

8-13-2020

Adaptive Dynamic Programming in Raw Meal Fineness Control of Vertical Mill Grinding Process Based on Extreme Learning Machine

Xiaofeng Lin

Guangxi University, Nanning 530004, China;

Weikai Kong

Guangxi University, Nanning 530004, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Adaptive Dynamic Programming in Raw Meal Fineness Control of Vertical Mill Grinding Process Based on Extreme Learning Machine

Abstract

Abstract: The grinding process of vertical mill raw meal in cement industry features nonlinear, strong coupling and long time-delay, which is difficult to model precisely and implement stable control for raw meal fineness. Against the problem, a production index prediction model of vertical mill raw meal grinding process was established using Extreme Learning Machine (ELM). *Adaptive dynamic programming (ADP) was used to control the raw meal fineness, whose action and critic networks were implemented by online sequential extreme learning machine.* In the meaning of simulation, the results show that the proposed method is valid and helpful to reduce the energy consumption.

Keywords

vertical mill, raw meal, Adaptive Dynamic Programming (ADP), Extreme Learning Machine (ELM)

Recommended Citation

Lin Xiaofeng, Kong Weikai. Adaptive Dynamic Programming in Raw Meal Fineness Control of Vertical Mill Grinding Process Based on Extreme Learning Machine[J]. Journal of System Simulation, 2016, 28(11): 2764-2770.

基于 ELM 的水泥立磨生料细度 ADP 控制

林小峰, 孔伟凯

(广西大学, 广西 南宁 530004)

摘要: 水泥生产中的立磨粉磨过程具有非线性、强耦合、大滞后等特点, 对其进行精确的建模和实现生料细度的控制比较困难。提出一种基于极限学习机(ELM, extreme learning machine)的自适应动态规划(ADP, adaptive dynamic programming)优化控制算法。采用极限学习机建立立磨生料粉磨过程的生料细度预测模型, 将其作为 ADP 算法中的模型网络, 并以在线序列极限学习机实现 ADP 的执行网络和评价网络。结果表明: 在仿真意义上, 所提算法能够对生料细度进行有效地控制, 对立磨稳定生产, 降低该生产过程的能耗具有一定理论指导意义。

关键词: 水泥立磨; 生料; 自适应动态规划; 极限学习机

中图分类号: TP183 文献标识码: A 文章编号: 1004-731X (2016) 11-2764-07

DOI: 10.16182/j.issn1004731x.joss.201611017

Adaptive Dynamic Programming in Raw Meal Fineness Control of Vertical Mill Grinding Process Based on Extreme Learning Machine

Lin Xiaofeng, Kong Weikai

(Guangxi University, Nanning 530004, China)

Abstract: The grinding process of vertical mill raw meal in cement industry features nonlinear, strong coupling and long time-delay, which is difficult to model precisely and implement stable control for raw meal fineness. Against the problem, a production index prediction model of vertical mill raw meal grinding process was established using Extreme Learning Machine (ELM). Adaptive dynamic programming (ADP) was used to control the raw meal fineness, whose action and critic networks were implemented by online sequential extreme learning machine. In the meaning of simulation, the results show that the proposed method is valid and helpful to reduce the energy consumption.

Keywords: vertical mill; raw meal; Adaptive Dynamic Programming (ADP); Extreme Learning Machine (ELM)

引言

粉磨过程是水泥生产过程的重要生产环节和典型耗能环节, 立磨是一种新型的粉磨设备, 集多功能于一体, 能高效综合地完成了物料的中碎、粉磨、烘干、选粉和气力输送过程^[1], 立磨已成为当

今国际上生料粉磨的首选设备。粉磨过程的电耗占整个水泥生产电耗的 50%~60%, 生料粉磨过细会增加电耗, 生料粉磨过粗, 影响产品质量。因此, 对生料细度的控制是影响能耗和稳定生产的关键因素^[2]。然而, 立磨生料粉磨过程是一个复杂的物理、化学过程, 具有非线性、强耦合、多输入等特点, 难以建立其精确的数学模型及实现稳定控制。

近年来, 自适应动态规划(ADP, adaptive dynamic programming)作为一种解决复杂非线性系统最优控制的优化方法, 已经得到了广泛地关注。



收稿日期: 2015-04-08 修回日期: 2015-10-18;
基金项目: 国家自然科学基金(61364007);
作者简介: 林小峰(1955-), 男, 广西陆川, 学士, 教授, 研究方向为复杂系统优化与智能控制; 孔伟凯(1989-), 男, 河北衡水, 硕士生, 研究方向为智能控制。

<http://www.china-simulation.com>

• 2764 •

ADP 将自适应评价理论应用于动态规划, 通过非线性的近似结构, 如神经网络等, 逐步逼近动态规划中的最优控制率及代价函数。通过这种方式, 避免了由于系统维数过大而引起的“维数灾”问题^[3-4]。

自适应动态规划算法一般采用 BP 网络实现, 但存在训练速度慢, 易陷入局部最小等问题。针对这些问题, 本文提出一种基于极限学习机的自适应动态规划优化控制算法, 采用极限学习机(ELM)神经网络建立立磨生料粉磨生产指标预测模型, 同时用极限学习机实现 ADP 算法, 对立磨粉磨过程中的稳定控制并降低电耗具有一定理论指导意义。

1 建立立磨粉磨过程模型

1.1 立磨粉磨工艺过程

立磨应用料床粉磨原理粉磨物料, 应用预热器和窑尾热风来传输和烘干物料, 具有能耗较低粉磨效率高的优点。

水泥厂立磨粉磨过程主要分为物料的粉磨和选粉两个阶段。

在物料粉磨阶段, 配比好的原料通过三道锁风阀门、下料溜子进入磨内, 堆积在磨盘中间, 磨盘转动产生的离心力使物料移向磨盘周边, 进入磨辊和磨盘间的辊道内, 磨辊在液压装置和加压机构的作用下, 向辊道内的物料施加压力。物料在辊道内被碾压之后, 向磨盘边缘移动, 直至从磨盘边缘的挡料圈上移出。

在物料选粉阶段, 风环处自下而上的热风对含水物料进行悬浮烘干, 并将磨碎后的物料带至磨机上部的分离器中进行分选。粗粉重新返回磨盘与喂入的物料一起进行再粉磨(这个过程也被称为内循环), 合格的成品随气流由磨机上部, 带出机外被回收器收集。没有被热风带起的粗颗粒物料溢出磨盘并由排渣口出磨, 然后被斗式提升机重新喂入磨机, 再次进行粉磨(这个过程也叫做外循环)。粉磨过程中可充分利用预热器的低温废气, 有利于节能降耗。

典型立磨系统工艺原理如图 1 所示。




图 1 立磨系统典型工艺原理图

在粉磨工艺工程中, 生料细度是一个很重要的指标, 在粉磨过程稳定的情况下, 出磨生料粒度一般维持在 $80\ \mu\text{m}$ 的筛余量在 20%~25%。影响生料细度的因素主要有以下几个^[3-6]。

1) 喂料量, 保证磨机运行的主要参数(进出口压差、磨机振动值等)正常, 过少的喂料, 容易导致立磨振动跳停, 当喂料量过大时, 磨盘上会出现“犁料”现象, 料层同样难以稳定;

2) 入磨气温、循环风挡板开度, 风量的大小和风速影响磨机出口温度、进出口压差等参数从而影响磨机碾磨效果和生产效率, 入磨温度高, 会使物料变得松散, 使料层变薄, 增加回料量, 增加磨内压差; 入磨温度过低, 物料含水量大, 粉磨和选粉效率都会降低;

3) 分离器转速, 影响细颗粒与粗颗粒的分离, 转速过大或过小会直接影响到最终收集的生料粉磨颗粒的质量, 影响粉磨细度水平。

上述是几个客观存在的影响变量, 控制好这几个变量是稳定粉磨细度的关键。

1.2 基于极限学习机的立磨生料细度预测模型

极限学习机(ELM)是 Huang G.B.等人提出的一种快速的单隐层神经网络训练算法^[7-9]。该算法的特点是在网络参数的确定过程中, 隐层节点参数(输入权值和阈值)随机选取, 无需调节; 而网络的输出权值是通过最小化平方损失函数得到的最小二乘解。相比于传统的 BP 网络, 只需进行一次输

出权值的确定,不需要通过多次误差反向传递调整多个参数,从而大大降低了网络学习时间。而且也避免了因为误差反向传递所引起的陷入局部最小等问题。

ELM 学习算法如下:

对于训练样本 (x, t) , 具有 L 个隐层神经元的单隐层前向神经网络的输出函数表达式为:

$$f_L(x) = \sum_{i=1}^L \beta_i G(a_i, b_i, x) \quad (1)$$

式中: a_i 为第 i 个隐层节点与输入之间的输入权值; b_i 为第 i 个隐层节点的阈值,两者都可以自由选择; β_i 为第 i 个隐层节点与输出之间的输出权值; $G(\cdot)$ 为隐层节点的输出函数。

考虑 N 个互异的样本 $\{(x_i, t_i)\}_{i=1}^N \subset R^n \times R^m$, 对于每一个输入 x_j 均有一个目标输出 $t_j, j=1, 2, \dots, N$ 。当

$$f_L(x_j) = \sum_{i=1}^L \beta_i G(a_i, b_i, x_j) = t_j, j=1, 2, \dots, N \quad (2)$$

时,网络输出没有误差。简化式(2)可以写成

$$H\beta = T \quad (3)$$

其中: $H(a_1, \dots, a_L, b_1, \dots, b_L, x_1, \dots, x_N) =$

$$H = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_1) \\ \vdots & \ddots & \vdots \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix}_{N \times L}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$$

则网络参数的训练问题转化为寻找最小二乘解 $\hat{\beta}$, 使得

$$\|H\hat{\beta} - T\| = \min_{\beta} \|H\beta - T\| \quad (4)$$

利用 Moore-penrose 广义逆可以得到

$$\hat{\beta} = H^\dagger T \quad (5)$$

ELM 算法训练过程中, 隐层节点参数 (a, b) 可以自由选择无需调节, 网络的输出权值是通过最小化平方损失函数得到最小二乘解, 网络的训练过程较简单、快速。

1.3 预测模型的训练及仿真

本文分别采用 ELM 网络和 BP 网络建立水泥立磨过程的预测模型, 选择喂料量、入磨气温、循环风挡板开度和分离器转速为控制量 u , 生料细度为状态量 x 。采集广西某水泥厂立磨粉磨过程数据, 由于采得的数据包含在线数据和离线数据, 采样时间也不相同, 需要在建模前对数据进行整合处理, 删除不符合生产实际的错误数据及存在较大误差的数据, 采用工程上常用的七点线性平滑法减小数据随机误差, 为了统一量纲对数据进行了零均值归一化处理。部分实时数据如表 1 所示。

表 1 某水泥厂立磨实时数据

序号	喂料量 t/h	入磨气温 /°C	分离器转速/rpm	循环风挡板开度%	生料细度%
1	428	155	37.5	40	22.22
2	420	158	37.5	30	25.67
3	415	157	37.5	30	24.51
4	425	146	39.5	55	21.22
...

设置 ELM 网络输入为 5, 输出为 1, 隐层节点设为 35, 隐层节点激活函数为 sigmod 函数按照公式(3)~(5)训练网络; BP 的性能与网络结构有很大的关系, 根据经验与试验, BP 网络隐层节点个数设为 25, 输入节点 5, 输出节点 1, 学习率 0.01, 学习误差 0.001, 学习步长为 1, 最大迭代次数 1 600 次。BP 网络隐层节点激活函数为 tanh()函数, 采用 Levenberg-Marquardt 训练方式训练网络。立磨粉磨生料细度 ELM 网络和 BP 网络的仿真结果对比如图 2 和图 3 所示。

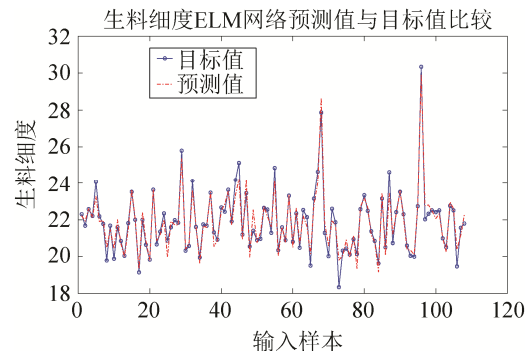


图 2 ELM 网络预测对比曲线

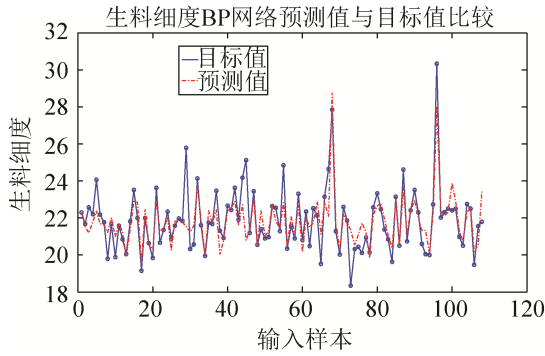


图 3 BP 网络预测对比曲线

其具体对比参数如表 2 所示。可以看出, ELM 网络的训练时间很短而且训练误差更小。

表 2 ELM 预测模型与 BP 预测模型之间的性能比较

模型性能	ELM	BP
生料细度均方根误差	0.066 7	0.178 8
生料细度最大相对误差%	4.15	14.38
训练时间/s	1.44	24.84

2 生料细度自适应动态规划控制

2.1 自适应动态规划(ADP)原理

自适应动态规划(adaptive dynamic programming, ADP)方法是动态规划、强化学习和人工神经网络等相结合形成的一种智能的优化控制方法^[10-12]。ADP 通过自适应迭代不断逼近哈密顿-雅可比-贝尔曼(Hamilton-Jacobi-Bellman equation, HJB)方程, 从而得到近似解, 避免了动态规划中随着存储量和计算量增大而引起的“维数灾”问题, 为解决非线性系统的最优控制问题提供了有效的方法。

本文采用 ADP 方法中最基础也是使用最广泛

的启发式动态规划(Heuristic dynamic programming, HDP)算法来控制水泥立磨的生料细度。HDP 包含评价网络、模型网络和执行网络三部分, 如图 4 所示。

图 4 中模型网络输出下一时刻状态 $x(k+1)$, 执行网络输出控制序列 $u(k)$, 评价网络输出近似代价函数 $V(x(k))$ 。

设系统的性能指标函数 $J(x(k), k)$ 为

$$J[x(k), k] = \sum_{i=k}^{\infty} \gamma^{i-k} U[x(i), u(i), i] \quad (6)$$

式中: U 为效用函数, $\gamma \in [0, 1)$ 为折扣因子。

记最优性能指标为 $J^*(x(k))$,

$$J^*(x(k)) = \min_{u(k)} \{U(x(k), u(k)) + \gamma J^*(x(k+1))\} \quad (7)$$

本文的控制对象是粉磨过程的生料细度, 生料细度的范围为 $(22.5 \pm 2.5)\%$, 因此选择的效用函数 U 可定义如下:

$$U(t) = \begin{cases} \left[\frac{X(t) - 22.5}{31} \right]^2, & |X(t) - 22.5| < 2.5 \\ 1, & \text{其他} \end{cases}$$

对于 HDP 算法, 评价网络输出的代价函数和执行网络的控制序列分别为 $V(x(k))$ 和 $u(k)$, 通过逐步最小化式(8)所示的误差来逐步逼近最优性能指标函数 $J^*(x(k))$ 。

$$\|E_c\| = \sum_k E_c(k)^2 = \sum_k [V(k) - U(k) - \gamma V(k+1)]^2 \quad (8)$$

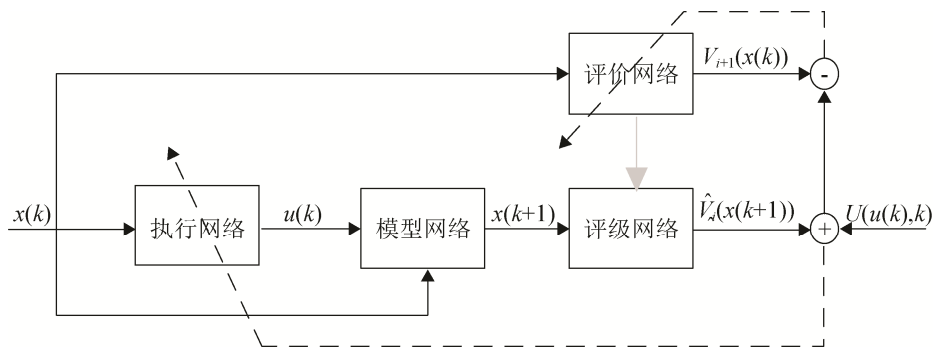


图 4 启发式动态规划结构图

2.2 基于 ELM 网络的 HDP 生料细度控制

现有的 HDP 算法评价网络, 执行网络和模型网络通常采用 BP 网络实现, 但由于 BP 网络调整参数众多, 存在训练时间长, 收敛速度慢, 易于陷入局部最小等缺点。因此需要对 HDP 算法的神经网络实现加以改进。单隐层前向网络的 ELM 算法通过 Moore-penrose 广义逆 H^\dagger 求最小二乘解, 从而确定网络的输出权值 β , 相比于 BP 网络, 大大简化了学习过程, 减少了学习时间。

为了实现 HDP 算法训练的过程, 本文用 ELM 网络的在线学习^[13]训练 HDP 的执行网络和评价网络。ELM 的在线学习由一部分初始数据确定输出权值 β , 当新的数据加入时, 在得到的 β 基础上进一步训练, 并对输出权值 β 进行修改, 有效地将新旧数据衔接在一起, 通过此过程训练 ADP 的执行网络和评价网络。

对于具有 L 个隐层节点的单隐层前向神经网络, 考虑总的训练样本 $\mathfrak{S}=\{(x_i, t_i) | x_i \in R^n, t_i \in R^m, i=1, 2, \dots, N\}$, 其中一个较小的训练样本子集 $\mathfrak{S}_0=\{(x_i, t_i) | i=1, \dots, N_0\}$, 其中 N_0 为 \mathfrak{S}_0 中的训练样本个数, $N_0 \leq N$ 。

根据公式(4)最小化 $\|H_0\beta - T_0\|$ 可以得到初始输出权值

$$\beta^{(0)}=K_0^{-1}H_0^T T_0 \tag{9}$$

这里 $H_0 = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_1) \\ \vdots & \dots & \vdots \\ G(a_1, b_1, x_{N_0}) & \dots & G(a_L, b_L, x_{N_0}) \end{bmatrix}_{N_0 \times L}$

$$T_0 = \begin{bmatrix} t_1^T \\ \vdots \\ t_{N_0}^T \end{bmatrix}_{N_0 \times m}$$

$$K_0 = H_0^T H_0 \tag{10}$$

对于取自 \mathfrak{S} 的第 $(k+1)$ 段训练样本 $\mathfrak{S}_{k+1}=\{(x_i, t_i) | i=\sum_{j=0}^k N_j+1, \dots, \sum_{j=0}^{k+1} N_j\}$, 其中 N_j 代表第 $(k+1)$ 段训练样本的个数。则输出权值可以按照公式(11)进行调整:

$$K_{k+1}=K_k+H_{k+1}^T H_{k+1}$$

$$\beta^{(k+1)}=\beta^{(k)}+K_{k+1}^{-1}H_{k+1}^T (T_{k+1}-H_{k+1}\beta^{(k)}) \tag{11}$$

其中:

$$H_{k+1} = \begin{bmatrix} G(a_1, b_1, x_{(\sum_{j=0}^k N_j)+1}) & \dots & G(a_L, b_L, x_{(\sum_{j=0}^k N_j)+1}) \\ \vdots & \dots & \vdots \\ G(a_1, b_1, x_{\sum_{j=0}^{k+1} N_j}) & \dots & G(a_L, b_L, x_{\sum_{j=0}^{k+1} N_j}) \end{bmatrix}_{N_{k+1} \times L}$$

$$T_{k+1} = \begin{bmatrix} t_{(\sum_{j=0}^k N_j)+1}^T \\ \vdots \\ t_{\sum_{j=0}^{k+1} N_j}^T \end{bmatrix}_{N_{k+1} \times m}$$

3 仿真实验

分别采用 ELM 网络和 BP 网络实现 HDP 算法。

ELM 网络实现的 HDP 算法, 设定评价网络隐层节点个数为 30, 输入输出节点均为 1 个, 执行网络隐层节点个数为 25, 输入节点为 1 个, 输出节点为 4 个, 初始生料细度 $X(0)=19$ 。ELM 算法按照公式(9)~(12)可以对执行网络和评价网络进行训练, ELM 网络代价函数的收敛过程见图 5, 控制率轨迹曲线如图 6 所示, 将优化控制律应用到系统 10 个时间步, 得到的优化状态轨迹如图 7 所示。采用 BP 网络实现的 HDP 算法, 评价网络网络结构为 1-8-1, 执行网络结构为 1-15-4, 学习率均为 0.01, 学习误差为 0.001, 最大迭代次数均为 1 600 次。BP 网络隐层节点激活函数为 $\tanh()$ 函数, 采用 Levenberg-Marquardt 训练方式训练网络。BP 网络仿真结果如图 8~10 所示。




图 5 基于 ELM 网络生料细度性能指标函数




图 6 基于 ELM 网络生料细度控制量控制轨迹

在代价函数和控制作用下生料细度的变化如图 7 所示。

图 7 所示。




图 7 基于 ELM 的生料细度 ADP 曲线




图 8 基于 BP 的生料细度性能指标函数

从图 7 和图 10 对比可以看出, 立磨生料粒度在 80 μm 的筛余量从 19%到 22.5%的过程中, 相对于 BP 网络的 ADP 控制, ELM 网络 ADP 控制能够更快达到稳定, 且超调量较小。算法性能对比如表 3 所示。




图 9 基于 BP 网络生料细度控制量控制轨迹




图 10 基于 BP 的生料细度 ADP 曲线

表 3 BP-ADP 与 ELM-ADP 性能比较

算法类型	时间步	控制误差/%
BP-ADP	24.586 1	7.11
ELM-ADP	2.776 8	0.724

由表 3 可以看出基于 ELM 网络的 ADP 算法训练比基于 BP 网络的 ADP 算法快得多, 同时控制误差也较小。

4 结论

水泥立磨生料粉磨过程工艺机理复杂、影响因素众多, 具有非线性, 强耦合等复杂特性, 难以建立其精确的数学模型。与此同时, 对立磨粉磨过程的控制不能随工况变化进行及时有效的调整, 粉磨过程的稳定控制难以实现。针对着这些问题, 本文采用单隐层前向网络极限学习机(ELM)算法, 建立了立磨粉磨过程的预测模型, 具有训练速度快、训

练精度高等优点。并提出了一种基于极限学习机在线学习的 ADP 优化算法对生料细度进行控制。仿真结果表明,系统训练时间短,超调量小,能快速达到稳定状态,在理论与仿真意义上,有利于对立磨粉磨生产过程的稳定控制和节能降耗,具有一定指导意义。

参考文献:

- [1] 肖争鸣, 李坚利. 水泥工艺技术 [M]. 北京: 化学工业出版社, 2006. Xiao Z M, Li L J. (Xiao Zhengming, Li Jianli. Cement technology [M]. Beijing, China: Chemical Industry Press, 2006.)
- [2] 颜文俊, 秦伟. 水泥立磨流程的建模和控制优化 [J]. 控制工程, 2012, 19(6): 929-934. (Yan W J, Qin W. Modeling and Control Optimization in Cement Vertical Roller Mill Process [J]. Control Engineering of China, 2012, 19(6): 929-934.)
- [3] Bellmanr Dreyfuss. Applied dynamic programming Princeton [M]. NJ, USA: Princeton Univ Press, 1962: 25-50.
- [4] Wang F Y, Zhang H G, Liu D R. Adaptive dynamic programming: an introduction [J]. IEEE Computational Intelligence Magazine (S1556-603X), 2009, 8(3): 39-47.
- [5] 孙常宝. 立式辊磨机原料磨系统工艺的控制 [J]. 散装水泥, 2007 (2): 57-59. (Sun B C. Process Control of Raw Mill System of Vertical Roller Mill [J]. Bulk Cement, 2007 (2): 57-59.)
- [6] 宁艳艳, 苑明哲, 王卓. 水泥生料立磨压差的广义预测 PID 控制 [J]. 信息与控制, 2012, 41(3): 378-390. (Ning Y Y, Yuan M Z, Wang Z. Generalized Predictive PID Controller of Differential Pressure in Vertical Roller Mill for Cement-Raw Grinding [J]. Information and Control, 2012, 41(3): 378-383, 390.)
- [7] Huang G B. An Insight into Extreme Learning Machines: Random Neurons, Random Features and Kernels [J]. Cognitive Computation (S1866-9964), 2014(6): 376-390.
- [8] Huang G B, Zhou H, Ding X, et al. Extreme Learning Machine for Regression and Multiclass Classification [J]. IEEE Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics (S2168-2267), 2012, 42(2): 513-529.
- [9] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications [J]. Neurocomputing (S0925-2312), 2006, 70: 489-501.
- [10] Wang D, Liu D R, Wei Q L, et al. Optimal control of unknown nonaffine nonlinear discrete-time systems based on adaptive dynamic programming [J]. Automatica (S0005-1098), 2012, 48(8): 1825-1832.
- [11] Zhang H G, Zhang X, Luo Y H, et al. An Overview of Research on Adaptive Dynamic Programming [J]. Automatica (S0005-1098), 2013, 39(4): 303-311.
- [12] Werbos P J. ADP: The Key Direction for Future Research in Intelligent Control and Understanding Brain Intelligent [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics (S2168-2267), 2008, 38(4): 898-900.
- [13] Liang N Y, Huang G B, P Saratchandran. A Fast and Accurate On-line Sequential Learning Algorithm for Feedforward Networks [J]. IEEE Transactions on Neural Networks (S1941-0093), 2006, 17(6): 1411-1423.