

基于分数阶PID控制器的多模型神经网络控制策略

唐军¹, 张皓^{2†}, 陈伟军³

(1. 宜宾职业技术学院电子信息与人工智能学院, 四川 宜宾 644000; 2. 雅安职业技术学院智能制造与信息工程学院, 四川 雅安 625100; 3. 岭南师范学院电子与电气工程学院, 广东 湛江 524048)

摘要: 由于分数阶PID相较于整数阶PID具有更多的参数自由度, 更广的控制范围, 以及更强的控制性能等优势, 本文提出一种基于分数阶PID的多模型神经网络控制器。将已整定好控制参数的多个分数阶PID控制器的输入输出数据进行采集, 并经过预处理后, 利用神经网络强大的学习能力和泛化能力进行多模型训练, 并将训练好的网络作为控制器。MATLAB仿真实验表明: 在进行多模型控制时, 该控制器的超调量为0, 最长调节时间、上升时间、延迟时间分别为430.99 s、259.50 s、90.76 s, 不仅兼具了多个分数阶PID的模型控制能力, 而且比每个分数阶PID控制器都具有更优越的性能指标。

关键词: 分数阶PID; 整数阶PID; 神经网络; 多模型

中图分类号: TP273+.3; TP273+.4

文献标识码: A

Multi-model Neural Network Control Strategy Based on Fractional-order PID Controller

TANG Jun¹, ZHANG Hao^{2†}, CHEN Weijun³

(1. School of Electronic Information and Artificial Intelligence, Yibin Vocational and Technical College, Yibin, Sichuan 644000, China; 2. School of Intelligent Manufacturing and Information Engineering, Ya'an Polytechnic College, Ya'an, Sichuan 625100, China;

3. School of Electronics and Electrical Engineering, Lingnan Normal University, Zhanjiang, Guangdong 524048, China)

Abstract: Since fractional-order PID has more parameter degrees of freedom, wider control range, and stronger control performance than integer-order PID, this paper proposes a multi-model neural network controller based on fractional-order PID. The input and output data of multiple fractional-order PID controllers with tuned control parameters are collected and preprocessed, and multi-model training is performed using the powerful learning and generalization capabilities of neural networks, and the trained network is used as the controller. MATLAB simulation experiments show that when performing multi-model control, the overshoot of the controller is 0, and the longest adjustment time, rise time and delay time are 430.99 s, 259.50 s and 90.76 s respectively. It not only has the model control capabilities of multiple fractional-order PIDs, but also has better performance indicators than each fractional-order PID controller.

Key words: fractional-order PID; integer-order PID; neural network; multi-model

整数阶比例积分微分(Integer Order Proportion Integral Differential, IOPID)算法, 具有原理

简单、结构清晰、易于实现等特点, 已成为目前工业控制中应用最广泛的控制器之一^[1-3]。但传统的

IOPID 由于其参数调节范围有限,控制器自由度偏低,控制范围相对较小,在控制具有纯滞后、非线性、时变性等复杂动态特性的被控对象时,往往会出现超调量较大、调节时间较长、鲁棒性较差等不太理想的控制效果^[4-8]。因此,为了改善上述问题^[4-8],有必要寻求更为先进的控制方法和技术。

近年来,将分数阶微积分理论与 IOPID 相结合形成的分数阶比例积分微分(Fractional Order Proportion Integral Differential, FOPID)算法,引起了越来越多的学者关注,并已成为当下控制领域研究的热点之一^[9-12]。相较于 IOPID 控制器, FOPID 增加了积分阶次和微分阶次两个控制参数,以其更加灵活的自由度和参数调节方式,使得控制系统具有更小的超调量、更短的调节时间、更低的稳态误差,以及更强的稳定性^[13-15]。

文献[16]为了减小机器人的运动误差,设计了基于 FOPID 的机器人控制系统,相较于 IOPID 控制系统,显著提升了系统稳定性。文献[17]针对永磁同步发电机控制系统,引入 FOPID 作为控制器,与 IOPID 控制器相比有效改善了发电机系统控制性能。文献[18]根据 Ziegler-Nichols 法整定 PID 参数的特点,改进了其整定规则,设计了 FOPID 控制器参数,其与依据传统整定规则的 FOPID 和 IOPID 相比,具有更好的综合性能指标。文献[19]利用遗传算法整定出最优 FOPID 控制器参数,以精确控制血压的自动调节。文献[20]利用粒子群优化算法整定出最优 FOPID 控制器参数,以精确控制阀门的开合程度。文献[16]~[20]均在离线状态下,依据不同方法整定出了适合各自控制系统的 FOPID 控制器参数,且都实现了较为满意的控制效果。但上述文献^[16-20]中的 FOPID 控制器均是针对具体的被控模型而整定的控制参数,若用于控制其他模型,或被控模型发生较大变化,则控制效果会大打折扣,甚至出现较大振荡,影响系统稳定性。因此,上述文献^[16-20]中的 FOPID 控制器无法在保证控制性能不衰减的前提下同时控制多个被控模型。

综上所述,本文在基于多个 FOPID 控制系统的基础上,利用神经网络强大的学习能力和泛化能力,将从每个 FOPID 中采集到的数据集经过处理和优化后,送入神经网络进行训练。最后,将训练好的神经网络控制器同时替换多个 FOPID 控制器,并在控制多个被控模型时,与对应的多个 FOPID 进行仿真实验对比,以验证本文提出的控制策略不仅能够实现多个模型的控制,且相较于 FOPID 还能进一步提升控制效果的多种优越性。

1 多模训练与多模控制

1.1 FOPID 控制系统

FOPID 在 IOPID 的基础上引入了积分阶次 λ 和微分阶次 μ 两个控制参数,使得控制器的参数整定更加灵活,调节范围更广,控制自由度更大,其控制器结构如图 1 所示。




图 1 FOPID 控制器结构

由图 1 可知, FOPID 控制器输出的传递函数为:

$$U(s) = (K_p + K_i s^{-\lambda} + K_d s^{\mu}) E(s) \tag{1}$$

式中, $U(s)$ 为控制量, $E(s)$ 为偏差, K_p 、 K_i 、 K_d 分别为比例系数、积分系数、微分系数, λ 和 μ 为积分阶次和微分阶次, s 为复变量。

1.2 多模型训练

神经网络具有强大的自学习能力和泛化能力,能够根据多个控制系统中的 FOPID 控制器模型的有效输入输出数据集,进行多模型控制器训练,如图 2 所示。




图 2 FOPID 多模型数据采集训练系统

根据图 2,本文首先基于三个 FOPID 控制系统中的 FOPID1、FOPID2、FOPID3 控制器,分别对应控制三个模型结构相同但参数不同的被控对象 $G_{p1}(s)$ 、 $G_{p2}(s)$ 、 $G_{p3}(s)$,并将每个 FOPID 控制器的控制参数 K_p 、 K_i 、 K_d 、 λ 、 μ ,整定到较为合适的数值,使其对应的每个被控对象都能输出较为满意的控制性能指标。

其次,在没有干扰和噪声即“异常点”的环境下,分别采集 601 组三个被控模型 $G_{p1}(s)$ 、 $G_{p2}(s)$ 、 $G_{p3}(s)$ 的偏差 $e_1(s)$ 、 $e_2(s)$ 、 $e_3(s)$,偏差变化率 $ec_1(s)$ 、 $ec_2(s)$ 、 $ec_3(s)$ 以及其分别所对应的 FOPID1、FOPID2、FOPID3 控制器输出的控制量

$U_1(s)$ 、 $U_2(s)$ 、 $U_3(s)$ 。

根据长期多次反复训练所得的模型性能、结构、数据等归纳总结可知,本文分别将 FOPID1、FOPID2、FOPID3 控制器数据集的其中 421 组输入输出数据对(约占每个控制器数据集的 70%)划分为训练集,用于训练权值。再将测试集和验证集各划分 90 组输入输出数据对(约各占每个控制器的数据集的 15%)用于防止数据的过度拟合,保证模型具有较强的泛化能力。同时,为了尽可能地使训练集、验证集以及测试集等每类子集中数据对的分布都能具有所采集的每个 FOPID 控制器中 601 组数据对的一些相关特征,从而提升模型的训练效果和泛化性能。因此,本文将每个 FOPID 控制器中 601 组数据对按照上述的训练集、验证集以及测试集的划分比例进行随机划分,并送入一个神经网络模型进行训练、验证和测试^[5]。

三个 FOPID 控制器输入输出数据集变化曲线如图 3 所示。

将图 3 中的数据集经过优化处理后,送入 6—8—8—8—3 结构的 5 层神经网络进行训练,如图 4 所示。





图 3 三个 FOPID 控制器输入输出数据集曲线




图 4 6—8—8—8—3 结构的 5 层神经网络

图 4 中每一层网络节点的激活函数均采用双曲正切函数。因此,第 2 层的输入输出为:

$$\begin{cases} z_k^{[2]} = \sum_{i=1}^6 w_{ki}^{[2]} x_i (k = 1, 2, \cdots, 8) \\ o_k^{[2]} = \frac{e^{z_k^{[2]}} - e^{-z_k^{[2]}}}{e^{z_k^{[2]}} + e^{-z_k^{[2]}}} \end{cases} \tag{2}$$

式中, $z_k^{[2]}$ 为第 2 层第 k 个节点的带权输入, $o_k^{[2]}$ 为第 2 层第 k 个节点的输出, $w_{ki}^{[2]}$ 为输入层第 i 个节点连接到第 2 层第 k 个节点的权值,上角标 $[\cdot]$ 表示网络层数。

同理,第 3 层的输入输出为:

$$\begin{cases} z_j^{[3]} = \sum_{k=1}^8 w_{jk}^{[3]} o_k^{[2]} (j = 1, 2, \cdots, 8) \\ o_j^{[3]} = \frac{e^{z_j^{[3]}} - e^{-z_j^{[3]}}}{e^{z_j^{[3]}} + e^{-z_j^{[3]}}} \end{cases} \tag{3}$$

第 4 层的输入输出为:

$$\begin{cases} z_n^{[4]} = \sum_{j=1}^8 w_{nj}^{[4]} o_j^{[3]} (n = 1, 2, \cdots, 8) \\ o_n^{[4]} = \frac{e^{z_n^{[4]}} - e^{-z_n^{[4]}}}{e^{z_n^{[4]}} + e^{-z_n^{[4]}}} \end{cases} \tag{4}$$

第 5 层的输入输出为:

$$\begin{cases} z_v^{[5]} = \sum_{n=1}^8 w_{vn}^{[5]} o_n^{[4]} (v = 1, 2, 3) \\ o_v^{[5]} = \frac{e^{z_v^{[5]}} - e^{-z_v^{[5]}}}{e^{z_v^{[5]}} + e^{-z_v^{[5]}}} \end{cases} \quad (5)$$

取误差函数:

$$E = \frac{1}{2M} \sum_{t=1}^{M=421} [u(t)_v - o(t)_v^{[5]}]^2 \quad (6)$$

式(6)中, t 为求和运算遍历的每个训练样本, $u(t)_v$ 为第 t 个样本的期望输出, $o(t)_v^{[5]}$ 为第 t 个样本的实际输出, $M = 421$ 为训练样本的总数。

本文神经网络采用动量梯度下降法和误差反向传播算法对 FOPID 控制器的数据集进行学习训练。第 5 层权值修正量为:

$$\begin{cases} \Delta w_{vn}^{[5]}(q) = -\eta \frac{\partial E}{\partial w_{vn}^{[5]}} + \alpha \Delta w_{vn}^{[5]}(q-1) \\ w_{vn}^{[5]}(q+1) = w_{vn}^{[5]}(q) + \Delta w_{vn}^{[5]}(q) \end{cases} \quad (7)$$

式中, η 为学习率, α 为惯性系数。第 5 层反向传播算法为:

$$\begin{cases} \frac{\partial E}{\partial w_{vn}^{[5]}} = \frac{\partial E}{\partial o(t)_v^{[5]}} \cdot \frac{\partial o(t)_v^{[5]}}{\partial z_v^{[5]}} \cdot \frac{\partial z_v^{[5]}}{\partial w_{vn}^{[5]}} \\ \delta_v^{[5]} = (o_v^{[5]})' \cdot \frac{1}{M} \sum_{t=1}^{M=421} [o(t)_v^{[5]} - u(t)_v]^2 \end{cases} \quad (8)$$

式中, $\delta_v^{[5]}$ 为第 5 层误差信号, 将式(8)代入式(7)得:

$$\Delta w_{vn}^{[5]}(q) = -\eta \delta_v^{[5]} o_n^{[4]} + \alpha \Delta w_{vn}^{[5]}(q-1) \quad (9)$$

第 4 层权值修正量为:

$$\begin{cases} \Delta w_{nj}^{[4]}(q) = -\eta \frac{\partial E}{\partial w_{nj}^{[4]}} + \alpha \Delta w_{nj}^{[4]}(q-1) \\ w_{nj}^{[4]}(q+1) = w_{nj}^{[4]}(q) + \Delta w_{nj}^{[4]}(q) \end{cases} \quad (10)$$

第 4 层反向传播算法为:

$$\begin{cases} \frac{\partial E}{\partial w_{nj}^{[4]}} = \frac{\partial E}{\partial o(t)_v^{[5]}} \cdot \frac{\partial o(t)_v^{[5]}}{\partial z_v^{[5]}} \cdot \frac{\partial z_v^{[5]}}{\partial o_n^{[4]}} \cdot \frac{\partial o_n^{[4]}}{\partial z_n^{[4]}} \cdot \frac{\partial z_n^{[4]}}{\partial w_{nj}^{[4]}} \\ \delta_n^{[4]} = \sum_v^3 \delta_v^{[5]} \cdot (o_n^{[4]})' w_{vn}^{[5]} \end{cases} \quad (11)$$

式(11)中, $\delta_n^{[4]}$ 为第 4 层误差信号, 将式(11)代入式(10)得:

$$\Delta w_{nj}^{[4]}(q) = -\eta \delta_n^{[4]} o_j^{[3]} + \alpha \Delta w_{nj}^{[4]}(q-1) \quad (12)$$

第 3 层权值修正量为:

$$\begin{cases} \Delta w_{jk}^{[3]}(q) = -\eta \frac{\partial E}{\partial w_{jk}^{[3]}} + \alpha \Delta w_{jk}^{[3]}(q-1) \\ w_{jk}^{[3]}(q+1) = w_{jk}^{[3]}(q) + \Delta w_{jk}^{[3]}(q) \end{cases} \quad (13)$$

第 3 层反向传播算法为:

$$\begin{cases} \frac{\partial E}{\partial w_{jk}^{[3]}} = \frac{\partial E}{\partial o(t)_v^{[5]}} \cdot \frac{\partial o(t)_v^{[5]}}{\partial z_v^{[5]}} \cdot \frac{\partial z_v^{[5]}}{\partial o_n^{[4]}} \cdot \frac{\partial o_n^{[4]}}{\partial z_n^{[4]}} \cdot \frac{\partial z_n^{[4]}}{\partial o_j^{[3]}} \cdot \frac{\partial o_j^{[3]}}{\partial z_j^{[3]}} \cdot \frac{\partial z_j^{[3]}}{\partial w_{jk}^{[3]}} \\ \delta_j^{[3]} = \sum_n^8 \delta_n^{[4]} \cdot (o_j^{[3]})' w_{nj}^{[4]} \end{cases} \quad (14)$$

式(14)中, $\delta_j^{[3]}$ 为第 3 层误差信号, 将式(14)代入式(13)得:

$$\Delta w_{jk}^{[3]}(q) = -\eta \delta_j^{[3]} o_k^{[2]} + \alpha \Delta w_{jk}^{[3]}(q-1) \quad (15)$$

第 2 层权值修正量为:

$$\begin{cases} \Delta w_{ki}^{[2]}(q) = -\eta \frac{\partial E}{\partial w_{ki}^{[2]}} + \alpha \Delta w_{ki}^{[2]}(q-1) \\ w_{ki}^{[2]}(q+1) = w_{ki}^{[2]}(q) + \Delta w_{ki}^{[2]}(q) \end{cases} \quad (16)$$

第 2 层反向传播算法为:

$$\begin{cases} \frac{\partial E}{\partial w_{jk}^{[3]}} = \frac{\partial E}{\partial o(t)_v^{[5]}} \cdot \frac{\partial o(t)_v^{[5]}}{\partial z_v^{[5]}} \cdot \frac{\partial z_v^{[5]}}{\partial o_n^{[4]}} \cdot \frac{\partial o_n^{[4]}}{\partial z_n^{[4]}} \cdot \frac{\partial z_n^{[4]}}{\partial o_j^{[3]}} \cdot \frac{\partial o_j^{[3]}}{\partial z_j^{[3]}} \cdot \frac{\partial z_j^{[3]}}{\partial o_k^{[2]}} \cdot \frac{\partial o_k^{[2]}}{\partial z_k^{[2]}} \cdot \frac{\partial z_k^{[2]}}{\partial w_{ki}^{[2]}} \\ \delta_k^{[2]} = \sum_j^8 \delta_j^{[3]} \cdot (o_k^{[2]})' w_{jk}^{[3]} \end{cases} \quad (17)$$

式(17)中, $\delta_k^{[2]}$ 为第 2 层误差信号, 将式(17)代入式(16)得:

$$\Delta w_{ki}^{[2]}(q) = -\eta \delta_k^{[2]} x_i + \alpha \Delta w_{ki}^{[2]}(q-1) \quad (18)$$

根据式(2)至式(18)的训练算法, 设置目标均方误差 $E = 0.1$, 学习率与动量系数 $\eta = \alpha = 0.001$, 经过 15230 次迭代, 如图 5 和图 6 所示。




图 5 网络实际均方误差

根据图 5 和图 6 可知, 基于 FOPID 控制器的多模型神经网络最终的实际均方误差为 $E = 0.095325$, 最终收敛梯度为 $\Delta = 18.7652$ 。回归值 R 如图 7 所示。

根据图 7 可知, 回归值 $R = 0.99997$ 说明期望

数据与实际数据相关线性度极高,网络训练效果极好。




图 6 网络收敛梯度




图 7 网络回归值

1.3 神经网络多模型控制系统

在工业过程控制中,温度是最为广泛和常见的被控量,其控制性能指标的好坏常常决定着物料生产工艺的水平。作为温度载体的被控对象,也会根据不同的物料选择不同的对象进行加热。由于温度控制对象普遍等效为带有纯滞后的一阶惯性环节,因此,不同的加热对象其模型结构相同参数不同^[4]。

如图 8 所示,将 1.2 节中训练好的网络作为多模型控制器,替代每个控制系统中的 FOPID 控制器,实现一个控制器控制多个结构相同参数不同的

被控对象。本文对选取电加热膜作为温度被控对象,采用测试建模法对其进行建模^[21],得到传递函数模型为:

$$G_{p1}(s) = \frac{0.1687}{46s + 1}e^{-5}$$
 (19)

将式(19)中的模型参数均增大一倍对应传递函数模型为:

$$G_{p2}(s) = \frac{0.3356}{92s + 1}e^{-10}$$
 (20)

将式(19)中的模型参数均减小一半对应传递函数模型为:

$$G_{p3}(s) = \frac{0.0839}{23s + 1}e^{-2.5}$$
 (21)




图 8 基于 FOPID 的神经网络多模型控制器

2 仿真实验分析

设定目标温度为 35℃,控制精度为±0.1℃。在 25℃以下时采用全功率加热,在 25~35℃的范围内,采用控制算法加热。选取仿真时间为 1000 s,并根据图 2 所示的 FOPID 多模型数据采集训练系统,使用 FOPID1、FOPID2、FOPID3 三个控制器的输入输出数据集时,整定好的能够使 $G_{p1}(s)$ 、 $G_{p2}(s)$ 、 $G_{p3}(s)$ 输出较为满意的控制性能指标的三套控制参数如表 1 所示。

表 1 每个 FOPID 控制器参数

FOPID1	FOPID2	FOPID3
$K_{p1}=0.839$	$K_{p2}=0.839$	$K_{p3}=0.839$
$K_{i1}=0.07627$	$K_{i2}=0.07627$	$K_{i3}=0.07627$
$K_{d1}=2.09875$	$K_{d2}=2.09875$	$K_{d3}=2.09875$
$\lambda_1=0.9$	$\lambda_2=0.72$	$\lambda_3=1.1$
$\mu_1=0.8$	$\mu_2=0.8$	$\mu_3=0.8$

将表 1 中训练网络时所用的三个 FOPID 控制器与训练好的多模型神经网络控制器,共同控制 $G_{p1}(s)$ 、 $G_{p2}(s)$ 、 $G_{p3}(s)$ 时的性能指标进行比较分析。

当共同控制 $G_{p1}(s)$ 时,四个控制器的系统输出响应曲线如图 9 所示。




图 9 控制模型为 $G_{p1}(s)$ 时输出响应曲线

当控制模型为 $G_{p1}(s)$ 时,根据图 9 所示,利用 MATLAB 测量并计算图中四个控制器的性能指标,如表 2 所示。

表 2 共同控制 $G_{p1}(s)$ 的性能指标

控制器	FOPID-NN	FOPID1	FOPID2	FOPID3
σ	0	0	0	13.2%
t_s/s	224.44	365.99	>1000	277.52
t_d/s	38.65	101.25	202.16	64.82
t_r/s	121.33	218.22	932.51	124.18
$e_{ss}/^{\circ}\text{C}$	< 0.1	< 0.1	> 0.1	< 0.1

根据表 2 可知当控制 $G_{p1}(s)$ 时,本文提出的 FOPID-NN 多模型控制策略,与采集数据集时该模型所整定的控制器 FOPID1 相比,调节时间 t_s 、延迟时间 t_d 、上升时间 t_r 均更短,说明其响应速度更快,性能指标更加优越。控制器 FOPID2 在 1000 s 仿真时间内无法达到稳态值,响应速度缓慢,稳态误差较大,且无法满足 $\pm 0.1^{\circ}\text{C}$ 的控制精度,而控制器 FOPID3 超调量 σ 较大,与 FOPID-NN 相比模型适应性较差。

当共同控制 $G_{p2}(s)$ 时,四个控制器的系统输出响应曲线如图 10 所示。




图 10 控制模型 $G_{p2}(s)$ 时输出响应曲线

当控制模型为 $G_{p2}(s)$ 时,根据图 10 所示,利用 MATLAB 测量并计算图中四个控制器的性能指标,如表 3 所示。

表 3 共同控制 $G_{p2}(s)$ 的性能指标

控制器	FOPID-NN	FOPID1	FOPID2	FOPID3
σ	0	20.2%	6%	46.8%
t_s/s	430.99	620.25	430.11	816.19
t_d/s	90.76	83.87	122.55	61.46
t_r/s	259.50	159.56	268.68	88.66
$e_{ss}/^{\circ}\text{C}$	< 0.1	< 0.1	< 0.1	< 0.1

根据表 3 可知,当控制 $G_{p2}(s)$ 时,本文提出的 FOPID-NN 多模型控制策略,与采集数据集时该模型所整定的控制器 FOPID2 相比,在 t_s 差异较小的情况下,具有更低的 σ ,更短的 t_d 和 t_r ,综合性能指标更优。控制器 FOPID1 和 FOPID3 均存在较大超调量,与 FOPID-NN 相比,模型适应性较差。

当共同控制 $G_{p3}(s)$ 时,四个控制器的系统输出响应曲线如图 11 所示。




图 11 控制模型 $G_{p3}(s)$ 时输出响应曲线

当控制模型为 $G_{p3}(s)$ 时,根据图 11 所示,利用 MATLAB 测量并计算图中四个控制器的性能指标,如表 4 所示。

表 4 共同控制 $G_{p3}(s)$ 的性能指标

控制器	FOPID-NN	FOPID1	FOPID2	FOPID3
σ	0	0	0	0
t_s/s	96.00	>1000	>1000	301.77
t_d/s	19.33	175.30	531.13	84.21
t_r/s	51.73	593.05	>1000	176.28
$e_{ss}/^{\circ}\text{C}$	< 0.1	> 0.1	> 0.1	< 0.1

根据表 4 可知,当控制 $G_{p3}(s)$ 时,本文提出的 FOPID-NN 多模型控制策略,与采集数据集时该模型所整定的控制器 FOPID3 相比, t_s 、 t_d 、 t_r 均更短,说明其响应速度更快,性能指标更加优越。控制器 FOPID1 和 FOPID2 在 1000 s 仿真时间内均

无法达到稳态值,响应速度缓慢,稳态误差较大,且无法满足 $\pm 0.1\text{ }^{\circ}\text{C}$ 的控制精度,与 FOPID-NN 相比,模型适应性较差。

3 结 论

提出了一种基于 FOPID 的神经网络多模型控制策略。将经过多个 FOPID 控制器输入输出数据训练而成的神经网络作为控制器时,不仅有兼具每个 FOPID 控制器的模型控制能力,而且在控制原系统模型时,比采集数据集时整定的原 FOPID 控制器具备更强的性能优势,其在一定程度上有相当的应用前景。

参考文献

[1] ZHANG J. PID control realization of drying system of the finishing line based on MCGS and PLC[C]//Journal of Physics: Conference Series. IOP Publishing, 2020, 1629(1): 012015.

[2] ZHUO Q L, JIA Z Y. PID control of chocolate 3D printer heating system[C]//Institute of Management Science and Industrial Engineering. Proceedings of 2018 5th International Conference on Electrical & Electronics Engineering and Computer Science(ICEECS 2018), 2018:310—313.

[3] 宋安然,周德廉,刘艳梨,等. 基于增量式 PID 控制的锅炉温控系统设计[J]. 电子测量技术, 2021, 44(6): 11—16.

[4] 张皓,高瑜翔. 前馈反馈 Smith 预估模糊 PID 组合温度控制算法[J]. 中国测试, 2020, 46(11):132—138+168.

[5] 张皓,高瑜翔,唐军,等. 基于 Sugeno 型模糊神经网络的双模控制器设计[J]. 中国测试, 2021, 47(10):129—136.

[6] 张皓,高瑜翔,曹远杰,等. 基于变论域模糊控制的 Taylor 逼近型内模 PID 算法[J]. 成都信息工程大学学报, 2021, 36(6):602—609.

[7] 张皓,高瑜翔,唐军,等. 基于 T-S 型模糊神经网络的内模自适应 PID 算法研究[J]. 工业仪表与自动化装置, 2021(6): 118—124.

[8] 张皓,涂雅培,高瑜翔,等. 基于多重模糊神经网络的 PID 温度控制算法[J]. 西华大学学报(自然科学版), 2023, 42(4): 58—65+81.

[9] 张雅琼,徐阳,周伟,等. 基于分数阶 PID 的连续变焦控制系统设计与实现[J]. 应用光学, 2023, 44(6):1306—1316.

[10] DAHAKE V R, PATIL M D, VYAWAHARE V A ,et al. Analysis of Networked Control System With Integer-order and Fractional-order PID Controllers[J]. International Journal of Control, Automation, and Systems, 2024, 22(2): 373—386.

[11] HU Y, LIU J, WANG Z, et al. Research on electric oil - pneumatic active suspension based on fractional-order PID position control[J]. Sensors, 2024; 24(5):1644.

[12] MUJAHED A. Fuzzy fractional-order PID control for heat exchanger[J]. Alexandria Engineering Journal, 2023, 6311—6316.

[13] CHOPADE A S, KHUBALKAR S W , JUNGHARE A S, et al. Design and implementation of digital fractional order PID controller using optimal pole-zero approximation method for magnetic levitation system[J]. IEEE/CAA Journal of Automatica Sinica, 2018, 5(5):95—107.

[14] 雷城,蓝益鹏,孙云鹏,等. 直线同步电动机磁悬浮系统的模糊分数阶滑模控制[J]. 电机与控制学报, 2022, 26(3):94—100.

[15] GAO K, SONG J, WANG X, et al. Fractional-order proportional-integral-derivative linear active disturbance rejection control design and parameter optimization for hypersonic vehicles with actuator faults[J]. Tsinghua Science and Technology, 2021, 26(1):9—23.

[16] 彭琳,唐德文,陈钢,等. 基于分数阶 PID 机器人自动行驶误差分析[J]. 机电工程技术, 2023, 52(2):134—138.

[17] 姚钢,李华荣,周荔丹,等. MP-MMC 驱动六相永磁同步风力发电机分数阶 PID 控制研究[J]. 电机与控制学报, 2022, 26(12):93—107.

[18] 唐鸣政,李创,唐荣年,等. 基于 Ziegler-Nichols 整定规则的分数阶 PID μ 控制器[J/OL]. 控制工程:1—8[2024—03—27].

[19] KRISHNA P S, RAO P V G K. Fractional-order PID controller for blood pressure regulation using genetic algorithm [J]. Biomedical Signal Processing and Control, 2024, 88: 105564.

[20] 朱敏,臧昭宇,赵聪聪,等. 基于粒子群优化分数阶 PID 的阀门开度控制[J]. 制造业自动化, 2022, 44(10):104—108.

[21] 张皓,唐军,唐翠微,等. 基于 STM32 的高性能温度控制器算法研究与实现[J/OL]. 自动化技术与应用, 1—8[2025—02—17].