

基于生物地理学优化算法的高速磨削 电主轴定子电阻辨识

吴玉厚,张云龙,张丽秀

(沈阳建筑大学机械工程学院,辽宁 沈阳 110168)

摘要 目的 减小电主轴在运行过程中定子电阻变化导致的电主轴转矩脉动,进而提高高速磨削机床加工精度. 方法 基于直接转矩控制系统下的高速磨削电主轴温度检测试验数据,将BP神经网络算法与随机扰动的生物地理学优化算法(MLBBO)相结合,利用MLBBO算法对传统的BP神经网络权值和阈值进行优化,建立基于MLBBO-BP的定子电阻辨识模型,并利用MATLAB进行仿真. 结果 利用MLBBO-BP模型方法对直接转矩控制系统下的电主轴定子电阻辨识精度可达 $\pm 0.3\%$,模型辨识能力较强. 和传统的BP神经网络辨识定子电阻方法相比,精度更高. 结论 利用MLBBO-BP方法可以有效地辨识定子电阻,辨识精度较高.

关键词 DTC; MLBBO; BP神经网络; 电主轴; 定子电阻辨识

中图分类号 TH133.2; TP183

文献标志码 A

Biogeography Based Optimization Algorithm of High Speed Grinding Motorized Spindle Stator Resistance Identification

WU Yuhou, ZHANG Yunlong, ZHANG Lixiu

(School of Mechanical Engineering, Shenyang Jianzhu University, Shenyang, China, 110168)

Abstract: In order to reduce the motorized spindle torque ripple caused by the changing of stator resistance in the process of running, which can increase the machining accuracy of high speed grinding machine tool. Based on the motorized spindle temperature test data, the neural network algorithm are combined with random perturbation of biogeography (MLBBO), which is used to optimize the traditional BP neural network weights and thresholds and established the model of stator resistance identification based on MLBBO-BP, finally simulated on Matlab. The simulation results show that the accuracy of stator resistance identification using MLBBO-BP model can reach 0.3% , the capability of model identification is strong, which has higher precision than traditional BP neural network algorithm.

收稿日期:2017-03-15

基金项目:国家自然科学基金项目(51375317, 51675353); 辽宁省高效创新团队支持计划项目(LT2014011)

作者简介:吴玉厚(1955—),男,教授,博士,博士研究生导师,主要从事数控机床主轴系统关键技术研究.

Key words: DTC; MLBBO; BP neural network; motorized spindle; stator resistance identification

目前,电主轴广泛采用的控制技术是直接转矩控制(direct torque control, DTC)技术和矢量控制技术. 直接转矩控制是20世纪80年代中期德国学者 Depenbrock^[1]和日本学者 Takahashi^[2]等提出的一种高性能的交流电动机变频调速系统. 与矢量控制技术相比,直接转矩控制系统具有结构简单、转矩响应快等优点. 经典的直接转矩控制系统中,基本的控制方法步骤如下:定子磁链的观测、定子磁链的区间判断、电磁转矩的有效控制、电压空间矢量的选择. 该方法将计算出的转矩与磁链和给定值比较,得到转矩差值 E_{te} 和磁链 E_{ψ} 以及磁链角 θ ,通过选择合适的空间电压矢量实现电机的直接转矩控制. 但是在电主轴的实际运行过程中,电主轴的定子电阻并不是一直保持恒定的,因此电阻的变化会导致直接转矩控制系统中定子磁链和转矩的观测模型不准确,进而影响直接转矩控制系统的控制效果,容易产生转矩脉动过大问题,影响机床加工精度,因此有必要对不同工况下电主轴系统的定子电阻进行辨识.

目前,实用的定子电阻在线辨识方案主要有两种:第一种是基于自适应机构定子电阻在线辨识. 近年来,模型参考自适应在电动机定子电阻辨识方面的应用越来越多, Soltani 等^[3]设计了基于李雅普诺夫定理的非线性定子磁链观测器,实现了定子磁链的在线瞬态估计. 黄志武等^[4]设计了一种全阶自适应状态观测器,提出了基于观测器的速度和定子电阻辨识方案. 参考模型和可调模型都与电机内部的各个参数有关,因此电机参数的准确性会影响定子电阻辨识的精度. 第二种是人工智能技术如模糊逻辑控制^[5]、RBF神经网络^[6]、模糊神经网络^[7-9]等方法,实际验证,通过人工智能方法辨识定子电阻精度较高、速度较快,是未来的发展方向. 但是大多数传统的人工智能技术要么复杂难

以计算,要么容易陷入局部最优点. BP(Back Propagation)神经网络是一种按误差逆传播算法训练的多层前馈网络,它可以逼近任意连续函数,具有很强的非线性映射能力,凭借在非线形系统辨识上的良好表现得到了广泛的应用. 但是 BP 神经网络收敛速度慢、不能保证收敛到全局最优点. 为此,许多专家和学者都提出了改进算法.

生物地理学优化算法^[10] (BBO, Biogeography-Based Optimization)以模拟物种迁移、变异等生物行为提出迁移算子、变异算子、清除算子来改变生物种群质量. 凭借其结构简单、容易实现等优点,该算法已经在工业领域得到广泛的应用. 文献[11-13]将 BBO 算法以及改进的混合差分进化 BBO 算法用于复杂的经济调度问题,取得了不错的效果. 文献[14]将改进的 BBO 算法应用在热工 PID 优化中. 陈绍武等^[15]将 BBO 与粒子群算法(PSO)相结合,提出了 BBOPSO 算法,并将其用于粗甲醇转化率的在线测量. 由封全喜等^[16]等提出的 MLBBO 在 BBO 的基础上引入随机扰动算子,提高了优化精度,克服了传统的 BBO 探索能力弱的缺点.

近几年,基于智能优化算法优化 BP 神经网络技术得到了很大程度的进展,精度也较传统的 BP 神经网络提高了很多,但是依旧存在一些问题,例如优化算法运行速度不能满足要求、优化算法优化 BP 神经网络的权值和阈值容易陷入局部最优点等. 笔者采用的 MLBBO-BP 算法是将 MLBBO 用于优化 BP 神经网络,进而将训练好的 BP 神经网络用于辨识电主轴的定子电阻,此方法能够很好地解决这些问题,精度更高,速度更快,不易陷入局部最优点.

1 电主轴定子电阻的特性分析

1.1 定子电阻对直接转矩控制系统的影响

在传统的直接转矩控制系统中, $u-i$ 模

型凭借其结构简单鲁棒性好,成为最常用的磁链观测模型^[17].其磁链计算式为

$$\psi_s = \int (U_s - I_s R_s) dt. \quad (1)$$

将温度、频率、电流等因素引入式(1)可以发现,此时电阻为 $R_s + \Delta R_s$, 电流也变成了 $I_s + \Delta I_s$. 此时定子磁链的实际值为

$$\psi'_s = \int [U_s - (I_s + \Delta I_s)(R_s + \Delta R_s)] dt. \quad (2)$$

定子磁链的观测值为

$$\psi_s^* = \int [U_s - (I_s + \Delta I_s)R_s] dt. \quad (3)$$

由式(2)和式(3)比较可以得知,磁链的偏差为

$$\Delta\psi_s = \int [\Delta R_s(I_s + \Delta I_s)] dt. \quad (4)$$

同理,根据直接转矩控制系统转矩表达式(5)可以得出,转矩偏差 $\Delta T_e = T'_e - T_e^* \neq 0$ (n_p 为极对数).

$$T_e = \frac{3}{2} n_p |\psi_s \times I_s|. \quad (5)$$

由于电流为可观测量,观测电流和实际电流相同,影响磁链和转矩的唯一因素就是 R_s , 因此定子电阻的变化会直接影响到磁链的观测和转矩的观测. 文献[18]利用 MATLAB 针对这一现象进行仿真试验,结果表明对于高速运行的电机来说,系统不受定子电阻变化的影响,但在低速下,定子电阻的变化会对系统产生明显影响. 对于高精度电主轴来说,磁链和转矩观测不准确会影响到直接转矩控制系统对高精度电主轴的控制效果,进而影响到机床的加工精度,因此有必要对不同工况下的定子电阻进行辨识.

1.2 影响定子电阻的因素

影响电主轴定子电阻的因素包括电主轴结构、电主轴温度、定子电流及频率^[19],在这些因素中,温度是影响定子电阻变化的主要因素.

根据文献[17]可知,感应电机定子绕组每相电阻可以根据式(6)计算:

$$R_s = K'_r \rho_w \frac{2N_1 l_\sigma}{A_{\sigma 1} a_1}. \quad (6)$$

式中: N_1 为每相串联的匝数; l_σ 为线圈半匝平均长度, mm; $A_{\sigma 1}$ 为导体的横截面积, mm^2 ; a_1 为每相绕组的并联支路数; ρ_w 为基准工作温度的导体电阻率; K'_r 为电阻增加系数.

由式(6)可知,电主轴的定子电阻除了与电主轴的内部因素有关,还与电主轴的运行工况有关. 温度的变化是导致定子电阻发生改变最主要的因素,温度变化对定子电阻的影响见式(7):

$$R_{s2} = \frac{235 + t_2}{235 + t_1} R_{s1}. \quad (7)$$

式中: R_{s1} 为温度为 t_1 时的冷态电阻; R_{s2} 为温度为 t_2 时的冷却电阻. 可以看出,理论的定子电阻值随着温度的变化成一次线性关系.

定子电流对定子电阻的影响本质是温度对定子电阻的影响. 定子电流一方面由于自身的变化导致铜耗增大,电主轴的温度上升. 另一方面则是由于电流的增大会导致电主轴漏磁增加,杂质损耗增大频率对定子电阻的影响与集肤效应有关. 异步电机通过改变电源频率来改变电主轴的转速. 但是如果电源频率增大,那么很有可能由于集肤效应的影响,电主轴的定子电阻也会发生变化. 同时,当电动机进入到弱磁调速范围内时,由于磁路饱和,电机内同样会产生集肤效应,这既可能导致转子电阻和电感发生改变,也可能对定子电阻产生一定影响.

1.3 定子电阻测量

在影响电主轴定子电阻的诸多因素中,运行时间和频率会影响到定子电阻的电流和温度,定子电阻的电流和温度是影响定子电阻的直接因素. 因此笔者利用精度为 0.1% 的 LCR-821 测试仪、精度达 0.5% 的 TC-2008 多路温度测试仪及测功机对型号为 150MD18Z9 的电主轴进行定子电阻、电流及外壳温度数值(由于定子电阻嵌于电主轴内部,其温度不易测量,因此试验选择对电主轴

表面温度进行了测量)的读取,进而观察和分析这些因素对定子电阻的影响.

试验中采用 25 ℃ 恒温水冷却. 由于运行时间和电主轴工作频率是预先设定的, 因此

选择每 10 min 测试一次, 一共测试 12 次, 频率范围为 10 ~ 250 Hz, 测量步长为 5 Hz. 电主轴定子电流的数值从变频器读取, 一共测得 588 组数据, 结果见表 1.

表 1 环境数据以及电阻值
Table 1 Environmental data and resistance values

编号	运行时间/min	频率/Hz	电流/A	温度/℃	定子电阻/Ω
1	10	10	5.85	25.1	2.172
2		15	5.792 3	25.061 8	2.173 3
⋮		⋮	⋮	⋮	⋮
49		250	5.79	35.1	2.232
50	20	10	5.74	25.233 3	2.172 9
51		15	5.664 1	25.182 8	2.181 3
⋮		⋮	⋮	⋮	⋮
98		250	5.735	36.3	2.237 9
99	30	10	5.75	26	2.176 6
100		15	5.683 9	26.389 7	2.182 1
⋮		⋮	⋮	⋮	⋮
147		250	5.71	36.733 3	2.242 8
⋮	⋮	⋮	⋮	⋮	⋮
588	120	250	5.77	36.9	2.245 6

根据以上数据, 利用 MATLAB 分析电阻随温度变化, 图 1 为电阻值和温度的变化散点图. 可以看出, 随着温度的升高, 电阻值在逐渐变大, 但是电阻值并不是严格遵循线性关系的, 再对比式(7), 可以证明影响定子电阻的因素不单单是定子电阻温度.




图 1 电阻值和温度的变化散点图
Fig. 1 Variation of the resistances and temperatures

2 基于 MLBBO - BP 的神经网络的定子电阻辨识算法

为了利用电主轴定子电阻测试试验结果辨识不同工况下的定子电阻, 笔者建立基于 BP 神经网络的定子电阻辨识模型. BP 神经网络的结构如图 2 所示, 输入层 - 隐含层 - 输出层采用 4 - 4 - 1 结构, 即输入层代表电主轴运行频率、电主轴工作时间、定子电流、定子电阻温度, 输出层是定子电阻. 神经网络使用训练函数是 Lenvenberg - Marquardt (即 LM 算法). 在传统的 BP 神经网络中, 输入层、输出层和隐含层之间的权值和阈值都是采用随机数的方式确定, 因此权值和阈值的选取会对 BP 神经网络的精度和运行速度产生一定的影响. 在该算法中, 将 MLBBO 用于优化 BP 神经网络的权值和阈值, 进而提高 BP 神经网络辨识电主轴的定子电阻的辨识精度.

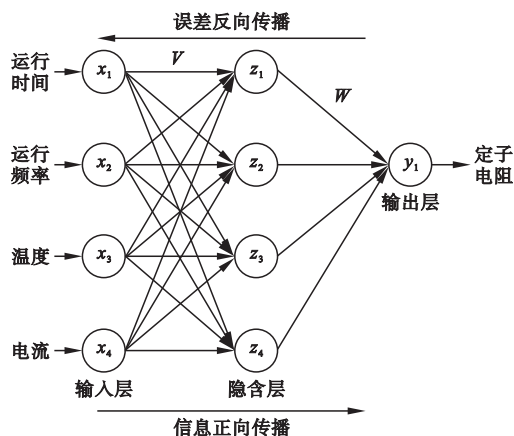


图 2 BP 神经网络的结构

Fig. 2 The structure of the BP neural network

MLBBO 算法有两个主要的参数:栖息地适应度指数 (Habitat Suitability Index, *HSI*) 和适应度指数变量 (Suitability Index Variables, *SIV*). 在文中, *SIV* 相当于即将优化的权值和阈值. 优化之前需要对权值和阈值进行初始化操作, 将它们归一到向量 \mathbf{x} (即 *SIV*) 中, 即 $\mathbf{x} = [w_1, b_1, w_2, b_2]$, 并赋予一组初始随机数, 其中 w_1 和 b_1 为分别为输入层和隐含层之间的权值和阈值, w_2 和 b_2 为分别为隐含层和输出层之间的权值和阈值.

适应度指数相当于评价权值和阈值好坏的重要指标, 这里采用 BP 神经网络训练的均方差, 见式(8):

$$MSE = \frac{1}{mp} \sum_{i=1}^p \sum_{j=1}^m (y'_{ij} - y_{ij})^2. \tag{8}$$

式中: MSE 为所求网络均方差; m 为输出节点的个数; p 为训练样本的数目; y'_{ij} 为网络期望输出值; y_{ij} 为网络实际输出值. 适应度指数的高低对应着每组权值和阈值在 BP 神经网络中的表现情况, 好的权值和阈值所训练出来的 BP 神经网络均方差更小.

MLBBO 为了改善物种质量, 引入了迁移算子、变异算子、清除算子和随机扰动算子. 迁移算子可以有效地交换 *SIV* 中的解向量, 高的 *HSI* 对应的解以一定的迁出率将信息共享给低 *HSI* 的解, 低 *HSI* 解从高 *HSI* 的解里面接受许多新的特征, 这些额外的新的

特征可以有效地提高解的质量. 马海平等^[20]提出了不同的迁移模型, 其中效果最好的就是余弦迁移率模型(见图 3). 在这种模型中, 迁入率 $\lambda_s = (I/2) \cdot (\cos(s\pi/n) + 1)$. λ_s 表示有 s 个种群时的迁入率, μ_s 为迁出率, s 为当前物种数量, n 为最大种群数量, I 和 E 分别对应于最大迁入率和最大迁出率.




图 3 BBO 算法余弦迁移率模型

Fig. 3 The cosine migration rate model of BBO algorithm

变异算子可以有效地丰富种群的多样性. 在种群的不断更替中, 当满足一定概率时, 种群就会产生变异, 一般这种变异概率比较小. 假定 BBO 算法根据各个栖息地的物种数量概率 $P(s_i)$, 对栖息地的特征变量进行变异, 下一时刻物种数量为 s 的概率 P'_s 计算见式(9):

$$P'_s = \begin{cases} -(\lambda_s + \mu_s)P_s + \mu_{s+1}P_{s+1}, & s=0, \\ -(\lambda_s + \mu_s)P_s + \lambda_{s-1}P_{s-1} + \mu_{s+1}P_{s+1}, & 1 \leq s \leq S_{\max} - 1, \\ -(\lambda_s + \mu_s)P_s + \lambda_{s-1}P_{s-1}, & s=S_{\max}. \end{cases} \tag{9}$$

如何根据栖息地拥有的种群数量确定相应的变异概率是变异算子的主要问题. 变异概率函数与该栖息地的数量概率成反比, 也就是说, 数量概率高的变异率低, 数量概率低的变异率就会高一些. 相应的函数见式(10):

$$m(x_i) = m_{\max} \left(1 - \frac{P(s_i)}{P_{\max}}\right). \tag{10}$$

清除算子的主要作用是防止迁移算子产生相似解影响种群的多样性, 导致种群的多样性差, 因此 Simon 提出利用清除算子来对相似解进行改变, 当两个解相似或相同时, 采用随机解代替相似解.

随机扰动算子的加入可以有效地改善传统 BBO 容易陷入局部最优点的问题,增加生

$$H_i(SIV) = \begin{cases} H_i(SIV) + a \times (H_k(SIV) - H_i(SIV)), & \text{rand}(0,1) < p_l, \\ H_i(SIV), & \text{else.} \end{cases} \quad (11)$$

式中: H_k 为随机选择的解; p_l 为扰动频率; a 为扰动幅度,该算子以一定概率在优良解的附近发生一定频率的扰动.

算法进行优化时使用的参数如下:最大迁入迁出率为 $I = E = 1$,进化次数为 500,种群规模为 20,变异概率为 0.05,扰动幅度 $a = 0.8$,扰动频率 $p_l = 0.2$.

3 辨识仿真与结果分析

在建立神经网络之前,首先要对定子电阻进行分组和处理.随机选择表 1 中的 480 组数据用于神经网络的模型的训练,另外的 108 组数据用于神经网络模型的检验.然后将数据样本进行归一化处理,并构建神经网络.将所需要优化的神经网络的权值和阈值采用随机数的方式统一整合成 N_p 个行向量并加入到 MLBBO 优化算法中.经过 500 次的循环迭代以后,可以得到最好的一组向量,将这组向量分解为神经网络所需要的权值和阈值,并将“最优”神经网络模型保留下来进行测试,所得到的神经网络训练步数和训练均方差见图 4.

态系统抗干扰性,极大地提升优化算法的探索能力.随机扰动算子如式(11)所示:

由图 4 可以看出,当训练步数达到 10 步时,训练数据和测试数据的均方差均趋于平稳,此时训练结束.由此可见,利用 MLBBO-BP 方法进行定子电阻辨识的辨识精度满足要求,并且速度很快.

为了更加直观地检测定子电阻辨识效果,笔者将测试数据的真实样本和测试数据的辨识结果相比较(见图 5),网络输出曲线是利用 MLBBO-BP 辨识后的输出样本数据值,样本曲线是样本数据的输出数据值.比较两条曲线,可以直观地得到样本数据与网络输出数据的拟合程度,在误差范围之内,两条曲线几乎重合,此时的神经网络已经具有辨识定子电阻的能力.




图 4 神经网络训练步数和均方差

Fig. 4 Neural network training steps and mean square error




图 5 网络输出电阻值和样本电阻值拟合程度曲线

Fig. 5 The fitting degree curves of the Network output resistance value and sample value

由 MLBBO-BP 优化过的神经网络网络输出数据和真实数据的误差见图 6.从图中可以看出,利用 MLBBO 训练 BP 神经网络的误差在 $\pm 0.007\Omega$ 之内,可以较为准确地观测定子电阻的阻值.根据表 1 采集到的不同工况下的定子电阻可以计算出利用 MLBBO-BP 方法辨识定子电阻精度达 $\pm 0.3\%$,可见 MLBBO-

BP 对定子电阻的辨识能力较强.




图 6 网络输出和样本输出之间的误差
Fig. 6 The error between the network output and sample output

图 7 是将 MLBBO - BP 方法和传统的 BP 神经网络辨识定子电阻方法相比较得到的电阻误差图.可以看出,利用 MLBBO - BP 方法得到的定子电阻精度更高,效果更好.




图 7 利用 MLBBO - BP 方法和原始 BP 神经网络辨识电阻误差
Fig. 7 The error plot of resistance identification using MLBBO-BP and simple BP Neural network

4 结 语

通过以上的 MATLAB 仿真,可以看出 BP 神经网络经过 MLBBO 优化以后可以很好地逼近样本数据,其预测的误差范围为 $\pm 0.007\Omega$. 在实际的应用中可以将环境因素直接引入到已经训练好的 BP 神经网络

中,就可以得到相应的定子电阻观测值.然后将观测到的定子电阻值输入到定子磁链观测器中,进而能够得到较为准确的磁链幅值,由此可以减少定子电阻的变化对高精度电主轴磁链和转矩的影响.进而提高高速加工行业的加工质量,促进高精度加工的发展.

参考文献

[1] DEPENBROCK M. Direct self-control(DSC) of inverter-fed introduction machine[J]. IEEE transaction on power electronics, 1988, 3 (4) : 420 - 429.

[2] TAKAHASHI I, NOGUCHI T. A new quick-response and high-efficiency control strategy of an induction motor[J]. IEEE transaction industry applications, 1986, 22 (5) : 820 - 827.

[3] SOLTANI J, MARKADEH G R A, ABJADI N R, et al. A new adaptive direct torque control (DTC) scheme based on SVM for adjustable speed sensorless induction motor drive [J]. Proceeding of international conference on electrical machines and systems, 2007, 2: 497 - 502.

[4] 黄志武, 桂卫华, 年晓红, 等. 一种新型的基于观测器的无速度传感器感应电动机定子电阻辨识方案 [J]. 电工技术学报, 2006, 21 (12) : 13 - 20.

(HUANG Zhiwu, GUI Weihua, NIAN Xiaohong, et al. A novel stator resistance identification methodology for speed sensorless induction motor drives using state observer [J]. Transactions of China electrotechnical society, 2006, 21 (12) : 13 - 20.)

[5] JOSHI P R, GUPTA R A, WADHAWANI A K. Intelligent controller for DTC controlled matrix converter cage drive system[J]. Iranian journal of electrical and computer engineering, 2008, 7 (1) : 9 - 16.

[6] 张丽秀, 吴玉厚, 片锦香, 等. 电主轴定子电阻混合智能辨识方法 [J]. 沈阳建筑大学学报 (自然科学版), 2013, 29 (6) : 1098 - 1103.

(ZHANG Lixiu, WU Yuhou, PIAN Jinxiang, et al. The method about stator resistance hybrid intelligent identification of motorized spindle [J]. Journal of Shenyang jianzhu university (natural science), 2013, 29 (6) : 1098 - 1103.)

[7] 曹开玉, 徐中, 刘晓冰. 模糊神经网络在线辨识定子电阻的直接转矩控制技术 [J]. 电工

- 技术,2003(4):41-43.
(CAO Kaiyu, XU Zhong, LIU Xiaobing. Direct torque control technology of fuzzy NN network online distinguishing satator resistance[J]. Electric engineering, 2003(4):41-43.)
- [8] VUKADINOVIC D, BASIC M, KULISIC L. Stator resistance identification based on neural and fuzzy logic principles in an induction motor drive[J]. Neurocomputing, 2010, 73(4/6):602-612.
- [9] SAYOUTI Y, ABBOU A, AKHERRAZ M. On-line neural network stator resistance estimation in direct torque controlled induction motor drive[M]. Piscataway: IEEE Computer Society, 2009.
- [10] SIMON D. Biogeography-based optimization[J]. IEEE transactions on evolutionary computation (S1089-778X), 2008, 12(6):702-713.
- [11] ROY P K, GHOSH S P, THAKUR S S. Biogeography-based optimization for economic load dispatch problems[J]. Electric power components and systems (S1532-5008), 2010, 38:166-181.
- [12] BHATTACHARYA A, CHATTOPADHYAY P K. Biogeography-based optimization for different economic load dispatch problems[J]. IEEE transactions on power systems, 2010, 25(2):1064-1077.
- [13] BHATTACHARYA A, CHATTOPADHYAY P K. Hybrid differential evolution with biogeography-based optimization for solution of economic load dispatch[J]. IEEE transaction on power systems (S0885-8950), 2010, 25(4):1955-1964.
- [14] 薛虹, 韩璞. 一种改进的 BBO 算法及在热工 PID 优化中的应用[J]. 华北电力大学学报(自然科学版), 2016, 43(1):81-85.
(XUE Hong, HAN Pu. Improved BBO algorithm and its application in PID optimization of thermal system[J]. Journal of north China electric power university (natural science edition), 2016, 43(1):81-85.)
- [15] 陈绍武, 宋书群, 张凌波, 等. 改进生物地理学甲醇合成转化率软测量[J]. 系统仿真学报, 2014, 26(1):17-22.
(CHEN Shaowu, SONG Shuqun, ZHANG Lingbo, et al. Soft sensor of conversion rate in methanol synthesis based on improved biogeography-based optimization[J]. Journal of system simulation, 2014, 26(1):17-22.)
- [16] 封全喜. 生物地理学优化算法研究及其应用[D]. 西安:西安电子科技大学, 2014.
(FENG Quanxi. Research on biogeography-based optimization and its application[D] Xi'an: Xidian University, 2014.)
- [17] 王成元, 夏加宽, 杨俊友, 等. 电机现代控制技术[M]. 北京:机械工业出版社, 2006.
(WANG Chengyuan, XIA Jiakuan, YANG Junyou, et al. Modern control technology of motor[M]. Beijing: China Machine Press, 2006.)
- [18] 梅柏杉, 陈晖. 直接转矩控制系统中定子电阻的影响分析[J]. 微特电机, 2009, 37(4):13-15.
(MEI Baishan, CHEN Hui. Influence analysis of stator resistance in direct torque control[J]. Small & special electrical machines, 2009, 37(4):13-15.)
- [19] 张丽秀, 刘晓辉, 吴玉厚, 等. 电主轴定子电阻特性分析[J]. 机电产品开发与创新, 2012, 25(5):162-164.
(ZHANG Lixiu, LIU Xiaohui, WU Yuhou, et al. Stator resistance characteristic analysis of electric spindle[J]. Development & innovation of machinery & electrical products, 2012, 25(5):162-164.)
- [20] 马海平, 李雪, 林升东. 生物地理学优化算法的迁移率模型分析[J]. 东南大学学报(自然科学版), 2009, 39(增刊 I):16-21.
(MA Haiping, LI Xue, LIN Dongsheng. Analysis of migration rate models for biogeography-based optimization[J]. Journal of southeast university (natural science edition), 2009, 39(SI):16-21.)