

doi: 10.3969/j.issn.0490-6756.2020.06.013

改进的BP神经网络PID控制器 在气体浓度控制中的研究

李航¹, 杜璠², 胡晓兵¹, 周韶武¹

(1. 四川大学机械工程学院, 成都 610065; 2. 四川航天长征装备制造有限公司, 成都 610065)

摘要: 针对动物缺氧实验中气体浓度控制这一时变非线性的过程, 将BP神经网络与传统PID控制相结合虽然可以取得较好的控制效果, 但是也存在着网络收敛速度慢、稳定性较差等问题, 基于此, 提出了一种基于改进的遗传算法优化的BP神经网络PID控制器. 首先, 该控制器对遗传算法的收敛速度和稳定性进行改进, 利用改进后的遗传算法优化BP神经网络的权重初始值; 然后, 用优化后的BP神经网络实现PID控制参数的在线调整; 最后, 在MATLAB中对两种控制器进行仿真实验, 结果显示, 与传统的BP神经网络PID控制器相比, 改进后的BP神经网络PID控制器具有更好的控制性能.

关键词: PID控制; BP神经网络; 遗传算法; 气体浓度控制; 智能控制

中图分类号: F407.67 **文献标识码:** A **文章编号:** 0490-6756(2020)06-1103-07

Research on improved BP neural network PID controller in gas concentration control

LI Hang¹, DU Fan², HU Xiao-Bing¹, ZHOU Shao-Wu¹

(1. School of Mechanical Engineering, Sichuan University, Chengdu 610065, China;

2. Sichuan Aerospace Changzheng Equipment Manufacturing Co., Ltd, Chengdu 610065, China)

Abstract: The process of gas concentration control in animal hypoxia experiment is time-varying and nonlinear, Combining BP neural network with traditional PID control can achieve better control results, but there are still some problems such as slow convergence speed and poor stability. To solve these problems, a new BP neural network PID controller, optimized by improved genetic algorithm, is proposed. The convergence speed and stability of genetic algorithm are improved in order to optimize the initial weights of BP neural network, then the optimized BP neural network was used to realize on-line adjustment of PID parameters in this controller. Finally, the conventional and improved controllers are simulated in MATLAB, the results show that the improved BP neural network PID controller has better control performance, compared with the conventional BP neural network PID controller.

Keywords: PID control; BP neural network; Genetic algorithm; Gas concentration control; Intelligent control

收稿日期: 2020-01-12

基金项目: 中国制造 2025 四川行动计划(2017ZZ018, 2018ZZ011)

作者简介: 李航(1996-), 男, 重庆北碚人, 硕士研究生, 研究方向为智能算法、机器视觉. E-mail: 396511990@qq.com

通讯作者: 胡晓兵. E-mail: huxb@scu.edu.cn

1 引言

传统的 PID 控制器由比例、积分、微分三个控制部分组成,由于其算法简单,较为稳定,广泛应用于各个控制系统中.然而在动物缺氧实验气体控制过程中,由于传感器测量存在滞后性,内外部环境不断变化,以及控制对象不确定因素的增多,导致系统呈现出时变非线性的特点,此时使用传统 PID 控制会出现较大的误差,无法达到理想的控制效果^[1].因此,迫切需要对其进行改良和优化. BP 神经网络具有较强的非线性映射能力和自适应能力,将传统 PID 控制器与 BP 神经网络相结合,利用 BP 神经网络自动生成 PID 控制器中 k_p 、 k_i 、 k_d 三个参数,能够提高系统的控制精度和适应能力^[2-4],从而实现智能控制.

然而, BP 神经网络存在着收敛速度慢,并且结果容易陷入局部最优解等问题.针对这些问题,文献^[5]在 BP 神经网络训练时将学习率依照误差自动调整,得到了更快的收敛速度和更小的误差.文献^[6]利用免疫遗传算法优化 BP 神经网络的权值,文献^[7]将遗传算法与粒子群算法相结合,形成一种混合优化算法对 BP 神经网络进行优化改进,利用优化后的神经网络生成 PID 控制器的参数,

实验结果显示,两种方法优化后的控制系统在控制精度和鲁棒性上都有较大提高.

为此,本文设计并提出了一种新型的基于改进的遗传算法优化的 BP 神经网络 PID 控制器(简称改进 GA-BP-PID 控制器).该控制器采用 BP 神经网络生成 PID 控制器各项参数,并提出一种改进的遗传算法优化神经网络的权重初始值.为了说明本文提出的改进 GA-BP-PID 控制器相较于传统的 BP 神经网络 PID 控制器(简称 BP-PID 控制器)具有更优的控制性能,本文以动物缺氧实验中气体浓度控制为例,对以上两种控制器进行仿真分析和比较.结果表明,本文提出的改进的控制器可以更加快速、精准地满足控制要求.

2 模型建立

当供应组织的氧不足或组织利用氧障碍时,机体的机能、代谢以及形态结构发生异常变化的病理过程称为缺氧.在鼠缺氧实验中,观察经缺氧环境刺激后小鼠的生理状态,对高原习服机制的研究具有重大的意义^[8].针对这一需求,本文利用一款智能动物实验箱实现氧气浓度的调控,并利用该实验箱记录实验过程中氧气浓度的实时变化数据.实验箱示意图如图 1 所示.

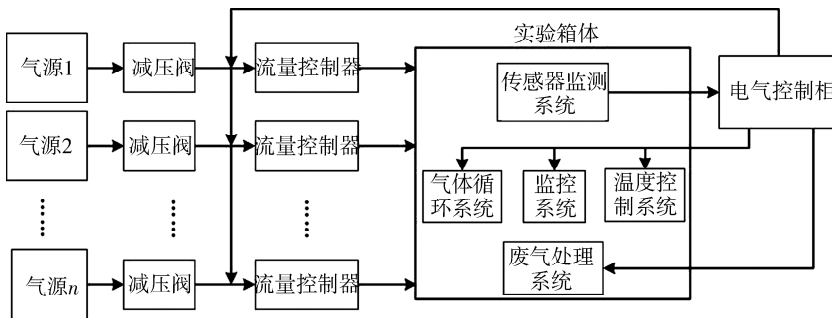


图 1 实验箱示意图

Fig. 1 Diagram of the experimental box




图 2 氧气浓度变化曲线

Fig. 2 Oxygen concentration curve

实验开始时,外界环境氧气浓度为 21%,设定箱体内部环境稳定时氧气浓度为 10%,采样时间为 1 s,得到各时刻氧气浓度变化数据,如图 2 所示.

由图 2 可知,控制过程中氧气浓度在稳定值附近不断振荡,最终并未稳定.系统响应是一条近似的 S 形单调曲线,且具有一阶延迟系统的特征,因此系统的传递函数可用以下式子近似表示.

$$G(S) = \frac{Ke^{-\tau s}}{Ts + 1} \quad (1)$$

式(1)中, K 为静态增益; T 为时间常数; τ 为延迟

时间. 本文采用作图法求解相关参数^[9]. 该方法计算简单、易于实现, 具体做法是过曲线斜率最大点做切线, 利用切线的交点找参数 T 与 τ , 静态增益 K 通过以下公式直接计算.

$$K = \frac{|u(\infty) - u(0)|}{r} \quad (2)$$

式(2)中, r 为期望的输出信号; $u(0)$ 为初始值; $u(\infty)$ 为输出稳态值. 由图 2 可得 $T + \tau = 55$ s, $\tau = 10$ s, $u(\infty) = 11$, $u(0) = 0$, $r = 11$, 因此系统的传递函数表达式为

$$G(S) = \frac{1}{45s + 1} e^{-10s} \quad (3)$$

3 BP 神经网络 PID 控制器

BP-PID 控制器由 PID 控制器和 BP 神经网络两部分组成. 传统 PID 控制器适用于简单的线性系统, 但对于非线性、时变性的系统控制效果则不太理想. BP 神经网络可以利用其自学习能力输出对应于某种最优控制率下的最优 PID 控制器参数组合以达到期望的控制效果^[10-11]. BP-PID 控制器的整体架构如图 3 所示.




图 3 BP 神经网络 PID 控制器结构

Fig. 3 Structure of BP neural network PID controller

3.1 增量式 PID 控制算法

传统 PID 控制器按照偏差的比例、积分和微分对系统进行控制, 控制过程如图 4 所示.




图 4 传统 PID 控制器控制流程

Fig. 4 Traditional PID controller control flow

在实际控制过程中, 为了降低累积误差的影响, 通常采用增量式 PID 控制算法进行控制. 增量式 PID 控制算法输出的是控制量增量, 即在上一次控制量的基础上需要增加或减少的控制量^[12],


其表达式如下.

$$\Delta u(k) = k_p [e(k) - e(k-1)] + k_i e(k) + k_d [e(k) - 2e(k-1) + e(k-2)] \quad (4)$$

式中, $\Delta u(k)$ 为控制量增量; $e(t)$ 为偏差信号; k_p 为比例系数; k_i 为积分作用参数; k_d 为微分作用参数. $e(k) = r(k) - y(k)$, $r(k)$ 为系统设定值, $y(k)$ 为当前控制对象状态值. 由增量式 PID 控制算法可以看出, 一旦确定出 k_p 、 k_i 、 k_d 三个控制参数, 利用前后三次采样值的偏差就可以计算出控制量增量, 避免了误差的累积.

3.2 BP 神经网络

BP 神经网络包括输入层、隐藏层和输出层三大部分, 网络中每一层的输出都是下一层的输入, 其层级结构如图 5 所示.



输入层 隐藏层 输出层

图 5 BP 神经网络结构

Fig. 5 Structure of BP neural network

其中, $X = [x_1, x_2, \dots, x_n]$ 组成输入层, 中间层为隐藏层, 最后一层为输出层, 负责计算输出 $Y = [y_1, y_2, \dots, y_m]$. 对于上述模型, 隐藏层结果和最终输出可由以下式表示.

$$a_i^{(l+1)} = g\left(\sum_{j=0} \theta_{ij}^l x_j\right) \quad (5)$$

$$y_m = g\left(\sum_{j=0} \theta_{ij}^l a_j\right) \quad (6)$$

式中, $a_i^{(l+1)}$ 代表第 $l+1$ 层的第 i 个激活单元; y_m 代表系统的第 m 个输出; $\theta_{ij}^{(l)}$ 代表从第 l 层映射到第 $l+1$ 层的权重; 函数 $g(x)$ 代表对计算结果进行非线性映射.

网络采用反向传播算法更新参数. 首先计算出 BP 神经网络的损失函数 $J(\Theta)$, 再逐层反向求出 $J(\Theta)$ 对所有参数的偏导数, 利用梯度下降算法更新网络参数. 输出层参数更新算法过程如下式所示.

$$\frac{\partial}{\partial \theta_{ij}^{(l)}} J(\theta) = \frac{\partial J(\theta)}{\partial y_i} \frac{\partial y_i}{\partial net_i^l} \frac{\partial net_i^l}{\partial \theta_{ij}^{(l)}} \quad (7)$$

$$net_i^l = \sum_{j=0} \theta_{ij}^{(l)} a_j \quad (8)$$

$$\theta_{ij}^{(l)} = \theta_{ij}^{(l)} - \alpha \frac{\partial}{\partial \theta_{ij}^{(l)}} J(\theta) \quad (9)$$

式中, $J(\Theta)$ 代表 BP 神经网络的损失函数; y_i 为网络输出; α 为学习速率. 隐含层参数更新继续向前求偏导数. 所有参数更新完后便进行下一次前向传播, 直至损失值达到预期效果.

4 算法改进

传统的 BP 神经网络的权重初始值是按照经验随机选取的, 这种方法会导致网络的收敛速度和最终结果都存在较大程度的不稳定性. 遗传算法具有很好的全局寻优性, 利用遗传算法可以快速地搜索出 BP 神经网络的最佳初始权重, 从而加快网络的训练过程^[13-14]. 但同时遗传算法也存在容易陷入局部最优解, 稳定性差等缺点. 因此本文提出一种改进的遗传算法, 对初始种群的生成过程和交叉过程进行了优化, 提高了算法的收敛速度和稳定性.

4.1 遗传算法

遗传算法是模拟生物进化论和遗传机理而形成的一种随机搜索最优解的方法, 它把问题存在的所有可能解视作自然界的生物种群, 种群中的所有个体按照设定方法进行编码, 经过选择、交叉和变异操作后, 利用适应度函数评价个体的优良程度, 淘汰适应度较差的个体, 这样反复循环, 直到结果满足条件^[15]. 与其他传统优化算法相比, 遗传算法具有较好的收敛性和全局搜索能力, 计算时间少, 鲁棒性高. 虽然遗传算法在许多领域中都有成功的应用, 但其自身也存在着较多的缺陷, 比如局部搜索能力差, 交叉与变异算子具有双重性, 并且随着迭代次数的增多, 种群多样性也在随之减少, 容易使结果陷入局部最优解.

4.2 遗传算法优化

为了确定 BP 神经网络的初始参数, 传统遗传算法从随机初始化的数据中获取初始种群. 由于初始种群范围较大, 个体之间并无任何联系, 导致寻优过程收敛速度较慢. 在原有算法基础上, 本文提出一种新的初始种群获取方法.

首先, 在解空间内随机生成一定规模的 M 个个体, 按照适应度函数取值搜索出得分最优的若干子 N 个个体组成新的种群, 称其为初始优胜个体种群. 适应度函数可由以下式表示.

$$F = k \left(\sum_{i=1}^n \text{abs}(y_i - o_i) \right) \quad (10)$$

式中, n 为网络输出的节点数; y_i 为 BP 神经网络第 i 个节点的期望输出; o_i 为第 i 个节点的预测输出; k 为系数. F 越小, 个体越优.

以每一个初始优胜个体为中心, 在每个个体的周围产生新的个体, 从而得到若干个优胜种群. 这一过程可以用下式表示.

$$a_{nm} = a_{ij} + \varepsilon \omega_{ij} \quad (11)$$

$$\omega_{ij} \sim U[a, b] \quad (12)$$

式中, a_{ij} 表示优胜个体种群中第 i 个个体的第 j 个基因; a_{nm} 表示以 a_{ij} 为中心生成的新个体基因; ω_{ij} 服从 (a, b) 之间的均匀分布; ε 为系数.

传统遗传算法交叉、变异过程是在种群中所有个体中进行的, 为了减小算法中交叉、变异算子的双重性, 本文提出不同优胜种群的个体之间进行交叉与变异, 将每一个优胜种群按照平均适应度值进行排序, 适应度值越优的种群, 与其他种群进行交叉与变异的概率越大. 该过程可由下式表示.

$$f_i = \frac{k}{F_i} \quad (13)$$

$$f_{\text{avg}}^k = \frac{\sum_{i=1}^K f_i}{K} \quad (14)$$

$$p_k = \frac{f_{\text{avg}}^k}{\sum_{k=1}^N f_{\text{avg}}^k} \quad (15)$$

式中, F_i 为个体 i 的适应度值; K 为优胜种群中个体数目; N 为优胜种群数目; p_k 为最终优胜种群 k 被选中的概率.

种群之间按照概率大小互相选择, 选中的种群之间再完成个体的交叉、变异操作, 产生新的个体. 上述过程完成后, 再对新种群中所有个体按照适应度值重新排序、分组, 重复上述过程, 直至最终产生最优个体. 算法步骤如下. (1) 随机确定若干个符合要求的个体; (2) 取前 N 个个体组成初始优胜个体种群; (3) 分别以每一个个体为中心产生新的 K 个个体, 组成 N 个优胜种群; (4) 按照每一个优胜种群的平均适应度 f_{avg} 进行排序, 排序靠前的种群按照轮盘赌法从其余种群中进行选择; (5) 互相选中的种群个体之间进行交叉、变异操作, 产生新的个体; (6) 新生成的所有个体按照适应度值重新排序、分组, 返回步骤(4)继续进行迭代优化, 直至产生最优个体.

4.3 改进 GA-BP-PID 控制器设计

在原有 BP-PID 控制器的基础上, 利用本文提出的改进的遗传算法初始化 BP 神经网络的权重初始值, 加速网络的训练过程, 最终构建的改进 GA-BP-PID 控制器结构如图 6 所示, 算法流程如图 7 所示.




图 6 改进 GA-BP-PID 控制器结构

Fig. 6 Structure of improved GA-BP0-PID controller




图 8 气体浓度控制实验中 BP 神经网络结构

Fig. 8 BP neural network structure in gas concentration control experiment

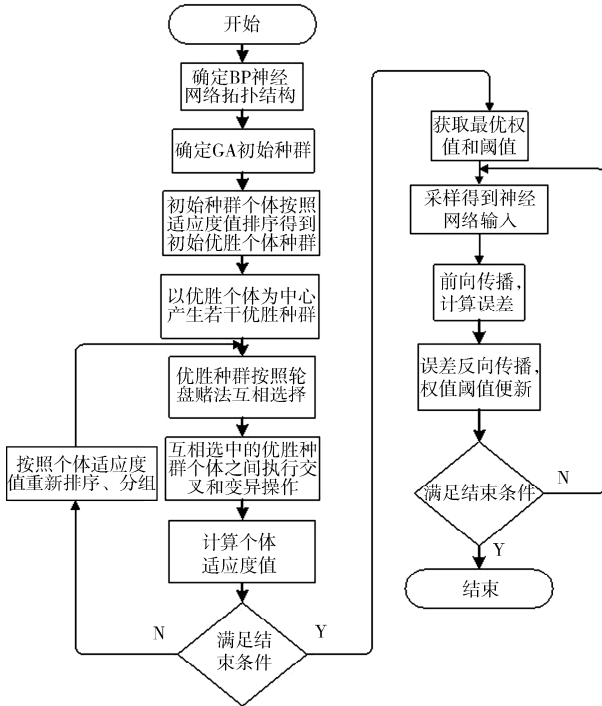


图 7 控制器算法流程

Fig. 7 Controller algorithm flow

5 应用与仿真

将传统 BP-PID 控制器与本文为提出的改进 GA-BP-PID 控制器分别应用于缺氧实验的气体控制中, 并利用 MATLAB 进行仿真分析, 比较两种方法的控制性能。

5.1 参数设置

对于传统 BP-PID 控制器, 设定 $r(k) = 11$, 采样时间 $t_s = 1_s$, 学习率 $\alpha = 0.2$, 惯性因子 $\omega = 0.05$, 网络权重初始值取 $[-1, 1]$ 之间的随机数。网络采用一层输入层、一层隐含层和一层输出层的三层网络架构, 利用试凑法确定隐含层节点数 $Q = 5$, $x = [r(k), y(k), e(k)]$ 作为网络的输入, 每层均添加偏置单元, $y = [k_p, k_i, k_d]$ 对应系统的输出, 网络结构如图 8 所示。

由于隐含层神经元的激活函数 sigmoid 函数将输出映射到 $[0, 1]$ 之间, 但实际 PID 控制器的三个参数需要在更大的范围进行调整^[16], 因此设置数组 $M = [m_1, m_2, m_3]$ 作为网络的输出增益。实验证明, 当 M 取值不同时, 系统的性能指标也有所不同。实验结果如下表所示, 综合考虑系统的各项性能指标, 选取输出增益 $M = [10, 1, 10]$ 。

表 1 m_2, m_3 不变 m_1 取不同值系统性能指标

Tab. 1 m_2, m_3 constant m_1 take different system performance indexes

| 参数取值 | A=5 | A=8 | A=10 | A=20 | A=30 | A=40 |
|---------|--------|--------|--------|--------|--------|--------|
| 上升时间/s | 57 | 59 | 66 | 151 | 206 | 266 |
| 最大超调量/% | 7.42 | 3.63 | 0.83 | 0 | 0 | 0 |
| 稳态误差 | 0.0002 | 0.0002 | 0.0002 | 0.0007 | 0.0031 | 0.0108 |

表 2 m_1, m_3 不变而 m_2 取不同值时系统性能指标

Tab. 2 m_1, m_3 constant m_2 take different system performance indexes

| 参数取值 | B=0.5 | B=0.8 | B=1 | B=1.2 | B=1.5 | B=2 |
|---------|--------|--------|--------|--------|--------|--------|
| 上升时间/s | 147 | 116 | 98 | 68 | 60 | 58 |
| 最大超调量/% | 0 | 0 | 0 | 0.51 | 1.34 | 2.10 |
| 稳态误差 | 0.0009 | 0.0005 | 0.0003 | 0.0002 | 0.0001 | 0.0001 |

表 3 m_1, m_2 不变而 m_3 取不同值时系统性能指标

Tab. 3 m_1, m_2 constant m_3 take different system performance indexes

| 参数取值 | C=5 | C=8 | C=10 | C=20 | C=30 | C=40 |
|---------|--------|--------|--------|--------|--------|--------|
| 上升时间/s | 146 | 116 | 82 | 65 | 60 | 58 |
| 最大超调量/% | 0 | 0 | 0 | 1.02 | 2.21 | 3.43 |
| 稳态误差 | 0.0007 | 0.0004 | 0.0001 | 0.0009 | 0.0017 | 0.0020 |

对于改进 GA-BP-PID 控制器, 上述 BP 神经网络设置不变, 利用改进的遗传算法寻找最优的权值和阈值。设定算法交叉概率 $p_c = 0.4$, 变异概率 $p_m = 0.2$, 迭代次数 $N_{iter} = 50$, 最终将得到的最优个

体作为 BP 神经网络的权重初始值.

5.2 仿真结果

按照上述设置的参数进行仿真实验,图 9 和图 10 为传统遗传算法与本文的改进算法在优化过程中最优个体适应度值曲线与平均适应度值曲线.图 11 和图 12 为传统 BP-PID 控制器与改进 GA-BP-PID 控制器控制效果曲线和控制误差曲线.




图 9 遗传算法最佳适应度曲线

Fig. 9 Optimal fitness curve of genetic algorithm




图 10 遗传算法平均适应度曲线

Fig. 10 Average fitness curve of genetic algorithm

由图 9 可以看出,与传统算法相比,改进的遗传算法具有更快的收敛速度和更少的迭代次数,并且最优个体适应度值更优.由图 10 可以看出,传统遗传算法交叉、变异算子的双重性,产生了适应度值较差的新个体,使得平均适应度并不是持续下降,而改进的遗传算法由于采用了优胜种群间的相互选择,因此具有更好的稳定性.

由图 11 和图 12 可以看出,与图 2 原始方法中不断振荡的输出相比,上述两种方法的输出都大幅度地改善了振荡情况,降低了最大超调量,取得了更好的控制效果.并且与传统的 BP-PID 控制器相比,改进 GA-BP-PID 控制器实现了无静差、无

超调量,具有更快的响应速度和更小的控制误差.




图 11 控制效果曲线图

Fig. 11 Control effect curve




图 12 控制误差曲线图

Fig. 12 Control error curve

将三种方法前 200 s 的实验结果进行量化处理得到三个控制器在实验过程中的各项性能指标对比结果.

表 4 仿真结果性能指标对比

Tab. 4 Comparison of performance indexes of simulation results

| 控制方式 | 传统控制 | BP-PID 控制 | 改进 GA-BP-PID 控制 |
|---------|------|-----------|-----------------|
| 最大超调量/% | 5.4 | 0.2 | 0 |
| 振荡次数 | 28 | 1 | 0 |
| 稳定时间/s | — | 95 | 62 |
| 稳态误差 | — | 0.000 1 | 0.000 1 |

由表 4 可见,在实验过程中,使用传统控制方式系统输出无法达到稳定值,最终结果会在稳定值附近不断振荡,因此无法确定系统稳定时间及其稳态误差,其控制效果较差,无法实现精准控制.其余两种控制器最终都将稳态误差控制在较小的范围之内,但与传统的 BP-PID 控制器相比,改进 GA-BP-PID 控制器具有更快的上升时间,并且实现了

零超调量,控制过程中没有出现振荡情况,系统稳定时间相较于前者有了大幅度的提升.由此可见,在气体浓度控制过程中,本文提出的基于改进的遗传算法优化的BP神经网络PID控制器能够取得更好的控制效果.

6 结 论

本文提出了一种改进的BP神经网络PID控制器,在原有BP神经网络PID控制器的基础上,利用改进的遗传算法寻找神经网络的最优初始权重值,实现对PID控制参数的有效整定.将控制器运用到气体浓度的控制过程中,结果表明,本文所提出的改进的遗传算法具有更优的适应度曲线和更好的稳定性,同时由于控制器合理地确定了神经网络的权重初始值,使得系统能够更快地到达稳定状态,具有更小的控制误差和更优的控制性能,能实现实验中气体浓度的准确控制,从而完成实验体的准确造模,对后续相关研究的开展具有重要的意义.

参考文献:

- [1] 李桂梅,曾喆昭.一种基于神经网络算法的非线性PID控制器[J].中南大学学报:自然科学版,2010,41:1865.
- [2] Fan J Z, Zhong J, Zhao J, *et al.* BP neural network tuned PID controller for position tracking of a pneumatic artificial muscle. [J]. Technol Health Care, 2015, 23(s2): S231.
- [3] Zheng M D, Wu X X, Qin W, *et al.* Application of PID control based on BP-NN for marine generator excitation system[C]// IEEE Power Engineering & Automation Conference. Wuhan: IEEE, 2012.
- [4] Ji X W, Wang J, Zhao Y Q, *et al.* Path planning and tracking for vehicle parallel parking based on preview BP neural network PID controller[J].天津大学学报:英文版,2015(3):199.
- [5] Borchert B, Gunther M. Single tank liquid level control based on improved BP neural network PID control algorithm [C] //Proceedings of the 2013 IEEE Third International Conference on Information Science and Technology. Yangzhou: IEEE, 2013.
- [6] Han L, Zhang Z Y. The application of immune genetic algorithm in main steam temperature of PID control of BP network [J]. Elsevier B V, 2012, 24: 80.
- [7] 袁建平,施一萍,蒋宇,等.改进的BP神经网络PID控制器在温室环境控制中的研究[J].电子测量技术,2019,42:19.
- [8] 杨帆.急性缺氧大鼠水代谢紊乱的机制研究[D].重庆:第三军医大学,2017.
- [9] 王春晨,徐新喜,陈锋,等.基于BP神经网络的PID控制器在气体混合配比系统中的应用[J].军事医学,2017,41:118.
- [10] 王青山,梁得亮,杜锦华.交流稳压电源的改进神经网络PID控制[J].电机与控制学报,2017,21:1.
- [11] 李万莉,李瑞.BP神经网络PID控制在电液比例加载系统中的应用[J].机电一体化,2017,23:35.
- [12] Li X G, Zhang S Y, Yang S C. Design of asynchronous motors energy saving controller base on BP-NN-PID control [C]// International Conference on Mechatronic Science. Jilin: IEEE, 2011.
- [13] 刘浩然,赵翠香,李轩,等.一种基于改进遗传算法的神经网络优化算法研究[J].仪器仪表学报,2016,37:1573.
- [14] 傅晓云,方旭,杨钢,等.基于遗传算法的PID控制器设计及仿真[J].华中科技大学学报:自然科学版,2012,40:1.
- [15] 周原令,胡晓兵,霍云亮,等.双基球扁发射药生产线的改进遗传排产算法研究[J].四川大学学报:自然科学版,2019,56:627.
- [16] 徐胜男,周祖德,艾青松,等.基于粒子群优化的神经网络自适应控制算法[J].中国机械工程,2012,23:2732.

引用本文格式:

- 中文:李航,杜璠,胡晓兵,等.改进的BP神经网络PID控制器在气体浓度控制中的研究[J].四川大学学报:自然科学版,2020,57:1103.
- 英文:Li H, Du F, Hu X B, *et al.* Research on improved BP neural network PID controller in gas concentration control [J]. J Sichuan Univ: Nat Sci Ed, 2020, 57: 1103.