

基于 BP-PID 改进的噪声稳健控制方法

邹晶晶[†]

(广东科学技术职业学院, 广东 珠海 519000)

摘 要:针对 BP-PID 控制器的控制性能受参数初值影响大、易陷入局部极值、对噪声敏感,且低信噪比条件下控制稳定性差等问题,提出了一种基于改进果蝇优化算法(Improved Fruit Fly Optimization Algorithm, IFOA)和径向基神经网络-卡尔曼滤波(Radial Basis Function Network-Kalman Filter, RBF-KF)的噪声稳健 BP-PID 控制方法。首先提出了一种 IFOA 随机搜索算法对 BP-PID 初值进行全局寻优,自动获得全局最优解,提升系统控制精度。然后利用所提 RBF-KF 对观测数据进行滤波平滑,降低量测和控制噪声对系统的影响,提升低信噪比条件下的控制稳定性。基于某智能车车速控制真实数据开展试验,结果表明,所提方法相对于传统方法控制精度提升超过 50%,控制稳定性提升超过 60%,并且在低信噪比条件下优势更加明显,更适合实际工程应用场景。

关键词:BP-PID; 车速控制; 果蝇优化算法; 噪声稳健; 卡尔曼滤波

中图分类号:TP18

文献标识码:A

Improved Noise Robust Control Method Based on BP-PID

ZOU Jingjing[†]

(Guangdong Polytechnic of Science and Technology, Zhuhai, Guangdong 519000, China)

Abstract: The control performance of the BP-PID controller is greatly affected by the initial parameter values, easily trapped in local extremum, sensitive to noise, and the control stability is poor under low signal-to-noise ratio conditions. Propose a noise robust BP-PID control method based on the improved fruit fly optimization algorithm (IFOA) and radial basis function network-Kalman filter (RBF-KF). Firstly, propose an IFOA random search algorithm to globally optimize the initial value of BP-PID, automatically obtain the global optimal solution, and improve the system control accuracy. Then, the proposed RBF-KF is used to filter and smooth the observed data, reduce the impact of measurement and control noise on the system, and improve control stability under low signal-to-noise ratio conditions. Based on real data of a certain intelligent vehicle's speed control, experiments are conducted. The results show that the proposed method improves control accuracy by more than 50% and control stability by more than 60% compared to traditional methods, and the advantages are more obvious under low signal-to-noise ratio conditions, more suitable for practical engineering application scenarios.

Key words: BP-PID; speed control; fruit fly optimization algorithm; noise robust; Kalman filter

BP-PID 控制器利用 BP 神经网络对 PID 控制器的比例(Proportional, P),积分(Integral, I)和

微分(Derivative, D)参数进行在线实时整定^[1-2],提升了传统 PID 控制器对非平稳,非线性和时变

系统的适应能力和控制性能,被广泛应用于机械制造,化工冶金,车速控制等领域^[3-5]。

然而由于 BP-PID 控制器在求解过程中采用梯度下降法,其收敛性能受网络初值的选取影响较大,初值选取不当会导致算法收敛速度下降,陷入局部最优解等问题^[6-7]。针对该问题,众多学者开展了大量的研究,其中最为经典的方法是将随机优化算法引入 BP-PID 控制器,利用优化算法的参数寻优能力对 BP-PID 初值进行全局寻优,提升控制性能^[8-10]。文献[11]提出一种改进的遗传算法(Genetic Algorithm, GA)对 BP-PID 控制器的初值进行全局寻优,通过加速网络的训练过程,提升参数整定的实时性,采用气体浓度控制试验验证了该方法的有效性;文献[12]针对磁悬浮列车单点混合磁悬浮球的控制问题,将粒子群(Particle Swarm Optimization, PSO)算法引入 BP-PID 控制器,有效解决了 BP-PID 收敛速度慢,对初值敏感的问题;文献[13]提出一种果蝇优化算法(Fruit Fly Optimization Algorithm, FOA)优化的 BP-PID 控制器,并通过典型测试函数验证了所提方法的控制性能。上述研究虽然在一定程度上解决了 BP-PID 参数整定问题,但是并没有考虑到真实控制过程中普遍存在的噪声和干扰等因素,在低信噪比条件下该类方法的控制稳定性会出现大幅下降,难以适应众多控制系统所处的复杂电磁环境^[14]。

针对 BP-PID 控制器初值优化以及低信噪比条件下的控制稳定性问题,提出了一种基于改进果蝇优化算法(Improved Fruit Flying Optimization Algorithm, IFOA)和径向基神经网络卡尔曼滤波(Radial Basis Function Network-Kalman Filter, RBF-KF)优化的 BP-PID 控制器,利用 IFOA 对网络初值进行全局寻优,相对于 FOA,PSO 和 GA 等优化算法,IFOA 具有更均衡的全局和局部搜索能力,从而可以获得更快的收敛速度和更高的控制精度;同时考虑到复杂电磁环境引起的低信噪比问题,还提出了使用 RBF-KF 算法对观测数据进行滤波平滑,有效降低噪声分量的影响并提升控制稳定性。最后采用某智能车车速控制系统真实数据开展试验,结果表明所提方法相对于 FOA-BP-PID,GA-BP-PID 和 PSO-BP-PID 三种控制器具有更高的控制精度和控制稳定性,并且在低信噪比条件下优势更加明显。

1 BP-PID 控制器

BP-PID 控制器系统架构如图 1 所示,包括传

统 PID 控制器和 BP 神经网络两部分。传统 PID 控制器的输入为被控对象预期值与实际输出值之间的偏差,通过将偏差的比例(k_p),积分(k_i)和微分(k_d)进行线性组合作为控制量对被控对象进行反馈控制。要想获得理想的控制效果,关键在于调整好 k_p , k_i 和 k_d 之间的相对关系,然而在实际应用中,系统控制性能与 k_p , k_i 和 k_d 之间往往并非简单的线性关系,且在控制过程中是动态调整的,因此传统基于经验预设的参数整定方法难以获得满意的控制性能。




图 1 BP-PID 控制器结构示意图

BP 神经网络具有任意非线性函数表达和自适应学习能力,将其与 PID 联合构建的 BP-PID 控制器通过对系统状态的动态学习能够从 k_p , k_i 和 k_d 的无穷非线性组合中自动得到最优控制性能。图 2 给出了 BP-PID 控制器利的网络结构图,由输入层,隐含层和输出层构成,其中输出层神经元即为 k_p , k_i 和 k_d 三个参数,输入层神经元 $x_j^{(1)}$ 和神经元个数 M 由具体问题决定,上标 (1) 表示网络第 1 层,即输入层。隐含层神经元个数 Q ,由输入和输出神经元个数共同决定。隐含层的输入 $net_i^{(2)}$, $i = 1, 2, \dots, Q$ 和输出 $O_i^{(2)}$ 之间的关系可以表示为:

$$\begin{cases} net_i^{(2)}(k) = \sum_{j=1}^M \omega_{ij}^{(2)} x_j^{(1)} \\ O_i^{(2)}(k) = f(net_i^{(2)}(k)), i = 1, 2, \dots, Q \end{cases} \quad (1)$$

式中, $\omega_{ij}^{(2)}$ 为输入层到隐含层的映射系数,上标 (2) 表示网络第 2 层,即隐含层。 $f(\cdot)$ 为神经元转移函数,通常采用双极性 Sigmoid 函数形式。

进一步可以计算得到网络输出层对应的输入和输出分别为:

$$\begin{cases} net_l^{(3)}(k) = \sum_{i=1}^Q \omega_{li}^{(3)} O_i^{(2)} \\ O_1^{(3)}(k) = k_p(k) = g(net_1^{(3)}(k)) \\ O_2^{(3)}(k) = k_i(k) = g(net_2^{(3)}(k)) \\ O_3^{(3)}(k) = k_d(k) = g(net_3^{(3)}(k)) \end{cases} \quad (2)$$

式中, $\omega_{li}^{(3)}$ 为隐含层到输出层的映射系数,上标 (3) 表示网络第 3 层,即输出层。 $k_p(k)$, $k_i(k)$ 和 $k_d(k)$ 分别为当前第 k 个状态下对应系统的比例,

积分和微分控制系数。 $g(\cdot)$ 为非负的 Sigmoid 函数。

BP-PID 控制器通常将控制器的实际输出 $v(k)$ 与预期输出 $y(k)$ 之间误差的平方和 $e^2(k)$ 作为待优化的性能指标函数,即:

$$e^2(k) = \frac{1}{2} (v(k) - y(k))^2 \tag{3}$$

采用梯度下降法对式(3)求解,可以得到网络映射系数 $w_{ij}^{(2)}$ 和 $w_{li}^{(3)}$ 的迭代公式如下:

$$\begin{cases} \Delta w_{li}^{(3)}(k) = \alpha_1 \Delta w_{li}^{(3)}(k-1) + \eta \delta_l^{(3)} O_i^{(2)}(k) \\ \Delta w_{ij}^{(2)}(k) = \alpha_2 \Delta w_{ij}^{(2)}(k-1) + \eta \delta_i^{(2)} O_j^{(1)}(k) \\ \delta_l^{(3)} = e(k) \operatorname{sgn}\left(\frac{\partial y(k)}{\partial u(k)}\right) \frac{\partial \Delta u(k)}{\partial O_l^{(3)}(k)} g'(\operatorname{net}_l^{(3)}(k)) \\ \delta_i^{(2)} = f'(\operatorname{net}_i^{(2)}(k)) \sum_{l=1}^3 \delta_l^{(3)} w_{li}^{(3)}(k) \end{cases} \tag{4}$$

式中, $g'(\cdot) = g(x)[1 - g(x)]$, $f'(\cdot) = [1 - f^2(x)]/2$, α_1 和 α_2 为预设的动量系数, η 为学习率参数。BP-PID 系统通过式(1)和式(2)所示正向传播与式(4)所示反向传播相结合的方式对网络映射参数实时更新,从而得到最优的控制系数 $k_p(k)$, $k_i(k)$ 和 $k_d(k)$ 。




图 2 三层 BP 神经网络结构

2 模型改进

BP-PID 采用梯度下降法进行模型计算,网络初值的选取对最终的性能影响很大,例如在图 3 所示优化问题中,存在唯一的全局最优解 B,如果在开始迭代时网络初值选取在 c 点或 d 点,则算法最终会收敛于全局最优解 B,但是如果网络初值选取在 a, b, e, f 点处,则算法会最终收敛于 A 点或 C 点等局部极值点,无法获得系统希望的控制性能。同时 BP-PID 模型没有考虑实际工程应用中普遍存在的测量噪声和控制噪声的影响,在低信噪比条件下控制性能会出现明显下降。针对上述问题,本文提出 IFOA 和 RBF-KF 方法对 BP-PID 控制器

进行优化改进,以提升系统控制性能和噪声稳健性。




图 3 梯度下降法示意

2.1 改进果蝇优化算法

果蝇优化算法^[15]是一种用于描述自然界果蝇觅食过程的群体智能优化算法,具有原理简单,收敛速度快,全局搜索能力强和鲁棒性高的优点,然而由于传统 FOA 采用固定搜索步长,在迭代初期能够保证较快的收敛速度,当接近最优解时由于局部搜索能力不足,会导致结果不稳定和算法易早熟等问题的出现^[16],同时传统 FOA 是在二维平面进行模型优化,根据第 1 小节介绍可知,BP-PID 控制器初值设置是一个三维空间 $[k_p(k), k_i(k)$ 和 $k_d(k)]$ 寻优问题,因此本文从以下两个方面对 FOA 算法进行改进提升:1)采用自适应搜索步长的方式提升 FOA 算法的局部寻优能力;2)将其扩展至三维空间进行搜索,以匹配 BP-PID 优化需求。

(1) 搜索步长改进

果蝇觅食过程中,通常开始时距离食物较远,因而应采用较大搜索步长以提升搜索效率,随着搜索过程的推移,果蝇群体逐渐接近食物,此时应采用较小的搜索步长从而提升搜索精度。针对该问题,本文提出通过将搜索步长与迭代次数关联,使搜索步长具有自适应变化能力:

$$R(i) = R(i-1) \left(1 - \frac{i}{n}\right)^3 \operatorname{sgn}(r - a) \tag{5}$$

式中, $R(i)$ 和 $R(i-1)$ 分别为第 i 次和第 $(i-1)$ 次的搜索步长, n 为最大迭代次数, $\operatorname{sgn}(\cdot)$ 为符号函数, r 为 $(0, 1)$ 范围内均匀取值的随机数, a 为可调参数。从式(5)可以看出,改进后的搜索方式能够根据当前搜索进度自动调整搜索精度,同时符号函数的引入使算法具备回退搜索能力,通过调整 a 的取值能够有效避免算法陷入局部最优解,本文经过多次试验得到 a 的最优取值为 0.5。

(2) 三维空间扩展

传统 FOA 算法是一种二维空间优化方法,无法适应三维空间优化问题,因此为了匹配 BP-PID 需求,需要将其扩展至三维空间,空间扩展过程如

图 4 所示。

空间的扩展意味着果蝇个体需要进行的飞行距离和飞行范围增大,更有利于获得全局最优解。在算法实现过程中,需要对传统 FOA 算法的迭代步骤和适应度函数进行对应修改,具体算法实现见第 3 小节算法实现步骤。




图 4 二维空间向三维空间扩展

2.2 径向基神经网络-卡尔曼滤波(RBF-KF)

上述 IFOA-BP-PID 控制系统在控制量采集及控制过程中,不可避免地会引入测量和控制噪声,导致控制精度下降和稳态延时等问题,因此需要考虑对观测信号进行实时滤波,提升系统控制稳定性。卡尔曼滤波^[17]是最小均方误差准则下的一种最优滤波器,只需要前一个采样时间的估计值和当前状态的观测值即可获得当前采样时刻的最优估计值,具有存储和运算量小,实时性高的特点。其递归过程主要由以下 5 个步骤构成^[18]:

①状态预测方程:

$$\hat{x}_k^* = A \hat{x}_{k-1} - B u_{k-1} \quad (11)$$

②状态预测协方差矩阵更新方程:

$$P_k^* = A P_{k-1}^* A^T + Q \quad (12)$$

③滤波增益方程

$$K_k = P_k^* C^T (C P_k^* C^T + R)^{-1} \quad (13)$$

④状态估计方程:

$$\tilde{x}_k = \hat{x}_k^* - K_k (y_k - C \hat{x}_k^*) \quad (14)$$

⑤状态估计均方差:

$$P_k = (I - K_k C) P_k^* \quad (15)$$

在上面的递归推导过程中,上标带“~”和“*”的变量表示状态预测值,仅带“~”的变量为状态估计值, $\tilde{x}_k^*$ 表示第 k 时刻的状态预测, $\tilde{x}_{k-1}$ 为 $k-1$ 时刻的状态估计值, u_{k-1} 表示 $k-1$ 时刻的输入控制变量, y_k 为 k 时刻的观测值, P_k^* 为 k 时刻状态估计误差的协方差矩阵, A 为状态转移矩阵, B 为控制矩阵, C 为观测矩阵, Q 和 R 分别为系统噪声协方差矩阵和观测噪声协方差矩阵, K_k 为 k 时刻的滤波增益。

KF 滤波性能取决于状态预测值 $\tilde{x}_k^*$ 和估计误差协方差矩阵 P_k^* 的初值 $\tilde{x}_0^*$, P_0^* , 这在实际工程实践中很难满足,因此 KF 使用过程中通常会存在较大滤波误差。针对这一问题,本文提出 RBF-KF 方法,通过在 KF 递归过程中引入 RBF 神经网络,将对滤波性能影响较大的预测误差 $u_k = \tilde{x}_k^* - \tilde{x}_{k-1}$, 滤波增益 K_k 和新息 $\delta_k = y_k - y_{k-1}$ 作为 RBF 神经网络输入,构建网络结构对 KF 滤波差进行修正,并将修正后的滤波误差补偿给滤波估计值,从而获得新的滤波估计值,具体实现框图如图 5 所示。




图 5 RBF 神经网络优化卡尔曼滤波模型

3 应用验证与结果分析

3.1 仿真架构

为了验证所提方法的控制性能,将其应用到某智能车车速控制系统中。智能车运行过程中会面临各种复杂突变的交通状况,其车速控制是一种典型的时变、非线性和非平稳随机过程。

所用智能车控制系统逻辑框图如图 6 所示,主要包含 BP-PID 控制器,IFOA 优化模型,车辆动力学模型和 RBF-KF 四部分。其中 BP-PID 采用 3-6-3 的网络架构,输入神经元分别为期望车速 $y(k)$ 、输出车速 $v(k)$ 以及期望车速与输出车速之间的差值 $e(k)$; IFOA 种群数量设置为 20,最大迭代次数设置为 100,果蝇群体的初始位置设置为 $[0, 0, 0]$ 。




图 6 系统仿真架构

系统输入的期望车速 $y(k)$ 为某智能车系统在远离市区的某郊区道路采集到的 12 分钟实测车速，如图 7 所示，可以看出测试过程中包括了起步，停止，平稳行驶，反复加速和反复减速等多种行为，较为真实地模拟了不同路况条件下的真实行驶情况。





图 7 某实际路况智能车车速测试数据


3.2 IFOA 参数优化试验

利用 IFOA 对 BP-PID 网络初值 $w_{opt}^{(2)}, w_{opt}^{(3)}$ 和 η_{opt} 进行全局寻优过程中的收敛曲线如图 8 所示，同时为了对比，在图 8 中我们一并给出了在相同条件下分别采用 GA, PSO 和 FOA 三种优化算法进行参数寻优得到的收敛曲线。从图 8 所示结果可以看出，所提 IFOA 算法由于兼具全局和局部搜索能力，收敛速度明显优于 3 种对比方法，只需要约 7 次迭代即可获得最优网络初值为 $w_{opt}^{(2)} = 7.32$, $w_{opt}^{(3)} = 11.58$, $\eta_{opt} = 6.01$ ；而 GA 算法收敛速度在 4 种算法中是最慢的，需要接近 20 次迭代才达到收敛状态，收敛时，网络初值取值为 $w_{opt}^{(2)} = 7.31$, $w_{opt}^{(3)} = 11.55$, $\eta_{opt} = 6.01$ ；PSO 算法收敛速度略慢于 IFOA，需要 10 次迭代实现算法收敛，收敛时网络初值取值为 $w_{opt}^{(2)} = 7.08$, $w_{opt}^{(3)} = 10.33$, $\eta_{opt} = 6.01$ ；FOA 算法由于采用固定步长进行搜索，在算法后期曲线出现了明显的振荡，最终需要 15 次迭代达到收敛，


收敛时网络初值取值为 $w_{opt}^{(2)} = 7.47$, $w_{opt}^{(3)} = 10.62$, $\eta_{opt} = 9.16$ ，与另外三种方差取值存在较大差异，表明 FOA 算法收敛于局部最优解(可结合 3.3 小节试验结果进一步验证)。



(a) $w_{opt}^{(2)}$



(b) $w_{opt}^{(3)}$



(c) η_{opt}

图 8 不同算法迭代过程中参数变化曲线


3.3 控制精度和稳定性

对于智能车车速控制的具体应用,车辆行驶过程中的安全性和稳定性(平稳性)是至关重要的,将其映射到控制系统,可以利用速度控制偏差 $e(k)$ 的均值 e_{mean} 和方差 e_{std} 进行评估,均值 e_{mean} 越小表明控制精度越高,即安全性越高,方差 e_{std} 越小表明系统控制越稳定,车速控制越平稳。 e_{mean} 和 e_{std} 的定义如下:


$$\begin{cases} e_{\text{mean}} = \frac{1}{K} \sum_{k=1}^K e(k) \\ e_{\text{std}} = \frac{1}{K} \sum_{k=1}^K [e(k) - e_{\text{mean}}]^2 \end{cases} \quad (18)$$

图 9(a) 给出了利用所提方法(记为:IFOA-BP-PID)得到的速度控制结果,同时为了对比,图 9(a)中同步给出了在相同条件下分别采用 GA-BP-PID, PSO-BP-PID 和 FOA-BP-PID 三种控制算法进行试验得到的控制结果,为了便于观察对比,图 9(b)给出了图 9(a)的局部放大图(110 s~160 s 内数据)。图 9(c)给出了 4 种方法速度跟踪误差图,同样图 9(d)为图 9(c)的局部放大图(110 s~160 s 内数据)。


从图 9 所示结果可以看出,所提 IFOA-BP-PID 控制器得到的速度控制结果与实际车速最为接近,误差在 $[-0.3125, 0.3233]$ 范围内, GSA-BP-PID 控制器的控制精度仅次于 IFOA-BP-PID,误差在 $[-0.6719, 0.7603]$ 范围内, PSO-BP-PID 控制器的控制精度要明显低于以上两种控制器,误差在 $[-2.4587, 1.7433]$ 范围内,而 FOA-BP-PID 控制器的控制精度出现了较大偏差,误差范围处于 $[-9.5210, 12.4302]$ 内,这说明控制过程陷入了局部极值,与 3.2 小节分析一致。




(a) 三种算法速度跟踪结果



(b) 图(a)的局部放大



(c) 三种方法速度跟踪误差



(d) 图(c)的局部放大

图 9 四种控制器的速度控制结果

表 1 给出了 4 种控制器进行速度控制得到的控制偏差 $e(k)$ 的均值 e_{mean} 和方差 e_{std} ，可以看出，所提 IFOA-BP-PID 控制性能相对于 GSA-BP-PID 提升了 50% 以上，相对于 PSO-BP-PID 提升了一个数量级，远远优于 FOA-BP-PID，上述结果表明，所提方法在智能车速度控制应用中，能够获得最优的控制精度（安全性）和控制稳定度（平稳性）。

表 1 四种方法控制精度对比

	FOA-BP-PID	PSO-BP-PID	GSA-BP-PID	IFOA-BP-PID
e_{mean}	3.2529	1.4847	0.1966	0.0934
e_{std}	4.3297	1.5349	0.2762	0.1011




图 10 图 RBF-KF 滤波结果

3.4 噪声稳健性

为了进一步验证所提方法在受到噪声干扰时的控制性能，采用向实测数据中加入高斯白噪声的方式开展试验。图 10 中黑色“—○—”出了利用 MATLAB 自带的 awgn() 函数向图 7 所示数据中加入高斯白噪声得到信噪比水平为 0 dB 时的车速变化曲线，可以看出，噪声的引入使车速变化曲线出现了较为明显的波动，从而导致控制性能下降。图 10 中蓝色“—+—”给出了利用传统 KF 方法对其进行平滑滤波得到的结果，红色“—*—”给出了利用所提 RBF-KF 方法对其进行平滑滤波得到的结果，对比图 7 与图 10 可以看出，相对于传统 KF 方法，利用所提 RBF-KF 对含噪数据进行滤波后得到的速度曲线更加平滑，滤波后速度曲线变化与真实车速数据更加接近，噪声抑制效果更好。

图 11 给出了不同信噪比条件下利用所提 RBF-KF-IFOA-BP-PID，GA-BP-PID，PSO-BP-PID 和 FOA-BP-PID 四种方法进行速度控制得到的速度控制误差均值 e_{mean} 和方差 e_{std} ，同时为了对比，图 11 中给出了利用传统 KF 方法结合所提 IFOA-BP-PID 控制器得到的控制结果（记为：KF-IFOA-BP-PID）。可以看出，随着信噪比降低，5 种方法的控制性能都出现了不同程度的下降，其中所提 RBF-KF-IFOA-BP-PID 性能下降最少，并且在不同信噪比条件下均能获得最优的控制精度和控制稳定性，相对于其他方法具有更强的噪声稳健性。




图 11 不同信噪比条件下的控制结果

4 结 论

随着工业控制系统向非线性、非平稳和时变性方向快速发展,传统基于预设网络参数的 BP-PID 控制系统出现控制性能下降,容易受噪声影响等问题。提出了一种 RBF-KF-IFOA-BP-PID 噪声稳健控制算法,利用兼具全局和局部搜索能力的 IFOA 对 BP-PID 网络初值进行全局寻优提升系统控制性能,同时将 RFB-KF 引入控制系统中,对观测数据进行滤波平滑,抑制其中的测量和控制噪声,提升控制系统在低信噪比条件下的控制性能。基于智能车车速控制实例对所提方法的性能进行验证,结果表明,相对于传统方法,所提 RBF-KF-IFOA-BP-PID 具有控制精度高,实时性好和更优良的噪声稳健性,具有较好的应用前景。

参考文献

- [1] GAIN H, WEI P F, WEN W, et al. The lateral tracking control for the intelligent vehicle based on adaptive PID neural network[J]. *Sensors*, 2017, 17(6):1244—1252.
- [2] GUO J, LUO Y, LI K, et al. Adaptive dynamic surface longitudinal tracking control of autonomous vehicles[J]. *IET Intelligent Transport Systems*, 2019, 13(5):1272—1280.
- [3] 张忠艺, 徐冬梅. 基于 PID 的制造业多智能体系统一致性分析[J]. *制造业自动化*, 2021, 43(3):168—172.
- [4] NIE L Z, GUAN J Y, LU C H, et al. Longitudinal speed control of autonomous vehicle based on a self-adaptive PID of radial basis function neural network[J]. *IET Intelligent Transport Systems*, 2018, 12(6):485—494.
- [5] 范怡敏, 罗云飞, 魏春英. 基于自适应神经网络的无人机 PID 控制器研究[J]. *电子测量技术*, 2021, 44(9):163—167.
- [6] 王永鼎, 陈小锋. 基于 BP 神经网络 PID 控制的 AGV 调速系统仿真[J]. *制造业自动化*, 2021, 43(6):63—67.
- [7] 肖宜辉, 宋保业, 许林. 一种无刷直流电机模糊比例积分控制器的设计[J]. *科学技术与工程*, 2020, 20(19):7750—7755.
- [8] 李捷菲. 基于 BP 神经网络的 PID 控制系统研究与设计[D]. 长春:吉林大学, 2019.
- [9] 刘晓昂, 张佳琪, 王爽. 基于模糊比例积分微分算法的汽车半主动悬架振动分析[J]. *科学技术与工程*, 2021, 21(2):781—785.
- [10] 赵广元, 王超. 基于改进人群搜索算法的 PID 控制器参数优化[J]. *计算机仿真*, 2020, 37(8):302—306.
- [11] 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(6):1103—1109.
- [12] 彭月, 苏芷玄, 杨杰, 等. 基于 PSO-BP-PID 单点混合悬浮球控制算法研究[J]. *铁道科学与工程学报*, 2022, 19(6):1511—1520.
- [13] 凤丽雨, 王友卫, 韩琳琳, 等. 双重驱动的果蝇优化算及其在 PID 控制器中的应用[J]. *控制与决策*, 2021, 36(9):2225—2233.
- [14] 张继荣, 张天. 基于改进粒子群算法的 PID 控制参数优化[J]. *计算机工程与设计*, 2020, 41(4):1035—1040.
- [15] 弋佳东, 杨洁. 基于 IFOA-SA-BP 神经网络的雷达信号识别[J]. *系统工程与电子技术*, 2020, 42(12):2735—2741.
- [16] ZANDIEH M, TAVANA M, ALIKAR N, et al. A tuned hybrid intelligent fruit fly optimization algorithm for fuzzy rule generation and classification[J]. *Neural Computing Applications*, 2019, 31(3):873—885.
- [17] YAO G, GAO F, WAGN C, et al. Design and simulation based on Kalman filter fuzzy adaptive PID control for mold liquid level control system[C]//Control and Decision Conference, 2009, CCDC'09. IEEE:6105—6109.
- [18] 龚波, 周永华, 艾娇燕. 融合卡尔曼滤波的无人船航向神经网络控制[J]. *计算机工程与设计*, 2020, 41(8):2315—2320.