

# 基于四重优化模糊 PID 算法的双轮自平衡结构机器人自动化控制方法研究

刘 婕<sup>1</sup>, 程 卉<sup>2</sup>

(1. 淄博师范高等专科学校 信息系, 山东 淄博 255130;

2. 海军航空大学 图书馆, 山东 烟台 264001)

**摘要:** 针对现有双轮自平衡结构机器人自动控制方法存在的倾角控制精度、机器人平衡性与工作效率相矛盾的不足, 设计了一种基于四重优化模糊 PID 算法的机器人控制方法; 先基于拉格朗日方程构建一种精准动力学模型, 用于分析运动中机器人的平衡姿态, 再基于线性优化降低模型的复杂度, 在动力学模型优化过程中引入了附加扰动项实施动态补偿, 进一步提升模型的性能; 构建一种 RBF 神经网络模型并与自适应模糊算法、PID 控制算法相融合, 提升 PID 控制器的数据训练能力和最优结果输出能力, 最后在神经网络输出层的 3 个输出节点控制上采用一种自适应调节机制, 并通过最优控制函数获取到合理的控制结果; 实验结果显示, 提出四重优化融合方案下未出现超过 25°倾角的情况, 且在无障碍、有障碍和有坡度 3 种情况下, 提出方法均未与障碍物碰撞, 在有坡度和障碍物的情况下采样标准差的波动值仅为 0.852。

**关键词:** 四重优化; 双轮自平衡结构; RBF; PID 控制; 自适应调节机制

## Research on Automatic Control Method of Two-Wheel Self-Balancing Structure Robot Based on Four-Fold Optimized Fuzzy PID Algorithm

LIU Jie<sup>1</sup>, CHENG Hui<sup>2</sup>

(1. Department of Information, Zibo Normal College, Zibo 255130, China;

2. Library, Naval Aeronautical University, Yantai 264001, China)

**Abstract:** Aiming at the shortcomings of the existing automatic control methods for two-wheel self-balancing structure robots, such as the contradiction between inclination control accuracy, robot balance and working efficiency, a robot control method based on the quadruple optimization fuzzy PID algorithm is designed. Firstly, a precise dynamic model is constructed based on the Lagrange equation to analyze the balanced posture of the robot in motion. Then, the complexity of the model is reduced through linear optimization. During the optimization process of the dynamic model, additional disturbance terms are introduced to implement dynamic compensation, further enhancing the performance of the model. An RBF neural network model was constructed and integrated with the adaptive fuzzy algorithm and PID control algorithm to enhance the data training ability and optimal result output ability of the PID controller. Finally, an adaptive adjustment mechanism was adopted in the control of the three output nodes of the neural network output layer, and reasonable control results were obtained through the optimal control function. The experimental results show that under the proposed quadruple optimization fusion scheme, there is no situation where the inclination Angle exceeds 25°. Moreover, in the three cases of no obstacles, with obstacles, and with slopes, the proposed method all involves collisions with obstacles. In the cases of slopes and obstacles, the fluctuation value of the standard deviation of the sampling site is only 0.852.

**Keywords:** quadruple optimization; two-wheel self-balancing structure; RBF; PID control; adaptive regulation mechanism

收稿日期:2025-11-10; 修回日期:2025-11-17。

作者简介:刘 婕(1981-),女,硕士,讲师。

引用格式:刘 婕,程 卉. 基于四重优化模糊 PID 算法的双轮自平衡结构机器人自动化控制方法研究[J]. 计算机测量与控制, 2025, 33(12):161-166,236.

## 0 引言

伴随着计算机科学技术、自动化控制技术、电子信息技术和移动通信技术的快速发展, 可移动机器人的设计水平与控制精度均有了显著提升<sup>[1-2]</sup>。可移动机器人的类别具体包括了轮式机器人、履带机器人、多足机器人及双足机器人等, 可移动机器人可以在野外救援、户外抢险、物料搬运及设备巡检等工作中替代人工操作人员<sup>[4-6]</sup>, 在显著提高工作效率的同时还能避免操作人员在工作中发生危险。多轮机器人和履带机器人虽然载重大, 但灵活度欠佳, 且无法实现在狭小空间内的转弯或掉头, 多足机器人和双足机器人具有一定的攀爬能力, 灵活度良好, 但行动速度较慢, 工作效率相对低下。双轮自平衡机器人是一种小型的轮式机器人<sup>[7]</sup>, 运动较为灵活可以实现零半径转弯, 而且双轮自平衡机器人结构设计较为简单, 可以在较小的空间内作业并完成特殊的任务。双轮自平衡机器人的控制难点是对动态平衡状态的把控<sup>[8]</sup>, 即在双轮机器人作业中先要实现自身的平衡, 通过内置的传感器采集运动状态相关数据, 实时调整姿态倾角的变化等<sup>[9]</sup>, 以维持自身的稳定与平衡。

汇总分析国内外现阶段关于双轮自平衡机器人较为主流的控制方案和控制策略, 主要包括基于数学模型的控制方案, 基于自适应模糊理论的控制方案, 基于神经网络和元启发算法的控制方案等。文献 [10] 提出一种基于模型预测控制 (MPC, model predictive control) 的控制方法, 模型预测控制主要通过优化未来一段时间内的系统行为, 来实现对机器人主体的控制, 基于数学的机器人控制具有精度高、响应快的优势, 但数学模型的实时计算量较大容易出现参数漂移的情况, 导致控制精度快速下降; 文献 [11] 提出一种基于自适应模糊算法的控制方案, 模糊算法无需构建复杂的数学模型, 仅需在线处理控制过程中的实际输出和期望输出, 再利用模糊规则和模糊推理以达到精确控制的目的, 适合非线性、不确定性较强的机器人控制系统, 但自适应模糊算法同样会面临模糊规则制定难度较高的不足, 间接影响到控制精度和控制效果; 文献 [12] 提出一种基于粒子群优化的神经网络算法, 基于粒子群算法来优化神经网络的参数提升网络性能, 但该算法无法克服神经网络算法固有缺点, 当中间隐含层数量较少时训练学习效率较低, 而随着中间隐含层数量的增加又面临梯度问题, 影响到机器人的在线反馈和控制效果。

针对现有主流的双轮平衡机器人控制方案存在的不足, 本文设计了一种基于四重优化的改进控制方法, 先基于拉格朗日方程构建两轮自平衡机器人运动模型, 通过对实时数据的线性化处理降低模型的复杂度, 并动态采集和处理机器人的运动数据同步滤除噪声干扰; 将模

糊 PID 算法和 RBF (Radial Basis Function network, 径向基网络) 神经网络算法融合, 形成算法之间的优势互补, 实施一种自适应的 PID 参数调节机制, 提升对双轮自平衡机器人的控制精度。

## 1 双轮自平衡结构机器人运动模型构建

双轮自平衡机器人须在世界坐标系范围内建模, 坐标系以机器人水平运动方向为 X 轴, 以机器人竖直旋转方向为 Y 轴, 以两轮中心连线方向为 Z 轴。双轮自平衡机器人在前进、后退、转弯过程中, 需要根据机器人的行进速度、轮距、轮速、姿态、倾角等信息确保机器人始终处于平衡状态<sup>[13-14]</sup>, 双轮自平衡机器人运动学平面坐标如图 1 所示。

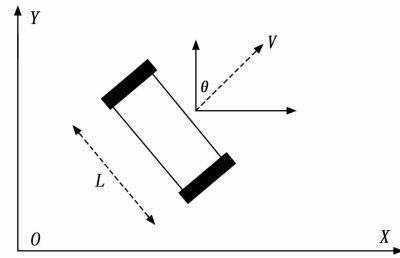


图 1 双轮自平衡机器人运动学平面坐标图

图 1 中,  $L$  为机器人两轮之间的轮距,  $v$  为双轮平衡机器人行进速度,  $\theta$  为双轮平衡机器人的转向角度<sup>[15]</sup>。基于机器人运动总动能和运动作用力的双重视角分析机器人的运动过程, 在拉格朗日方程基础上定义双轮自平衡机器人运动中的广义作用力  $F$ , 如公式 (1) 所示:

$$F = \frac{d}{dt} \left( \frac{\partial E}{\partial q_i} \right) - \frac{\partial E}{\partial q_i} \quad (1)$$

式中,  $E$  为机器人的运动总动能,  $q_i$  表示与广义作用力相关的广义变量, 其取值范围在 1 和  $n$  之间 ( $n$  为一个正整数), 双轮机器人的运动速度  $v$  表示如下:

$$v = \dot{a}L \cos\theta \sin\alpha + \theta r \sin\alpha - \dot{a}L \cos\alpha \sin\alpha \quad (2)$$

式中,  $\alpha$  为运动中机器人的倾角,  $\dot{a}$  为倾角的一阶导数,  $r$  为轮半径。

## 2 四重优化模糊 PID 算法

四重优化方案对模糊自适应神经网络 PID 算法从多个维度进行全方位优化, 具体包括模型的复杂度、模型的扰动补偿、噪声的抑制及 PID 参数的动态优化, 优化过程如图 2 所示。

从多重优化视角出发完善了模糊自适应神经网络 PID 模型的性能, 既降低了模型复杂度和计算量, 又能够提高 PID 模型的动态优化能力。

### 2.1 轻量化模型优化

非线性控制的难度和复杂度远超过线性控制, 而对

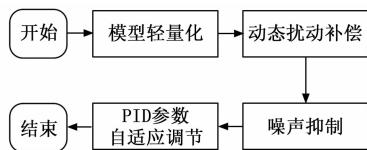


图 2 四重优化的具体流程

双轮自平衡机器人的控制过程是一个典型的非线性控制过程<sup>[16-18]</sup>, 控制较为复杂且包括多个未知变量, 需要通过预估和拟合获得更精确的结果。而线性控制的精度较高且稳定性更好, 为此本文通过对双轮自平衡机器人运动过程的轻量化处理(线性处理), 以进一步提升控制精度和改善控制效果<sup>[19-20]</sup>, 轻量化处理的过程如下(线性处理主要针对倾角  $a$  及其正弦函数  $\sin a$ ):

$$\begin{cases} a \approx \sin a \\ \cos a \approx 1 \\ (\sin a)^2 \approx a^2 \end{cases} \quad (3)$$

在轻量化处理过程中还要忽略掉影响微乎其微的一些变量, 例如轴承摩擦力, 这类摩擦力属于一种较小的扰动量, 其本身对机器人控制结果的影响较小, 但计算成本较高还会增加模型的复杂度, 通过轻量化处理以降低模型的复杂度, 减少计算量。经过轻量化处理后的模型可以表示如下:

$$F = MgL\theta - \xi_1 - \xi_2 = Ma + (ML + J)\ddot{\theta} \quad (4)$$

式中,  $M$  为机器人质量,  $g$  为重力常数,  $\xi_1$ 、 $\xi_2$  分别为机器人左右轮的扭矩,  $J$  为机器人运动中与倾角相关的雅克比矩阵,  $\ddot{\theta}$  为转角的二阶导数, 此时机器人运动速度  $v$  表示如下:

$$v = \dot{a}L \cos \theta + \theta \dot{a} - \dot{a}L \dot{\theta} \quad (5)$$

轻量化处理后运动模型求最优解的计算量将有所降低且模型的复杂度同步降低, 轻量化处理使原本复杂的非线性变换过程逐渐向线性变换转换, 而基于线性变换的控制方式与传统非线性控制方式相比, 在控制精度和控制难度等方面有较为显著的优势。为避免轻量化处理后出现过大的偏差, 重复公式(3)~(5)多次后取均值以最大限度地实现误差补偿。在对双轮自平衡机器人实施运动误差补偿的同时还要克服与外部环境交互产生的扰动补偿, 与运动过程中产生摩擦扰动。

## 2.2 动态扰动补偿的改进方案

双轮自平衡机器人在作业过程中会与地面形成摩擦力, 机器人也存在受到外部冲击导致方向出现偏差的风险, 其系统内部的载荷波动也会形成干扰量, 上述这些干扰因素本身会降低对机器人的控制精度, 引起转角或倾角的偏差。为此, 本文引入了附加扰动项实施动态补偿, 进一步提升模型的性能, 加入扰动的广义作用力表示如下:

$$F = MgL\theta\tau - \xi_1 - \xi_2 \quad (6)$$

式中,  $\tau$  为各扰动项的综合值, 通过引入 LuGre 模型来分析各种不同扰动的影响:

$$\tau = [\zeta + (\zeta - \kappa\eta - \psi\chi)e^{-(\dot{\theta}/\dot{a})^2}] \operatorname{sgn}(\dot{\theta})\sigma^2 \dot{a} \quad (7)$$

式中,  $\zeta$  为摩擦扰动,  $\eta$  为冲击扰动,  $\kappa$  表示冲击风险系数取值在 0~1 之间,  $\chi$  表示载荷扰动,  $\psi$  表示载荷扰动系数取值也在 0~1 之间, 系数值越趋近于 1, 表明发生冲击风险值越高,  $\sigma$  表示倾角和转角发生偏转的标准差值。通过实时动态计算各扰动项的综合值判断其对双轮自平衡机器人控制的影响, 并通过参数调节降低扰动项对机器人控制的干扰。

## 2.3 姿态数据噪声自适应分离优化及姿态角计算

机器人控制中需实时将自身状态数据传递到后台机, 并实现指令的传递和交互, 但由于环境噪声和系统噪声的存在会干扰数据的传输或造成数据传输的延迟等。而且双轮机器人运动中的稳定性较差, 需要通过实时调整姿态角以实现对自身平衡的控制。在机器人的控制中需要实时采集当前时刻的数据, 为确保数据传输的精度先对采集到的实时姿态数据做预处理, 消除噪声的干扰再实现对姿态角的精确测量。

将  $t$  时刻后台机系统采集到的双轮自平衡机器人倾角数据信号设定为  $x(t)$ 。

$$x(t) = s(t) + \chi(t) \quad (8)$$

式中,  $s(t)$  为有用信号,  $\chi(t)$  为噪声信号, 采用低通滤波器处理噪声, 但为防止传统算法存在的噪声残留等问题, 本文引入了一种动态化和自适应的滤波方式, 即赋予  $s(t)$  和  $\chi(t)$  一个初始的权重, 并且设定一个初始迭代次数, 通过不断增加有用信号权重和减少噪声信号的权重, 逐步剔除噪声干扰, 赋权后的  $x(t)$  表示如下:

$$x(t) = \omega_1 s(t) + \omega_2 \chi(t) \quad (9)$$

式中,  $\omega_1$  和  $\omega_2$  分别为有用信号和噪声信号各自的权重,  $\omega_1$  和  $\omega_2$  在给定的迭代次数内动态调整各信号权重。引入低通滤波器 D 并将式(9)改写成向量的形式:

$$\mathbf{x} = \omega_1 \mathbf{Dz} + \omega_2 \boldsymbol{\chi} \quad (10)$$

式中,  $\mathbf{x}$  是与  $x(t)$  相对应的向量形式,  $\mathbf{D}$  为低通滤波器,  $\mathbf{z}$  为有用信号中的低通部分,  $\boldsymbol{\chi}$  为噪声部分对应向量, 经过自适应的滤波器处理后的最佳信号解可以表示为:

$$\mathbf{x}^* = \arg \min \|\omega_1 \mathbf{Dz} - \mathbf{x}\|_2^2 \quad (11)$$

通过低通滤波处理和自适应权重调整,  $\omega_1$  取值趋近于 1, 而  $\omega_2$  的取值趋近于零。

剔除噪声干扰后的双轮自平衡机器人的实际倾角值通过对机器人的加速器、陀螺仪采集数据的融合获取记为  $a(t-1)$  (假定时间点为  $t-1$  时点), 为了提升当期  $t$  时刻较为精确的最佳倾角  $a^*(t)$ , 引入了采样时间  $T_c$  和低通滤波器的时间系数  $\psi$  并通过拉普拉斯离散方程转换, 得到  $t$  时刻双轮自平衡机器人的最佳倾角。

$$a^*(t) = \frac{\psi}{T_c + \psi} a^*(t-1) + \frac{\psi}{T_c + \psi} a(t) + \frac{\psi}{T_c + \psi} [a(t) - a(t-1)] \quad (12)$$

经过噪声分离和高精度倾角的计算，并通过对倾角值的分析和调整，同步结合行进方向、速度等指标值对机器人的稳定性实时控制，使双轮自平衡机器人在稳定控制的前提下提升工作效率。将经过噪声滤除的机器人姿态数据作为模糊自适应神经网络 PID 模型输入项，经过模糊计算和去模糊化等环节输出最终的结果。但传统 PID 模型参数固定，从一定程度上限制模型的性能。为此，本文设计了一种 PID 参数的自适应调节方案，通过动态调节参数提升模型的控制性能与指令输出的精度。

## 2.4 PID 参数自适应调节优化

自适应模糊 PID 控制和神经网络控制均为控制领域的有效方案，本文在构建双轮自平衡机器人运动学模型和精确获取姿态角的同时，构建了一种模糊-RBF-PID 混合控制架构。突破了传统 PID 控制参数固定的不足，采用自适应参数调节机制进一步提升了 PID 控制精度高和神经网络训练能力强的双重优势，实时生成可变的控制量以改善控制效果。自适应模糊算法选用了 7 个模糊变量即：NB（负大）、NM（负中）、NS（负小）、Z（零）、PS（正小）、PM（正中）、PB（正大）。模糊规则如表 1 所示。

表 1 自适应模糊算法的模糊规则表

	NB	NM	NS	Z	PS	PM	PB
NB	PB	PS	PM	PM	PB	PB	Z
NM	PS	PS	PB	NM	Z	Z	NM
NS	PM	PB	NM	Z	PB	NS	NS
Z	PS	NB	NB	NB	PM	PS	NB
PS	Z	NM	Z	Z	PM	PB	NS
PM	PS	Z	PS	PM	PB	NS	PB
PB	NM	PM	NB	PB	NB	PS	NB

混合控制架构中的神经网络，选择训练能力更强且逼近能力也较强的 RBF 径向基神经网络，混合架构的输入分别为期望控制输入和实际控制输入，中间包括模糊化层和模糊推理层，输出对应自适应 PID 的 3 个参数  $k_p$ 、 $k_i$  和  $k_d$ ，混合控制架构如图 3 所示。

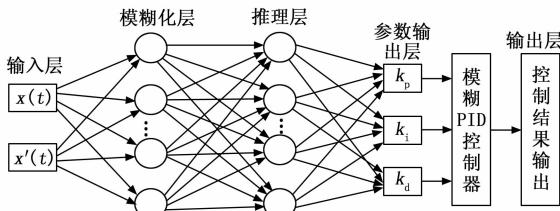


图 3 模糊-RBF-PID 混合控制架构

在输入层分别采用实际的机器人姿态信号  $x(t)$ （以

双轮自平衡机器人的倾角数据为例进行研究）和期望的姿态信号  $x'(t)$ ，其中期望信号为理论值， $x(t)$  与  $x'(t)$  之间的差距越小越好。在模糊化层要确定神经网络的节点数量，这是确定模型复杂度及模型训练能力的关键，在模糊推理层其神经网络节点数量与模糊化层的数量一致，模糊化层神经网络节点数量  $K_2$  计算过程如下：

$$K_2 = \sqrt{\frac{K_1 + K_4}{2}} + a \quad (13)$$

式中， $K_1$  和  $K_4$  分别为输入层和输出层的节点数量， $a$  表示一个取值在 1~10 之间（含 1 和 10 的整数）。模糊化的过程是将输入数据转换为模糊值，并利用制定好的模糊规则转变为模糊值进行模糊推理，该层的模糊隶属函数选择铃型函数  $F$ ：

$$F(x) = e^{-(x-\bar{x})^2/2\sigma^2} \quad (14)$$

式中， $\bar{x}$  为输入数据的均值， $\sigma$  为输入数据的标准差。

图 2 中的参数输出层的 3 个输出节点，分别对应模糊 PID 控制器的 3 个参数  $k_p$ 、 $k_i$  和  $k_d$ ，模糊 PID 控制器中 3 个参数分别被赋予不同的功能，其中  $k_p$  控制系统误差， $k_i$  增强控制系统的无差性，而  $k_d$  对误差的变化速率做出响应，3 个校正步骤同步校正  $x(t)$  和  $x'(t)$  之间的控制误差  $\epsilon(t)$ ，保证模糊控制器的稳定性。但模糊控制器自身仍存在抗干扰能力差、精度低等不足，需要通过引入控制偏差  $\epsilon(t)$  对模糊隶属度函数进行调整，在  $t$  时刻的模糊隶属度函数  $F(t)$  表示如下：

$$F(t) = K_c \left( \epsilon(t) + T_a \int_0^n \epsilon(t) dt + T_b \frac{d\epsilon(t)}{dt} \right) \quad (15)$$

式中， $K_c$  为比例增益， $T_a$  为时间积分系数， $T_b$  为时间微分系数，上述 3 个参数的取值范围均值 0~1 之间，且都采用自适应调节的模式，即根据控制偏差  $\epsilon(t)$  的值大小进行自适应调整，自适应调整的过程如图 4 所示。

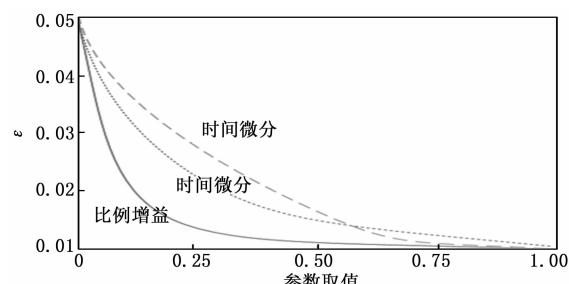


图 4 自适应参数的调节机制

在设定的有限迭代次数内（本文设定为 500 次）当  $\epsilon$  值增大时通过同步调整比例增益、时间积分系数和时间微分系数值控制  $\epsilon$  值，避免由于双轮自平衡机器人频繁移动而导致误差值持续增大。

在  $T$  时刻模糊神经网络自适应 PID 的期望输出值为  $\hat{y}(t)$  表示如下：

$$\hat{y}(t) = \varphi(t) \hat{\lambda}(t-1) \quad (16)$$

式中,  $\varphi(t)$  表示自适应 PID 控制模型在  $t$  时刻参数项系数的函数,  $\varphi(t)$  是 PID 控制器比例增益  $K_c$ , 时间积分系数  $T_a$ , 时间微分系数  $T_b$  的最优控制函数 (本文选用即时的代价函数和终端代价函数之和的方式表示)。

$$\varphi(t) = \int_0^n \phi_c(t, K_c, T_a, T_b) dt + \phi_e[x(n)] \quad (17)$$

式中,  $\phi_c$  为即时的代价函数,  $\phi_e$  终端代价函数,  $n$  为输入样本数据的总数量。 $\hat{\lambda}(t-1)$  为  $t-1$  时刻模型参数控制量的期望值。期望输出与实际输出之间的差值  $\mu(t)$  表示如下:

$$\mu(t) = y(t) - \hat{y}(t) \quad (18)$$

最后, 经过模糊神经网络自适应 PID 控制器得到的系统真实输出  $y(t)$  表示如下:

$$y(t) = \varphi^T(t) \hat{\lambda}(t-1) + \mu(t) \quad (19)$$

通过公式 (17) 与最优控制函数, 能够描述出实际控制量的变换过程, 并以自适应 PID 控制模型在  $t$  时刻参数项系数函数作为实际控制量, 继而实现对 PID 控制器的参数  $k_p$ 、 $k_i$  和  $k_d$  实施更加精确地控制, 并同步对双轮自平衡机器人的倾角变化及整个运动过程进行实时控制。

### 3 实验结果与分析

#### 3.1 实验准备

实验用机器人选择我国自主研发的基于 Zephyr RTOS 的驱动程序的双轮自平衡机器人, 采用基于 ARM Cortex A55 内核的 RK3568 主控板, 内置了嵌入式的通信模块, 且支持 WIFI 和蓝牙功能。该双轮自平衡机器人配备双电机、霍尔传感器、陀螺仪和距离传感器, 且配备了海康 CV-X 系列的双目深感摄像头, 用于辅助机器人的运动和避碰。

实验用机器人的相关参数如表 2 所示。

表 2 双轮自平衡机器人的相关参数

序号	参数	参数值
1	机器人高度	0.6 m
2	机器人宽度	0.8 m
3	整备质量	55 kg
4	最大行进速度	1.5 m/s
5	最大安全倾角	25°

最大安全倾角 25° 通过实验测试得出, 当以最大速度前进或后退时, 如果机器倾角超过 25° 发生倾倒的概率高达 50.5%。为验证本文提出的控制方法的有效性, 进行一组双轮自平衡机器人的控制实验具体包括:

- 1) 倾角控制实验;
- 2) 平路行进速度控制与避碰实验;
- 3) 坡路控制实验。

双足自平衡机器人的相关实时数据 (如车身倾角、

运行速度等) 由机器人内置的传感器获取, 并通过通信模块上传到后台, 同步引入文献 [10]、文献 [11] 和文献 [12] 等 3 种方法参与对比。各控制方法的参数设定如下: 本文方法的 RBF 神经网络隐含层数量为 3 层 (根据实验输入集的规模而确定), 模型最大迭代次数 200 次, 摩擦扰动 0.75,  $\eta$  冲击扰动 0.60,  $\kappa$  表示冲击风险系数 0.32; 传统各算法的最大迭代次数同步设定为 200 次, 神经网络隐含层的最大层数设定为 3 层, PSO 算法初始种群数量为 100 (根据实验输入集的规模而确定), 其他参数均按模型的最优状态设定。

#### 3.2 实验结果与分析

##### 3.2.1 不同算法下机器人倾角控制实验

在一个 L 型的场地测试机器人最大速度运行和转弯时倾角的变化情况, 在相同的测试条件下同步引入文献 [8-10] 等 3 种传统的方法参与对比, 最大的倾角度设定为 25°, 倾角超过 25° 双轮自平衡机器人有发生倾倒事故的风险, 实验的场景设定如图 5 所示。

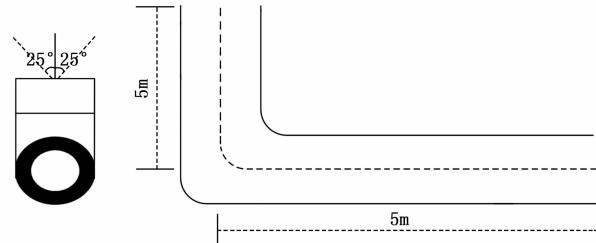


图 5 机器人倾角控制实验场景模拟

在 L 型跑道上随机采集了 200 个采样点, 并将结果拟合成曲线, 统计结果如图 6 所示。

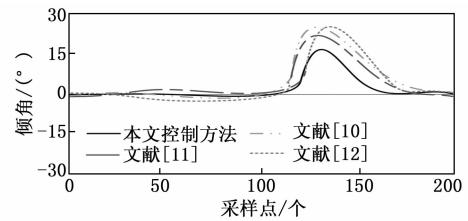


图 6 倾角控制采样点曲线拟合结果统计

如图 6 所示, 各控制算法均值在第 120 个采样点左右出现了较大的倾角波动, 此处为 L 型跑道的转弯处, 即在转弯处更容易出现倾角过大的情况, 也能突出显示出各控制算法的效果, 分别统计各控制算法倾角超过 25° 采样的数量及整个过程的采样点标准差, 统计结果如表 3 和表 4 所示。

表 3 超差的采样点数量统计

算法	本文控制方法	文献[10]	文献[11]	文献[12]
超差点数量/个	0	12	13	10

表 4 全过程采样点波动的标准差统计

算法	本文控制算法	文献[10]	文献[11]	文献[12]
标准差值	0.671	0.915	0.965	0.906

表 3 和表 4 的统计结果显示：本文提出控制算法并未出现超过  $25^\circ$  的倾斜情况，且全过程采样点波动的标准差值仅为 0.671，要显著低于 3 种传统的双轮自平衡控制算法。

### 3.2.2 平路行进速度控制与避碰实验

在存在 10 个障碍物的情况下进行避碰实验，并将机器人的倾角设定在  $25^\circ$  的安全区间，当机器人出现倾角过大时会主动降速，实验测试场地的障碍物布置情况如图 7 所示。

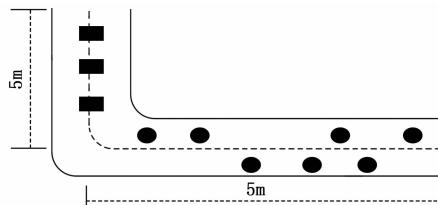


图 7 包含障碍物的场地布置情况

表 5 完成距离的时间对比

算法	本文控制算法	文献[10]	文献[11]	文献[12]
完成时间/s	19.5	23.2	24.1	23.9

表 6 与障碍物发生碰撞次数的对比

算法	本文控制算法	文献[10]	文献[11]	文献[12]
碰撞次数/次	0	2	1	3

在设定的双轮自平衡机器人固定倾角范围内，本文控制算法最先完成了整个路程，耗时 19.5 s，且没有与障碍物发生碰撞，其他 3 种传统控制方法的完成时间分别为 23.2、24.1 和 29.9 s。

### 3.2.3 关于坡路的实验控制

坡路实验在 L 型测试场地中增加了两组坡路，轮式机器人要上坡、坡顶和下坡（坡度均小于  $7.5^\circ$ ），如图 8 所示。

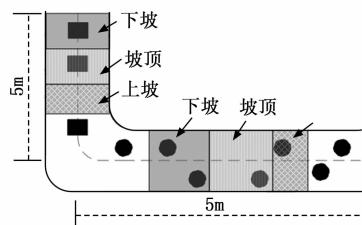


图 8 增加了坡路的场地设定

在增加两组坡路的情况下，仍旧随机采集了 200 个采样点，并将结果拟合成曲线，具体的统计结果如图 9

所示。

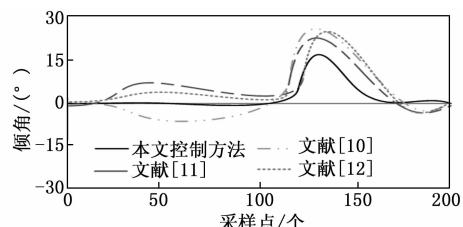


图 9 增加坡路的倾角控制采样点曲线拟合结果统计

在增加坡路后不仅在 120 个采样点出了较大的倾角波动，在两组坡路处也出现了倾角波动，但从拟合结果来看本文提出算法下的拟合效果仍旧优于 3 种传统的控制方法（标准差值的统计结果为 0.852），整个过程的采样点标准差统计结果如表 6 所示。

表 6 全过程采样点波动的标准差统计

算法	本文控制算法	文献[10]	文献[11]	文献[12]
标准差值	0.852	1.112	1.156	1.123

### 3.3 消融实验

本文提出的控制算法对经典的模糊神经网络 PID 算法进行了 4 重优化（线性处理，扰动补偿、噪声消除和自适应参数调节），若将未优化的模糊神经网络 PID 模型定为模型 A，经过线性处理的模型定为 B，再经过扰动补偿处理的模型定为 C，再经过噪声消除的模型定为模型 D，最后经过全优化的最终模型定为模型 E，各环节的贡献率分布情况如表 7 所示，各部分改进都对整个模型的优化起到了一定作用，尤其是自适应参数调节机制。

表 7 全过程采样点波动的标准差贡献率统计

标准差值	模型 A	模型 B	模型 C	模型 D	模型 E
未增加坡路	0.952	0.912	0.883	0.792	0.671
增加了坡路	1.102	1.002	0.988	0.971	0.852

## 4 结束语

双轮自平衡机器人凭借其灵活性特点在多个领域都有较为广泛的应用，但双轮自平衡机器人的稳定性较差，内置了陀螺仪和位移传感器，需要通过感知自身的倾角变化和速度变化而实时调整，而实时地动态调整会影响到机器人的工作效率，因此双轮自平衡机器人需要基于平衡的视角实施全局动态控制。现有控制方案存在工作效率与平衡控制矛盾的情况，为避免机器人倾倒只能以牺牲机器人的工作效率为代价。为解决现存矛盾本文提出一种基于四重优化的模糊自适应 PID 自动化控制方案，先在设定拉格朗日数据模型的基础上，形成一种机器人平衡的动态补偿机制，对模型做轻量化处理并

（下转第 236 页）