 UT 矩阵的非负定性和算法的稳定性, 并通过 UT

得到的采样点及其相应权重建立的概率密度分布更加接近制造系统真实状态的概率密度分布.

2.2.2 自适应 MCMC 方法描述 无迹粒子滤波本质上属于粒子滤波理论^[17-18] 的范畴, 随着时间更新 UPFNN 算法中粒子种类会逐渐减少, 从而引起粒子多样性损失问题. 而 MCMC 方法是在贝叶斯理论框架下提出, 通过计算机进行模拟满足 Markov 序列的 Monte Carlo 方法, 实现抽样分布随模拟的进行而改变的动态模拟. 因此, MCMC 在粒子重采样后能使粒子保持多样性而不影响近似有效性.

MCMC 理论中最核心部分是采样粒子时的接受概率^[19], 但粒子多样性会随着更新迭代而逐渐减少, 故要求在保证粒子多样性的前提下, 尽可能保持原有粒子的真实状态, 从而使所建立的概率密度分布更接近真实分布. 对此, 本文提出了如式(5)的表达式, 该表达式能够根据粒子迭代次数来调整接受概率, 更新前期粒子种类足够多, 此时接受概率可以小一些; 随着更新迭代, 后期接受概率要大一些, 使粒子的种类增加, 以防止粒子多样性损失.

$$\alpha(x_k^{(i)}, x_k^{*(i)}) = \begin{cases} \min\left(1, \frac{|p(z_k | x_k^{*(i)}) - p(z_k | x_k^{(i)})|}{p(z_k | x_k^{(i)})}\right), & t < \frac{T}{2} \\ \min\left(1, \frac{p(z_k | x_k^{*(i)})}{p(z_k | x_k^{(i)})}\right), & t \geq \frac{T}{2} \end{cases} \quad (5)$$

其中, $x_k^{(i)}$ 表示状态变量 (粒子); z_k 表示量测变量; $p(\cdot)$ 表示概率分布; $x_k^{*(i)}$ 表示通过 MCMC 采样得到的新粒子; 上标表示粒子序列; 下标表示时间序列; t 表示当前粒子迭代次数; T 表示粒子总迭代次数.

2.2.3 自适应 MCMC-UPFNN 算法设计及分析 基于上述新型 UPF 算法、自适应 MCMC 理论和神经网络, 本文提出一种基于自适应 MCMC 采样的新型无迹粒子滤波神经网络即 AMCMC-UPFNN 算法.

基于式(1)的滤波方程, AMCMC-UPFNN 流程如下.

(1) 初始化估计值. 从神经网络权值阈值所建立的先验分布中抽取 N 个粒子 $\omega_0^i \sim p(\omega_0)$, $i=1, 2, \dots, N$.

(2) 时间更新. 根据式(3)进行 UT 采样, 通过得到的采样点及其相应权重计算统计量 y .

$$\bar{\omega}_{k|k-1}^{(r)} = \sum_{j=1}^{2N} w_j^m \chi_{j,k|k-1}^{(r)} \quad (6)$$

$$P_{k|k-1}^i = \sum_{j=0}^{2N} \omega_j^f (\chi_{j,k|k-1}^{(x)} - \bar{\omega}_{k|k-1}^{i(x)}) \times$$
$$(\chi_{j,k|k-1}^{(x)} - \bar{\omega}_{k|k-1}^{i(x)})^T \tag{7}$$
$$y_{j,k|k-1}^i = h(\chi_{j,k|k-1}^{(x)}) \tag{8}$$

其中, $\lambda = \alpha^2 (N + \kappa^2) - N$; ω_j^f 为第 j 个采样点均值所对应的权值; ω_j^f 为第 j 个采样点方差所对应的权值.

(3) 权值更新. 统计量 y 的均值 $\bar{\omega}_k^i$ 和方差 P_k^i 计算过程如下.

$$\bar{y}_{k|k-1}^i = \sum_{j=0}^{2N} \omega_j^m y_{j,k|k-1}^i \tag{8}$$
$$P_{\bar{y}_{k|k-1}^i} = \sum_{j=0}^{2N} \omega_j^f (y_{j,k|k-1}^i - \bar{y}_{k|k-1}^i) \times$$
$$(y_{j,k|k-1}^i - \bar{y}_{k|k-1}^i)^T \tag{9}$$
$$P_{\omega_{k|k-1}^i} = \sum_{j=0}^{2N} \omega_j^f (\chi_{j,k|k-1}^i - \bar{\omega}_{k|k-1}^i) \times$$
$$(y_{j,k|k-1}^i - \bar{y}_{k|k-1}^i)^T \tag{10}$$
$$K_k = P_{\omega_{k|k-1}^i} P_{\bar{y}_{k|k-1}^i}^{-1} \tag{11}$$
$$\bar{\omega}_k^i = \bar{\omega}_{k|k-1}^i + K_k (y_k - \bar{y}_{k|k-1}^i) \tag{12}$$
$$P_k^i = P_{k|k-1}^i - K_k P_{\bar{y}_{k|k-1}^i} K_k^T \tag{13}$$

(4) 重要性重采样. 从 $q(\omega_k^i | \omega_{0:k-1}^i, y_{1:k}) = N(\bar{\omega}_k^i, \hat{P}_k^i)$ 中抽取粒子, 计算权重并归一化:

$$\omega_k^i = \omega_{k-1}^i \frac{p(y_k | \bar{\omega}_k^i) p(\bar{\omega}_k^i | \omega_{k-1}^i)}{q(\bar{\omega}_k^i | \omega_{0:k-1}^i, y_{1:k})} \tag{14}$$
$$\tilde{\omega}_k^i = \omega_k^i / \sum_{j=1}^N \omega_k^j \tag{15}$$

若 $N_{\text{eff}} \leq N_{\text{th}}$ (N_{eff} 为有效粒子数, N_{th} 为设定的阈值, 一般取为 $N/3$) 则说明粒子的权值已经退化严重, 需要进行重要性重采样; 否则直接进入下一步骤.

(5) MCMC 过程. 根据式(5)的接受概率来产生新的粒子:

(a) 若接受, 则

$$\bar{\omega}_k^{(i)} = \omega_k^{*(i)} \tag{16}$$

(b) 若否则拒绝, 则

$$\bar{\omega}_k^{(i)} = \omega_k^{(i)} \tag{17}$$

(6) 结果输出.

$$\begin{cases} \hat{\omega}_k = \sum_{i=1}^N \tilde{\omega}_k^{(i)} \bar{\omega}_k^{(i)} \\ P_k = \sum_{i=1}^N \tilde{\omega}_k^{(i)} (\bar{\omega}_k^{(i)} - \hat{\omega}_k) (\bar{\omega}_k^{(i)} - \hat{\omega}_k)^T \end{cases} \tag{18}$$

3 铝电解能耗建模应用实验

3.1 实验对象

本文将重庆某电解铝制造车间异型阴极和穿孔阳极联合使用的新型铝电解装备作为实验对

象^[12], 如图 1 所示. 其中, f_1 表示吨铝直流能耗, 原则上希望其数值越小越好.




图 1 新型铝电解装备核心构件联用
Fig. 1 Combination of core components of new aluminum electrolysis equipment

根据专家的经验, 以及我们对电解铝制造系统的工艺参数的分析, 得出影响吨铝直流电耗的系列参数有如下过程工艺变量: 系列电流、分子比、铝水平、电解质水平、槽温度、出铝量、氟化盐日用量、下料间隔和槽压. 基于工厂计算机测控系统对电解槽进行日报数据采样得到上述工艺数据样本 773 组, 如表 1 所示. 利用这些实测样本和本文所开发的算法开展铝电解制造系统单位直流能耗的建模分析与研究.

表 1 电解槽数据样本
Tab. 1 Electrolytic cell data sample

参数	样本				
	1	2	3		773
系列电流/A	1 679	1 679	1 679		1 752
工作电压/mV	3 712	3 723	3 718		3 617
NB 次数	646	707	671		781
分子比	2. 31	2. 31	2. 31		2. 72
出铝量/kg	1 260	1 240	1 260		1 340
铝水平/cm	21. 5	21. 5	22		16
电解质水平/cm	17	17	17		8
槽温/℃	952	942	947		948
氟化盐日用量/kg	29	23. 4	21. 6		19. 8
吨铝直流电耗/(kW · h/t-Al)	11 852	12 130	11 889		11 702

3.2 基于 AMCMC-UPFNN 的建模及结果分析
为验证 AMCMC-UPFNN 算法的有效性和优越性, 本文在相同的数据样本及仿真平台 (MATLABR2014b) 条件下, 对比预测误差来衡量算法性能. 所有实验均将表 1 中 773 组铝电解数据分成训练集样本 700 组和检验集样本 73 组, 其中采用 9-9-1 的神经网络结构, 输入为 9 种决策参数, 输出为单位能耗, 隐含层传递函数为 Sigmoid 函数, 输出层传递函数为 Purelin 函数.




图 2 能耗预测输出与期望输出对比图

Fig. 2 Comparison of energy consumption prediction output and expected output

依据 PFNN、UPFNN、MCMC-UPFNN 和 AMCMC-UPFNN 建立铝电解工艺能耗模型,如图 2 所示. 为了清楚地分析模型优劣,4 种模型预测能耗相对误差对比如图 3. 从曲线的拟合效果可看出,AMCMC-UPFNN 拟合效果都远远优于其他模型. 整体来看,根据调整后的无迹变换所建立的模型性能均优于其他模型,凸显了其优越性,并且自适应 MCMC 对于算法的优化是可行的.

从方法上而言,调整后的 UT 使算法可适用于高维数据的场合,提高了算法的鲁棒性;通过引入自适应 MCMC 克服了算法中粒子多样性损失问题,提高了模型的精度. 从图 3 可看出,AMCMC-UPFNN 相对误差百分比不超过 1%,取得了比 PFNN、UPFNN 和 MCMC-UPFNN 更优的性能指标. 各模型建立能耗模型的指标数据对比见表 2.




图 3 模型能耗相对误差对比图

Fig. 3 Comparison of relative error of model energy consumption

表 2 不同模型相关性指标比较

Tab. 2 Comparison of relevant performance indicators of different models

模型类别	检验集绝对误差指标统计					
	Max	Min	Average	SSE (10 ⁵)	MSE (10 ³)	RMSE
PFNN	831.34	6.31	422.72	174.82	239.64	488.83
UPFNN	598.56	1.99	288.16	81.74	112.37	334.48
MCMC-UPFNN	198.09	0.66	98.06	9.36	12.88	113.22
AMCMC-UPFNN	99.72	4.10	49.93	2.53	3.47	58.92

从表 2 可知,就模型精度而言,很明显 AMCMC-UPFNN 的各项绝对误差指标都低于 PFNN、

UPFNN 和 MCMC-UPFNN. 特别是, AMCMC-UPFNN 模型的 SSE、MSE 和 RMSE 明显低于其他 3 种方法, 进而验证了 AMCMC-UPFNN 方法的有效性.

为了避免随机化初始值对模型评估的偶然影响, 本文基于各模型分别对能耗预测进行 20 次独立重复实验, 然后统计实验结果的相关性能指标, 并通过箱线图的形式展示了 AMCMC-UPFNN 能耗模型良好的稳定性, 如图 4 所示.




图 4 不同模型多次检验相关性能指标箱线图
Fig. 4 Box plot of related performance indicators for multiple tests of different models

4 结 论

本文提出了一种基于自适应 MCMC 采样的新型无迹粒子滤波神经网络 (AMCMC-UPFNN) 算法, 以无迹粒子滤波神经网络为研究对象, 利用无迹变换 (UT) 中 κ 参数的平方项代替 UPFNN 算法中对应的常规项; 然后, 引入自适应 MCMC 来解决 UPFNN 中粒子多样性损失问题; 最后本文系统性地呈现了 AMCMC-UPFNN 算法框架并构建了铝电解能耗模型. 通过对 PFNN、PFNN、MCMC-UPFNN 和 AMCMC-UPFNN 建立的铝电解能耗模型进行对比实验验证. 结果证实了利用 AMCMC-UPFNN 算法所建模型精度高和自适应能力强. 因此, 本研究为利用滤波神经网络进行建模提供了新的思路和方法. 在未来研究过程中, 将进一步探索滤波理论与深度神经网络学习算法的融合策略来进一步挖掘铝电解制造系统的隐藏运行规律.

参考文献:

[1] 桂卫华, 岳伟超, 谢永芳, 等. 铝电解生产智能优化制造研究综述[J]. 自动化学报, 2018, 44: 1957.

[2] 李泉. 2020 年中国电解铝行业竞争格局与发展趋势分析, 产量增速创历史新低[N]. 华经情报网, 2020-03-23(1).

[3] 龙彬, 胡思才, 郭峻铭, 等. 基于 BP 神经网络的网络小说排行预测[J]. 四川大学学报: 自然科学版, 2019, 56: 50.

[4] Johnson A, Li C. Wavelet packet time series analysis of aluminum electrolytic cells[J]. Proc SPIE, 2001, 4391: 228.

[5] 曾水平, 倪亚超. 广义动态模糊神经网络在铝电解预测中的研究与仿真[J]. 冶金自动化, 2014, 38: 21.

[6] 李太福, 侯杰, 姚立忠, 等. 基于改进 UKFNN 和 NSGA-II 的工业过程决策参数稳健优化[J]. 计算机应用研究, 2015, 32: 2716.

[7] Acosta M, Kanarachos S. Tire lateral force estimation and grip potential identification using Neural Networks, Extended Kalman filter, and recursive least squares [J]. Neural Comput Appl, 2018, 30: 3445.

[8] Pesce V, Silvestrini S, Lavagna M. Radial basis function neural network aided adaptive extended Kalman filter for spacecraft relative navigation[J]. Aerosp Sci Technol, 2020, 96: 105527.

[9] Yao L Z, Li T F, Li Y Y, et al. An improved feed-

forward neural network based on UKF and strong tracking filtering to establish energy consumption model for aluminum electrolysis process [J]. *Neural Comput Appl*, 2019, 31: 4271.

[10] Goleijani S, Ameli M T. An agent-based approach to power system dynamic state estimation through dual unscented Kalman filter and artificial neural network [J]. *Soft Computi*, 2019, 23: 12585.

[11] 李太福, 姚立忠, 易军, 等. 强跟踪平方根 UKFNN 的铝电解槽工耗动态演化模型[J]. *自动化学报*, 2014, 40: 522.

[12] 赵拥军, 赵勇胜, 赵闯. 基于马尔科夫链蒙特卡洛抽样的最大似然时差-频差联合估计算法[J]. *电子与信息学报*, 2016, 38: 2745.

[13] 屈志勇, 陈亭, 铁强, 等. 马尔科夫链蒙特卡洛算法并行化及其应用[J]. *计算机工程与设计*, 2016, 37: 1811.

[14] 汪成亮, 庞栩, 陆志坚. 基于神经网络的铝电解混合控制模型研究[J]. *计算机应用研究*, 2010, 27: 142.

[15] 李太福, 侯杰, 姚立忠, 等. Gamma Test 噪声估计的 Kalman 神经网络在动态工业过程建模中的应用[J]. *机械工程学报*, 2014, 50: 29.

[16] 王坎, 辜小花, 高论, 等. 基于 UPFNN 的油田机采工艺动态演化建模[J]. *现代电子技术*, 2017, 40: 109.

[17] 赵康, 王正勇, 何小海, 等. 基于改进粒子滤波的视觉目标跟踪[J]. *四川大学学报: 自然科学版*, 2019, 56: 875.

[18] 林晓梦, 高勇. 一种改进重采样的粒子滤波盲分离算法[J]. *重庆邮电大学学报: 自然科学版*, 2019, 31: 502.

[19] 杨奕飞, 鲍威尔. MCMC 粒子滤波的动力定位状态估计方法[J]. *控制工程*, 2019, 26: 2036.

引用本文格式:

中 文: 丁伟, 姚立忠, 龙伟, 等. 基于自适应 MCMC 采样的新型 UPFNN 铝电解能耗模型[J]. *四川大学学报: 自然科学版*, 2021, 58: 033004.

英 文: Ding W, Yao L Z, Long W, *et al.* The modeling based on AMCMC-UPFNN for aluminum electrolysis energy consumption [J]. *J Sichuan Univ: Nat Sci Ed*, 2021, 58: 033004.