

基于变时域模型预测控制的车辆路径跟踪研究

胡 靖¹, 郑国君¹, 李伟东²

(1. 大连理工大学 力学与航空航天学院, 辽宁 大连 116024;

2. 大连理工大学 机械工程学院, 辽宁 大连 116024)

摘要: 为提高智能驾驶车辆使用 MPC 进行路径跟踪时应对不同工况的自适应能力, 提出了一种基于 RBF 神经网络与 SSA 优化算法的变时域模型预测控制方法: 基于车辆三自由度动力学模型搭建 MPC 控制器; 以此为基础, 利用 RBF 神经网络对不同车速、附着系数和时域参数下的横向误差值和航向角误差值进行预估; 将预估结果传递至 SSA 寻优以实现控制器预测时域和控制时域的实时优化; 建立 Simulink/Carsim 仿真模型对所提出的自适应 MPC 控制器进行仿真验证, 实验结果表明: 与固定时域 MPC 控制器和基于车速的自适应时域 Speed-MPC 控制器相比, 该控制策略在低速低附着、中速中附着和高速高附着 3 种工况下的横向及航向角误差的平均值和最大值均明显降低; 因此, 改进后的 AMPC 控制器具有良好的控制效果, 可以保证车辆路径跟踪的准确性和稳定性。

关键词: 智能驾驶; 路径跟踪; 模型预测控制; 麻雀搜索算法; 径向基神经网络

Research on Vehicle Path Tracking Based on Variable Time Domain Model Predictive Control

HU Jing¹, ZHENG Guojun¹, LI Weidong²

(1. School of Mechanics and Aerospace Engineering, Dalian University of Technology, Dalian 116024, China;

2. School of Mechanical Engineering, Dalian University of Technology, Dalian 116024, China)

Abstract: To improve the adaptive ability of intelligent driving vehicles in path tracking using model predictive control (MPC) under different working conditions, a predictive control method based on the radial basis function network (RBF) neural network and sparrow search algorithm (SSA) optimization algorithm for a variable time domain model is proposed, and an MPC controller based on vehicle three degree of freedom dynamic model is built. Based on this, the RBF neural network is used to estimate the lateral error and heading angle error values under different vehicle speeds, adhesion coefficients, and time-domain parameters. Transfer the estimated results to SSA optimization to achieve real-time optimization of controller prediction and control time domains. A Simulink/Carsim simulation model is established to verify the proposed adaptive MPC controller. Experimental results show that compared with the fixed time-domain MPC and vehicle speed based adaptive time-domain speed-MPC controller, the control strategy significantly reduces the average and maximum lateral and heading angle errors under three operating conditions: low-speed low adhesion, medium-speed medium adhesion, and high-speed high adhesion. Therefore, the improved adaptive model predictive control (AMPC) controller has a good control performance, which can ensure the accuracy and stability of vehicle path tracking.

Keywords: intelligent driving; path tracking; model predictive control; sparrow search algorithm; radial basis function network

0 引言

智能驾驶技术的普及及其适用速度范围的不断提

高, 意味着智能驾驶需要适应越来越多的复杂场景。在面对一些严峻工况时, 需综合考虑较大的曲率变化率和较差的附着条件带来的车辆横向失稳的可能性, 这对智

收稿日期:2024-12-05; 修回日期:2025-01-13。

基金项目:辽宁省科技创新重大专项资助项目(ZX20220560)。

作者简介:胡 靖(1999-), 男, 硕士研究生。

通讯作者:李伟东(1975-), 男, 博士, 副教授。

引用格式:胡 靖, 郑国君, 李伟东. 基于变时域模型预测控制的车辆路径跟踪研究[J]. 计算机测量与控制, 2025, 33(12): 128

能驾驶车辆路径跟踪的稳定性和准确性提出了较高的要求^[1-3]。

目前在车辆路径跟踪控制领域方面, 相关学者选择不同的控制方法来提高车辆控制器的精度和求解效率。传统控制方法有 PID 控制 (PID, proportional integral derivative)^[4]、滑模变结构控制^[5]、线性二次型调节器控制 (LQR, linear quadratic regulator)^[6]、模型预测控制 (MPC, model predictive control)^[7] 等。随着新兴技术在车辆路径跟踪控制领域的兴起, 强化学习^[8]、神经网络^[9]等方法也在路径跟踪领域得到广泛应用。其中 MPC 控制方法得到了广泛运用, 但在 MPC 控制的过程中不但要考虑车辆本身的运动学或者动力学模型约束, 同时还要结合实际的路面附着系数、道路曲率和车辆侧偏角等条件的约束。这意味着固定参数的 MPC 控制方法很难保证车辆在多工况下路径跟踪的稳定性与准确性, 因此国内外学者对自适应模型预测控制 (AMPC, adaptive model predictive control) 展开研究^[10-12]。文献 [13] 提出一种自适应路径跟踪的方法, 利用模糊控制对 MPC 控制器的时域参数展开实时优化的, 从而实现根据车辆实时车速对控制器时域参数的自适应选择, 提高了车辆在高速行驶工况下轨迹跟踪的精度和稳定性。文献 [14] 提出了一种基于可拓相平面稳定域划分的 Tube-MPC 车辆稳定性控制的方法, 用于自适应调节优化 MPC 目标函数权重、协调附加横摆力矩与前轮转角的控制, 提高了车辆在极限工况下的行驶稳定性与噪声干扰环境下的鲁棒性。文献 [15] 提出一种基于 MPC 的具有转角包络约束的路径跟踪控制器, 通过将转向角包络的全长预测范围分为两个不同的部分, 提高了车辆在非固定路面附着系数和车速工况下的跟踪精度和实时计算能力。文献 [16] 提出了一种基于优化动力学模型的自适应预测时域控制策略, 在侧倾转向和变形转向特性的优化模型基础上设计车速与道路曲率的自适应策略, 实现了预瞄距离的实时调整, 提高了车辆在高速大曲率等极限工况下的路径跟踪精度。文献 [17] 提出了一种基于协方差最小化的修正平方根容积卡尔曼滤波方法, 基于车辆路径跟踪误差模型构建自适应模型预测控制器来校正轮胎横向偏转刚度, 提高了车辆在低附着系数路面的路径跟踪精度和稳定性。文献 [18] 提出了一种具有不同复杂程度和保真度的车辆模型, 通过监督方案对比模型的预测误差和 MPC 的求解时间等代价, 在 MPC 的跟踪能力与计算复杂度之间进行自适应模型选择, 显著提高了 MPC 控制器的平均求解时间和跟踪精度。

综上研究, 针对固定时域 MPC 难以满足变化工况的问题, 为提高自动驾驶车辆对不同工况的适应能力和跟踪精度, 本文提出一种利用融合径向基神经网络

(RBF, radial basis function network) 的麻雀搜索算法 (SSA, sparrow search algorithm) 对可变时域自适应模型预测控制的路径跟踪策略。本文算法首先使用 RBF 神经网络对于车辆在行驶工况下的横向误差和航向角误差进行估计; 然后利用预估后的结果作为目标函数使用麻雀搜索算法进行寻优; 最后利用寻优所得结果作为改进后的 AMPC 控制器时域参数参与给定路径跟踪控制。

1 车辆动力学建模

为在准确描述车辆的动力学特性的同时降低控制器运算量和提高计算效率, 对车辆动力学模型进行简化: 忽略车辆自身的垂向运动与悬架系统, 忽略车辆转向系统, 以车辆前轮转角作为控制系统输入变量, 忽略车辆空气动力学的影响, 同时忽略轮胎滚动阻力、侧倾和回正力矩, 由此得到简化后的车辆三自由度模型, 如图 1 所示。

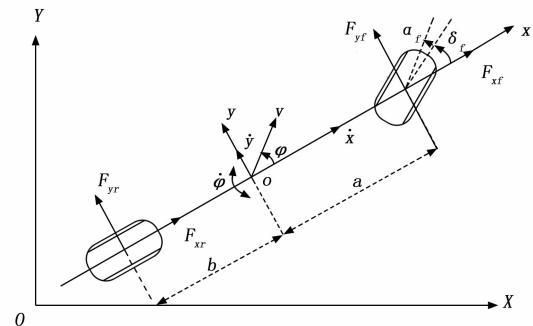


图 1 三自由度力学模型

图 1 中, XOY 代表惯性坐标系, xoy 代表车身坐标系, δ_f 车辆前轮的转角, F_{yf} 和 F_{yr} 分别为车辆前后轮所受的侧向力的合力, F_{xf} 和 F_{xr} 分别为车辆前后轮所受的纵向力的合力, 为车辆的横摆角速度, α_f 为车辆的前轮侧偏角, O 为车辆的质心, a 和 b 分别为车辆前后轴到质心距离。

根据牛顿第二定律和力矩平衡定律可得三自由度车辆动力学模型如式 (1) 所示:

$$\begin{cases} m(\ddot{x} - \dot{y}\varphi) = 2F_{xf} + 2F_{xr} \\ m(\ddot{y} + \dot{x}\varphi) = 2F_{yf} + 2F_{yr} \\ I_z\ddot{\varphi} = 2aF_{yf} - 2bF_{yr} \end{cases} \quad (1)$$

$$\dot{Y} = v_x \sin \varphi + v_y \cos \varphi$$

$$\dot{X} = v_x \cos \varphi - v_y \sin \varphi$$

其中: m 为车辆整备质量, I_z 为车辆绕 z 轴的转动惯量。

根据轮胎模型可知, 当车轮侧偏角较小时, 车轮的侧偏角与侧偏力近似为线性关系。基于小角度假设, 将轮胎横向力近似为:

$$\begin{cases} F_{yf} = C_{cf}\alpha_f \\ F_{yr} = C_{cr}\alpha_r \end{cases} \quad (2)$$

其中: C_{cf} 和 C_{cr} 分别为车辆前后轮侧偏刚度, α_f 和 α_r 分别为车辆前后轮侧偏角, 结合刚体运动学得计算公式为:

$$\begin{cases} \alpha_f = \frac{v_y + \dot{\varphi}a}{v_x} - \delta_f \\ \alpha_r = \frac{v_y - \dot{\varphi}b}{v_x} \end{cases} \quad (3)$$

考虑车轮与地面的滑移作用, 尤其当车辆行驶在路面附着系数较小的工况下时, 轮胎的滑移作用会对车轮的纵向力有较大影响, 依据小角度假设和线性轮胎模型, 将轮胎纵向力近似为:

$$\begin{cases} F_{xf} = C_{lf}s_f \\ F_{xr} = C_{lr}s_r \end{cases} \quad (4)$$

其中: C_{lf} 和 C_{lr} 为车辆前后轮的纵向侧偏刚度, s_f 和 s_r 分别为车辆前后轮的滑移率, 其计算公式为:

$$s = \frac{v_c - \omega r}{v_c} \quad (5)$$

其中: v_c 为车轮轮心的纵向速度, ω 为车轮转动角速度, r 为车轮的滚动半径。

将式 (2) ~ (5) 代入式 (1) 中可得车辆三自由度动力学模型, 将其转换为空间状态方程:

$$\dot{\mathbf{X}} = f(\mathbf{X}, \mathbf{u}) \quad (6)$$

式中, 状态量 $\mathbf{X} = [\dot{y}, \dot{x}, \dot{\varphi}, \dot{\varphi}, Y, X]$, 控制量 $u = \delta_f$ 。

2 自适应预测时域控制器设计

图 2 为自适应可变时域模型预测控制器结构图, 该控制器利用 RBF 神经网络基于车速、路面附着系数和时域参数等信息对横向误差 e_d 及航向角误差 e_φ 进行预测; 在得到预测信息后结合麻雀搜索算法对控制器的时域参数进行寻优; 最后结合参考路径和自车状态量信息进行计算, 将得出的前轮转角 δ_f 信息反馈给 Carsim 模型, 完成车辆路径跟踪的闭环控制。

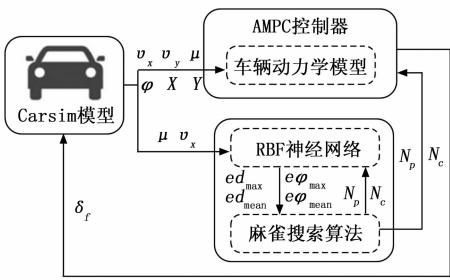


图 2 自适应 MPC 控制器结构图

2.1 MPC 控制器设计

模型预测控制通过对给定预测时域内的系统状态量进行预测, 计算出系统最优控制输入, 以满足性能指标和约束条件, 故本文选择用 MPC 控制器进行车辆横向路径跟踪控制^[19]。以非线性的车辆三自由度模型的状态空间方程作为预测模型, 计算跟踪理想横向位置和横

摆角速度所需的前轮转角量。

为减小车辆行驶过程中的计算量, 提高控制器的计算效率, 对控制系统的空间状态方程进行线性化和离散化。对系统进行一阶泰勒展开线性化, 并分别利用中点欧拉法和向前欧拉法对系统的状态量和控制量进行离散化处理, 得到离散形式的状态方程为:

$$\begin{cases} \mathbf{X}(k+1) = \mathbf{A}_k \mathbf{X}(k) + \mathbf{B}_k \mathbf{u}(k) \\ \mathbf{\eta}(k) = \mathbf{C}_k \mathbf{X}(k) \end{cases} \quad (7)$$

其中: $\mathbf{X}(k)$ 为 k 时刻的状态量, $\mathbf{u}(k)$ 为 k 时刻的控制量。 $\mathbf{A}_k = \left(\mathbf{I} + \frac{\mathbf{A}(t)dt}{2} \right) \left(\mathbf{I} - \frac{\mathbf{A}(t)dt}{2} \right)^{-1}$, $\mathbf{B}_k = \mathbf{B}(t)dt$; $\mathbf{A}(t)$ 、 $\mathbf{B}(t)$ 为状态量和控制量的雅各比矩阵, \mathbf{I} 为单位矩阵, dt 为系统采样时间, $\mathbf{\eta}(k)$ 为 k 时刻控制系统的输出量:

$$\mathbf{\eta} = [X \ Y \ \varphi]^T \quad (8)$$

在车速或道路曲率变化发生时, 控制量可能会发生较大变动导致车辆出现失稳的情况。为防止此问题的发生, 引入控制增量来对单位时间内的控制增量进行约束。将状态变量与控制变量相结合, 得到扩维的状态变量:

$$\begin{cases} \tilde{\mathbf{X}}(k+1) = \tilde{\mathbf{A}}_k \tilde{\mathbf{X}}(k) + \tilde{\mathbf{B}}_k \Delta \mathbf{u}(k) \\ \mathbf{\eta}(k) = \tilde{\mathbf{C}}_k \tilde{\mathbf{X}}(k) \end{cases} \quad (9)$$

其中: $\tilde{\mathbf{X}}(k) = [\mathbf{X}(k), \mathbf{u}(k-1)]^T$, $\tilde{\mathbf{A}}_k = \begin{bmatrix} \mathbf{A}_k & \mathbf{B}_k \\ \mathbf{0}_{m \times n} & \mathbf{I}_m \end{bmatrix}$, $\tilde{\mathbf{B}}_k = [\mathbf{B}_k, \mathbf{I}_m]^T$, $\tilde{\mathbf{C}}_k = [\mathbf{C}_k, 0]$, n 为系统状态量维度值, m 为系统控制量维度值。

设置控制系统的预测时域和控制时域参数分别为 N_p 和 N_c , 对预测试域内的控制输出进行滚动优化, 得到控制系统的输出序列为:

$$\mathbf{Y}(k) = \boldsymbol{\psi} \tilde{\mathbf{X}}(k) + \boldsymbol{\Theta} \Delta \mathbf{U}(k) \quad (10)$$

其中:

$$\mathbf{Y}(k) = \begin{bmatrix} \mathbf{\eta}(k+1) \\ \mathbf{\eta}(k+2) \\ \vdots \\ \mathbf{\eta}(k+N_p) \end{bmatrix}, \boldsymbol{\psi} = \begin{bmatrix} \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k \\ \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k^2 \\ \vdots \\ \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k^{N_p} \end{bmatrix},$$

$$\boldsymbol{\Theta} = \begin{bmatrix} \tilde{\mathbf{C}}_k \tilde{\mathbf{B}}_k & \cdots & 0 & 0 \\ \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k \tilde{\mathbf{B}}_k & \tilde{\mathbf{C}}_k \tilde{\mathbf{B}}_k & \cdots & 0 \\ \vdots & \vdots & \cdots & \vdots \\ \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k^{N_p-1} \tilde{\mathbf{B}}_k & \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k^{N_p-2} \tilde{\mathbf{B}}_k & \cdots & \tilde{\mathbf{C}}_k \tilde{\mathbf{B}}_k \\ \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k^N \tilde{\mathbf{B}}_k & \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k^{N_p-1} \tilde{\mathbf{B}}_k & \cdots & \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k \tilde{\mathbf{B}}_k \\ \vdots & \vdots & \cdots & \vdots \\ \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k^{N_p} \tilde{\mathbf{B}}_k & \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k^{N_p-1} \tilde{\mathbf{B}}_k & \cdots & \tilde{\mathbf{C}}_k \tilde{\mathbf{A}}_k^{N_p-N_c-1} \tilde{\mathbf{B}}_k \end{bmatrix},$$

$$\Delta \mathbf{U}(k) = [\Delta u(k), \Delta u(k+1), \dots, \Delta u(k+N_c)]^T.$$

车辆的路径跟踪过程, 其目的是尽量减小车辆位置与目标路径的误差值, 同时保持车辆的稳定性, 使车辆可以精确而稳定地进行路径跟踪。因此在 MPC 控制器对预测时域内的控制序列进行求解时, 设计目标函

数为:

$$J(t) = \sum_{i=1}^{N_p} \|\mathbf{Y}(t+i) - \mathbf{Y}_r(t+i)\|_Q^2 + \sum_{i=1}^N \|\Delta u(t+i)\|_R^2 + \rho \epsilon^2 \quad (11)$$

其中: 第一项为控制系统输出与车辆目标轨迹之间的误差, 用以表示车辆在路径跟踪时的准确性; 第二项为控制系统输入的变化量, 用以表示车辆路径跟踪时的平稳性; $\mathbf{Y}(t+i)$ 和 $\mathbf{Y}_r(t+i)$ 表示从 t 时刻开始, 预测时域内第 i 个时刻的系统预估输出值及期望输出值; Q 、 R 分别表示系统在跟踪过程中精确性和平稳性的权重; ϵ 为松弛因子, ρ 为松弛因子权重, 通过这项参数来保证在进行二次规划问题求解时有最优解。

在控制器求解过程中, 为了保证车辆能够对给定的参考路径进行准确跟踪, 需要考虑执行机构的约束和能够保持车辆平稳驾驶的控制量及控制增量的约束, 将它们限制在合理的范围内:

$$\begin{cases} \mathbf{U}_{\min} \leq \mathbf{U} \leq \mathbf{U}_{\max} \\ \Delta \mathbf{U}_{\min} \leq \Delta \mathbf{U} \leq \Delta \mathbf{U}_{\max} \end{cases} \quad (12)$$

由于轮胎只在线性特性区间内侧向力与侧偏角之间近似成线性关系, 同时车辆三自由度动力学模型基于小角度假设建立, 因此将车辆侧偏角限制为:

$$-2.5^\circ \leq \alpha \leq 2.5^\circ \quad (13)$$

为保证车辆稳定行驶, 需要对车辆质心侧偏角进行限制: 博世公司经实验分析得出, 在高附着系数路面上, 车辆质心侧偏角极限值为 $\pm 12^\circ$; 在附着系数路面上, 极限值降低至 $\pm 2^\circ$ ^[20]。

综上, 在每个周期内对式 (11) 的有约束二次型问题进行求解, 得到 $N_c \times 1$ 的控制增量序列, 取序列首个元素作为控制增量输入。

2.2 RBF 神经网络设计

时域参数 N_p 和 N_c 是自适应 MPC 控制器的重要参数, 在保持控制器参数不变的情况下, 时域参数决定了控制器的预测精度和控制精度^[21]。当预测时域 N_p 较大时, 控制器会增强对较远距离的车辆状态信息和障碍物的预测, 但同时也会增加控制器的计算成本和结果预测误差。当预测时域 N_p 值较小时, 控制器会倾向于对近处障碍物信息的处理, 但也会导致控制器预测能力的降低, 出现无法及时转向和路径跟踪失败等问题。当控制时域 N_c 取较大值时, 可以提高控制器的跟踪精度和控制器的稳定性, 但同时也降低了控制系统响应的实时性。当控制时域参数 N_c 较小时, 可以减小控制器计算量, 提升响应速度, 但同时会导致控制器在跟踪时可能会出现超调现象, 降低车辆的跟踪精度。

在实际的驾驶过程中, 车辆会遇到不同速度和路面附着系数路面的驾驶工况, 而传统 MPC 控制器固定的

时域参数不能满足车辆在不同工况下的路径跟踪需求, 不匹配的时域参数会导致车辆的路径跟踪能力急剧下降^[22]。本文利用麻雀搜索算法和 RBF 神经网络相结合对 MPC 控制器的时域参数进行自适应优化, 使车辆在面对不同工况下时都能以最理想的状态进行横向路径跟踪。

在对控制器时域参数进行自适应优化时需要对不同参数的跟踪结果进行对比。选取横向误差 e_d 和航向角误差 e_φ 作为优化的评价指标。在时域参数优化过程中, 需要对不同的车速 v 、路面附着系数 μ 、时域参数 N_p 和 N_c 组成的不同工况对应的评价指标做出准确的预估。

径向基神经网络 (RBF) 是前馈神经网络, 其包含了输入、隐含和输出三层, 具有快速的收敛速度和极强的容错性, 这使其在复杂问题处理中展现出较高的性能^[23]。本文利用 RBF 网络对车一路信息和横向跟踪评价指标之间的映射关系进行学习, 获得用于在线控制的评价指标预测模型。

设置 RBF 网络的输入为车速、路面附着系数和控制器时域参数; 输出为横向和航向角误差的平均值和最大值; 在此基础上, 将模型输出层权重以较小的随机值初始化, 以打破权重初始值对称性, 使网络输出与实际输出之间的误差最小化。

车辆路径跟踪系统为非线性系统, 而高斯核函数可以将多维样本输入数据映射到高维空间, 使得原本线性不可分的数据变得线性可分, 因此 RBF 网络采用标准高斯激活函数:

$$\varphi(\mathbf{x}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}\|^2}{2\sigma^2}\right) \quad (14)$$

其中: 向量 \mathbf{x} 为网络的输入; \mathbf{c} 为网络中心位置矢量; σ 为基函数标准差。RBF 网络结构如图 3 所示。

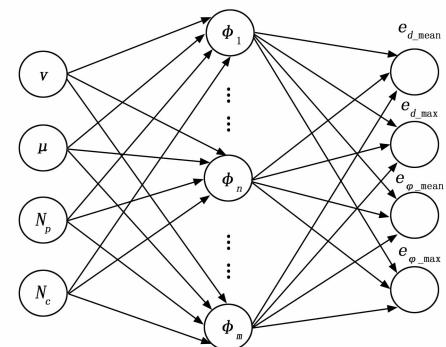


图 3 RBF 神经网络结构图

2.3 融合 RBF 网络的麻雀搜索算法

为对控制器的时域参数进行优化, 将麻雀搜索算法引入到 AMPC 控制器中。通过优化算法对控制器的预测时域和控制时域参数进行寻优, 找到不同行驶工况最

适应的时域参数, 以提高车辆跟踪精度。

麻雀搜索算法将粒子种群划分为发现者、跟随者和警戒者 3 种类型, 通过模拟麻雀群体捕食和反捕食的行为对参数进行寻优^[24]。在迭代的过程中, 将适应度函数较优的个体定义为发现者, 通过发现者的位置来对整个种群中的个体位置进行引导, 同时不断更新发现者的位置, 以避免种群陷入局部最优当中, 发现者的位置更新公式如下:

$$x_{i,j}^{t+1} = \begin{cases} x_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \cdot T_{\max}}\right), & R_2 < ST \\ x_{i,j}^t + Q \cdot \mathbf{L}, & R_2 \geq ST \end{cases} \quad (15)$$

其中: $x_{i,j}^t$ 表示在第 t 轮迭代中第 i 个个体的第 j 维所处位置; α 为 $(0,1]$ 随机数, T_{\max} 为优化算法最大迭代次数; Q 为符合正态分布的随机数, \mathbf{L} 为元素值均为 1 的 $1 \times \dim$ 矩阵, \dim 为维度值; R_2 和 ST 分别为警戒值和安全值, 其中 $R_2 \in (0.5, 1]$, $ST \in (0.5, 1]$; 当警戒值超过安全值时表示当前区域有危险, 需到别的安全区域搜索, 反之当前区域安全, 可以继续进行搜索。

追随者为种群中适应度较差的群体, 应该追随发现者的位置来更新自身位置, 其位置更新公式为:

$$x_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{x_{\text{worst}} - x_{i,j}^t}{i^2}\right), & i > \frac{n}{2} \\ x_p^{t+1} + |x_{i,j}^t - x_p^{t+1}| \cdot \mathbf{A}^+ \cdot \mathbf{L}, & i \leq \frac{n}{2} \end{cases} \quad (16)$$

式中, x_{worst} 表示全局最差位置, x_p^t 在第 t 轮迭代时的最优位置; \mathbf{A} 为元素值随机为 1 或 -1 的 $1 \times \dim$ 矩阵, $\mathbf{A}^+ = \mathbf{A}^T (\mathbf{A}\mathbf{A}^T)^{-1}$; n 为种群数量, 当 $i > n/2$ 时个体适应度较差, 需要到其余区域进行搜索, 而剩余追随者个体则可以围绕在发现者附近区域进行搜索。

为在增强算法全局搜索能力的同时避免忽视局部搜索效率, 经多次实验对比后从种群中随机选取 15% 的个体作为警戒者, 确保算法既具备足够引导能力而不过度依赖特定个体。其位置更新公式如下:

$$x_{i,j}^{t+1} = \begin{cases} \chi_{\text{best}}^t + \beta |\chi_{i,j}^t - \chi_{\text{best}}^t|, & f_i > f_g \\ x_{i,j}^t + k \left(\frac{|\chi_{i,j}^t - \chi_{\text{worst}}^t|}{(f_i - f_w) + \epsilon} \right), & f_i = f_g \end{cases} \quad (17)$$

其中: χ_{best}^t 为全局最优位置, β 为步长修正系数, 服从标准分布; f_i 为当前个体适应度, f_g 和 f_w 分别为全局最优和最差适应度; $k \in (0,1]$ 为随机数, ϵ 为极小数; 当个体适应度大于 f_g 时, 个体位于种群边缘危险区域, 需要向全局最优位置靠近; 当个体适应度等于 f_g 时, 说明个体处于种群中心, 通过随机扰动远离全局最差位置。

在控制器时域参数优化过程中, RBF 神经网络通过其强大的非线性拟合能力和快速学习特性, 能够有效捕捉系统的复杂动态关系, 但其在全局搜索和避免局部最优等方面能力不足; 而麻雀搜索算法具有良好的全局

搜索能力和较强的跳出局部最优陷阱的能力, 但在处理高维度和复杂非线性问题时其可能面临收敛速度慢和计算资源消耗较大的问题。本文将 RBF 神经网络与麻雀算法进行融合, 在提升模型预测精度的同时, 增强优化过程的鲁棒性和计算效率, 避免了单一方法可能出现的局部最优问题。

因麻雀搜索算法的优化参数包含预测时域 N_p 和控制时域 N_c , 故设定个体维度 $\dim=2$ 。在车辆进行路径跟踪的过程中, 每当输入的车速和路面附着系数变化值超过限定范围时, 通过融合 RBF 网络的麻雀搜索算法对 AMPC 控制器的预测时域和控制时域进行寻优, 设置车速和路面附着系数变化的限定范围为 $|\Delta v| \leq 5 \text{ km/h}$ 、 $|\Delta \mu| \leq 0.1$ 。首先, 初始化麻雀搜索算法种群, 确定初始化个体的初始值; 之后, 将初始化个体值对应的时域参数和当前工况下的车速及路面附着系数输入到训练好的 RBF 模型中, 通过 RBF 产生的预测结果使控制器的横向误差平均值 e_{d_mean} 、横向误差最大值 e_{d_max} 、航向角误差平均值 e_{φ_mean} 、航向角误差最大值 e_{φ_max} 与 N_p 、 N_c 建立映射关系, 对麻雀搜索算法种群的适应度函数进行评估。同时, 为使在优化结果保持不变的同时能够尽量减小控制器计算量、提高计算效率, 将 N_p 和 N_c 引入优化算法的适应度函数中, 实现在个体适应度相近时, 使用较小的时域参数对车辆进行控制。最后, 通过不断的迭代寻优, 得出最优适应度对应的时域参数 N_p 、 N_c , 将其带入 AMPC 控制器中完成路径跟踪。

在适应度函数中, 由于各个变量的数量级不同, 需要对其进行归一化, 避免由于数量级差异对适应度函数产生较大影响, 其归一化公式如下:

$$X_{i_nor} = \frac{X_i - X_{i_min}}{X_{i_max} - X_{i_min}} \quad (18)$$

其中: X_{i_nor} 为变量的归一化值, X_{i_max} 和 X_{i_min} 变量的最大值和最小值。

将归一化变量带入适应度函数, 设计函数如下:

$$fitness(i) = \omega_1 E_{\text{mean}} + \omega_2 E_{\text{max}} + \omega_3 N \quad (19)$$

其中: ω_1 为误差平均值在适应度函数中的权重, $E_{\text{mean}} = [e_{d_mean}, e_{\varphi_mean}]^T$; ω_2 代表误差最大值在适应度中权重, $E_{\text{max}} = [e_{d_max}, e_{\varphi_max}]^T$; ω_3 代表时域参数在适应度中的权重, $N = [N_p, N_c]^T$; 其中各项权重矩阵的元素总和为 1。

综上, 可以得出融合 RBF 网络的麻雀搜索算法, 其运行流程原理如图 4 所示。

3 仿真实验与分析

为验证融合 RBF 网络的麻雀搜索算法对时域参数自适应调节的优势, 本文采用 Matlab/Simulink 和 Car-sim 进行联合仿真。对比算法为传统 MPC 控制器和基

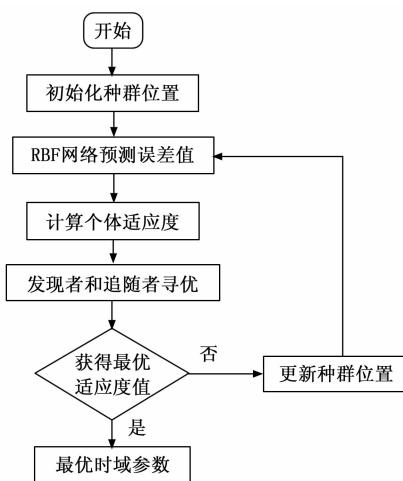


图 4 麻雀搜索算法对时域参数的调节

于车速的自适应时域 Speed-MPC 控制器; 仿真场景选取双移线工况下的高速干沥青路面、中速潮湿路面和低速雨雪覆盖路面, 以验证在交叉工况下本文所提出的 AMPC 控制器的横向跟踪能力。在 Carsim 软件中选取 E-class, sedan 车型作为仿真车辆; 经多次仿真实验后选取控制效果最优的控制权重, 整车及控制器参数见表 1。

表 1 整车及 AMPC 参数

整车质量 m/kg	转动惯量 I_z	前轮侧偏刚度 C_f	后轮侧偏刚度 C_r
1 840	3 234	-67 600	-62 700
质心到前轴 距离 l_z/m	质心到后轴 距离 l_r/m	横向偏差权重	航向偏差权重
1.40	1.65	8 000	2 000
控制量权重 R	控制周期 T/s	松弛因子权重 ρ	转角增量 $\Delta\theta_f/\text{deg}$
10 000	0.01	500	$[-0.8, 0.8]$

3.1 RBF 网络模型训练仿真

通过大量仿真实验, 建立车速、路面附着系数和时域参数的映射关系。对跟踪结果的横向误差平均值 e_{d_mean} 、横向误差最大值 e_{d_max} 、航向角误差平均值 e_{φ_mean} 、航向角误差最大值 e_{φ_max} 进行分析处理, 整理为数据集, 其中输入参数的取值范围见表 2。

表 2 输入参数取值范围

参数	$v/(\text{km}/\text{h})$	μ	N_p	N_c
范围	$[36, 72]$	$[0.4, 0.85]$	$[10, 36]$	$[5, N_p-1]$

其中, 将车速划分为低中高 3 种类型, 分别对应 36、54 和 72 km/h; 将路面附着系数划分为低附着系数 0.4, 中附着系数 0.6, 高附着系数 0.85。对输入参数进行排列组合, 将仿真结果组成的 3 858 组数据随机排列, 其中 80% 作为训练集, 20% 作为验证集, 对 RBF

神经网络进行训练。RBF 神经网络在进行 300 次迭代后, 均方误差为。

RBF 网络的训练效果如表 3 所示, 可以看出此时 RBF 神经网络得拟合效果较好, 输出变量的预测值与真实值较为接近, 训练和验证的效果符合预期。

表 3 RBF 训练效果

输出变量	e_{d_mean}	e_{d_max}	e_{φ_mean}	e_{φ_max}
训练集 RMSE	0.010 8	0.035 1	0.001 7	0.009 1
训练集 R^2	0.997 4	0.997 9	0.993 7	0.984 6
测试集 RMSE	0.010 1	0.033 8	0.001 6	0.008 2
测试集 R^2	0.997 7	0.998 1	0.994 3	0.987 2

综上所述, 训练好的 RBF 神经网络模型可以实现对于给定工况下车辆路径跟踪的横向误差和航向角误差的平均值和最大值的预测。其中输入值为当前工况下的车速、路面附着系数以及给定的控制器时域参数。将预测结果传递给优化算法, 作为进行控制器时域参数寻优时的评价指标。

3.2 低速雨雪覆盖路面工况仿真

在低附着系数工况下, 路面的极限附着力会随着附着系数的降低而迅速降低, 需要控制器提供精确地控制, 故选取低速雨雪覆盖路面作为仿真工况。设置仿真工况下车速为 36 km/h, 路面附着系数为 0.3。

AMPC 控制器通过麻雀搜索算法进行寻优, 将不同个体的时域参数、路面附着系数和车速传入 RBF 神经网络中, 对车辆的横向误差值和航向角误差值进行预测。将 RBF 预测结果带入目标函数中对个体适应度值进行计算, 最后得出最优适应度所对应的控制器预测时域和控制时域分别为 16 和 5; 传统固定时域 MPC 控制器的时域参数分别选定为 20 和 15; Speed-MPC 控制器的时域参数在当前车速下为 14 和 9, 其它参数保持不变。在设定工况下对车辆双移线工况路径进行跟踪, 图 5 为融合 SSA-RBF 算法的 AMPC 控制器、Speed-MPC 控制器和传统 MPC 控制器在低速低附着系数工况下路径跟踪精度的对比。

图 5 (a) 为 3 种控制器在低速低附着系数工况下的路径跟踪曲线。在该工况下 3 种控制器均可稳定地对给定路径进行跟踪, 且并未产生振荡。图 5 (b) 为车辆路径跟踪横向误差曲线, 从中可以看出 AMPC 控制器在跟踪过程中产生的横向误差平均值和最大值均小于传统 MPC 控制器和 Speed-MPC 控制器, 并且收敛后未产生稳态误差。图 5 (c) 为车辆路径跟踪航向角误差曲线, 从中可以看出 AMPC 控制器航向角误差平均值和最大值也均小于其他两种控制器。表 4 为车辆在低速低附着系数工况下的路径跟踪误差。

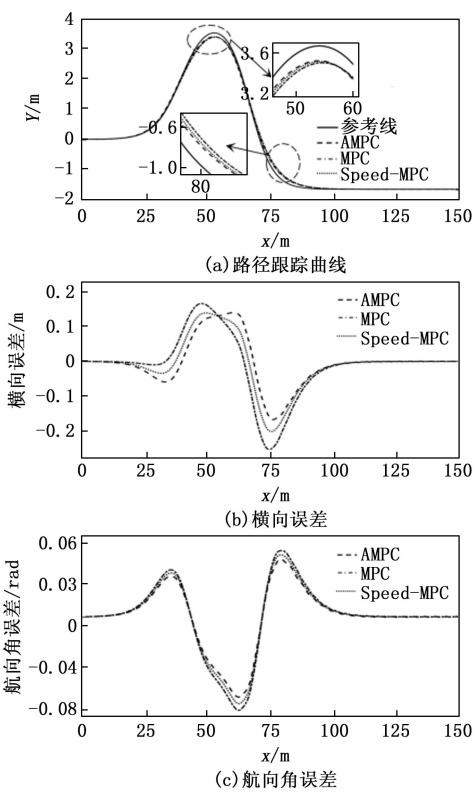


图 5 低速工况下路径跟踪精度对比

表 4 低速工况路径跟踪误差

控制器	e_d _mean / m	e_d _max / m	e_φ _mean / rad	e_φ _max / rad
AMPC	0.040	0.157	0.014	0.061
Speed-MPC	0.042	0.190	0.016	0.066
MPC	0.049	0.239	0.017	0.071

如表 4 所示, AMPC 控制器平均横向误差和最大横向误差比传统 MPC 控制器减小 18.36% 和 34.31%, 比 Speed-MPC 控制器减小 4.76% 和 17.37%; 平均航向误差和最大航向误差比传统 MPC 控制器减小 17.65% 和 14.08%, 比 Speed-MPC 控制器减小 12.50% 和 7.58%。

3.3 中速潮湿路面工况仿真

中速潮湿路面是车辆经常会面对的行驶工况, 因此选取此工况作为仿真验证工况之一。设置仿真工况下车速为 54 km/h, 路面附着系数为 0.6。

在此工况下, 保持固定时域 MPC 时域参数为 20 和 15; AMPC 控制器的时域参数经优化后选取为 15 和 9; Speed-MPC 控制器在此车速下时域参数选取为 19 和 14, 其它参数保持不变。

表 5 为此工况下的车辆路径跟踪误差。

如表 5 所示, 在此工况下 AMPC 控制器的平均横向误差和最大横向误差比传统 MPC 控制器分别减小 32.73% 和 42.09%, 比 Speed-MPC 控制器减小 27.45% 和 39.01%; 平均航向误差和最大航向误差比传统 MPC

控制器分别减小 23.08% 和 12.96%, 比 Speed-MPC 控制器减小 16.67% 和 9.62%。

表 5 中速工况路径跟踪误差

控制器	e_d _mean / m	e_d _max / m	e_φ _mean / rad	e_φ _max / rad
AMPC	0.037	0.172	0.010	0.047
Speed-MPC	0.051	0.282	0.012	0.052
MPC	0.055	0.297	0.013	0.054

3.4 高速沥青路面工况仿真

当车辆在高速沥青路面行驶时, 由于较高的车速往往会导致车辆路径跟踪的效果降低, 故选取此仿真工况作为仿真验证工况之一。设置仿真工况下车速为 72 km/h, 路面附着系数为 0.85。

在此工况下, 传统固定时域 MPC 控制器的预测时域和控制时域仍选定为 20 和 15; AMPC 控制器经优化后选取时域参数为 25 和 11; Speed-MPC 控制器时域参数在此车速下选取为 23 和 18, 其它参数保持不变。3 种控制器在高速高附着系数工况下路径跟踪精度的对比如图 6 所示。

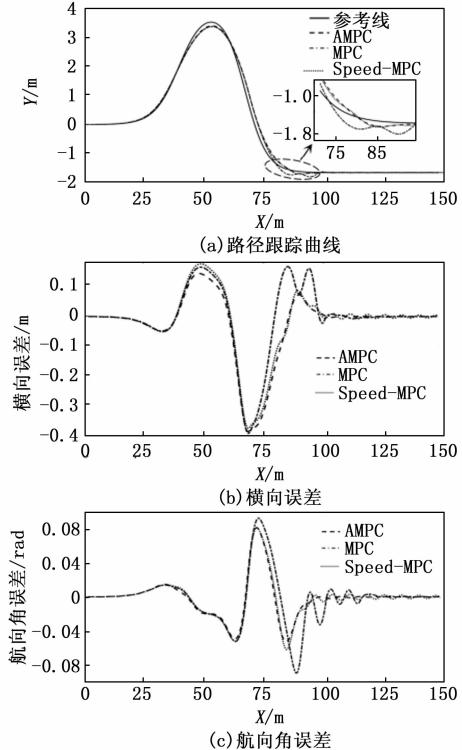


图 6 高速工况下路径跟踪精度对比

从图 6 中可以看出, 传统 MPC 控制器和 Speed-MPC 控制器在进行转向时横向误差和航向角误差均会产生振荡, 导致车辆的路径跟踪不能及时收敛, 从而影响车辆路径跟踪的安全性和稳定性, 在实车上表现为车辆围绕给定路径产生画龙现象; 而 AMPC 控制器的轨迹跟踪效果在恢复直线跟踪时能够迅速收敛, 并未产生

振荡。表 6 为车辆在高速高附着系数工况下的路径跟踪误差。

表 6 高速工况路径跟踪误差

控制器	e_{d_mean} /m	e_{d_max} /m	e_{φ_mean} /rad	e_{φ_max} /rad
AMPC	0.063	0.393	0.012	0.082
Speed-MPC	0.066	0.389	0.014	0.082
MPC	0.074	0.401	0.019	0.093

如表 6 所示, 在此工况下 AMPC 控制器的轨迹跟踪效果仍然明显优于其余两种控制器。AMPC 控制器的平均横向误差和最大横向误差比传统 MPC 控制器分别减小 14.86% 和 2.0%, 平均航向误差和最大航向误差比传统固定时域 MPC 控制器分别减小 31.58% 和 11.83%。

综上所述, 本文所设计的基于融合 RBF 神经网络的麻雀算法的自适应控制器能够有效地减少车辆路径跟踪过程中产生的横向误差和航向角误差的平均值和最大值。同时还能够减少在车辆对参考路径进行跟踪时所产生的振荡现象, 提高了车辆路径跟踪的稳定性和准确性, 具有较高的鲁棒性。

4 结束语

本文提出了基于融合 RBF 神经网络的麻雀搜索算法的自适应 MPC 控制器, 对给定路径进行横向跟踪。首先, 根据车辆三自由度模型搭建了 MPC 路径跟踪控制器; 其次, 对 RBF 神经网络进行训练, 从而实现对不同车速、附着系数和时域参数下的横向误差值和航向误差值进行预估; 然后, 将 RBF 模型预估结果传递给麻雀搜索算法以实现控制器预测时域和控制时域的实时优化, 从而提高车辆的在横向跟踪过程中的精度; 最后, 搭建联合仿真模型对车辆在低速冰雪路面、中速潮湿路面和高速沥青路面 3 种工况下进行仿真验证, 仿真结果表明本文提出的 AMPC 控制器能明显的减小车辆在跟踪过程中的横向误差和航向误差, 同时还可降低跟踪过程中车辆航向角的振荡现象, 提高了车辆路径跟踪的准确性和稳定性。

本文设计的控制器并未考虑车辆参数变化, 后续会针对车辆参数变动对路径跟踪带来的影响进行研究, 进一步提升控制精度和效果。

参考文献:

- [1] 熊璐, 杨兴, 卓桂荣, 等. 无人驾驶车辆的运动控制发展现状综述 [J]. 机械工程学报, 2020, 56 (10): 127–143.
- [2] LEE J, CHOI S. Integrated control of steering and braking for path tracking using multi-point linearized MPC [J]. IEEE Transactions on Intelligent Vehicles, 2023, 8 (5): 3324–3335.
- [3] LEE J, HWANG Y, CHOI S B. Robust tube-MPC based steering and braking control for path tracking at high-speed driving [J]. IEEE Transactions on Vehicular Technology, 2023, 72 (12): 15301–15316.
- [4] LI R, DENG S, HU Y. Autonomous vehicle modeling and velocity control based on decomposed fuzzy PID [J]. International Journal of Fuzzy Systems, 2022, 24 (5): 2354–2362.
- [5] 葛程, 李伟东, 黄振柱, 等. 基于模糊终端滑模控制器的路径跟踪横向控制策略 [J]. 大连理工大学学报, 2024, 64 (4): 376–383.
- [6] ZHENG Z, YE Z, ZHENG X. Intelligent vehicle lateral control strategy research based on feedforward+predictive LQR algorithm with GA optimisation and PID compensation [J]. Scientific Reports, 2024, 14 (1): 22317.
- [7] STANO P, MONTANARO U, TAVERNINI D, et al. Model predictive path tracking control for automated road vehicles: a review [J]. Annual Reviews in Control, 2023, 55: 194–236.
- [8] YAO J, GE Z. Path-tracking control strategy of unmanned vehicle based on DDPG algorithm [J]. Sensors, 2022, 22 (20): 12.
- [9] SIEBERG P, HUERTEN C, SCHRAMM D. Representation of an integrated non-linear model-based predictive vehicle dynamics control system by a coactive neuro-fuzzy inference system [C] //2020 IEEE Intelligent Vehicles Symposium (IV), 2020: 572–577.
- [10] JALALI M, HASHEMI E, KHAJEPOUR A, et al. A combined-slip predictive control of vehicle stability with experimental verification [J]. Vehicle System Dynamics, 2018, 56 (2): 319–340.
- [11] LI Y, FAN J, LIU Y, et al. Path planning and path tracking for autonomous vehicle based on MPC with adaptive dual-horizon-parameters [J]. International Journal of Automotive Technology, 2022, 23 (5): 1239–1253.
- [12] MENG Q, QIAN C, CHEN K, et al. Variable step MPC trajectory tracking control method for intelligent vehicle [J]. Nonlinear Dynamics, 2024, 112 (21): 19223–19241.
- [13] 范贤波, 彭育辉, 钟聰. 基于自适应 MPC 的自动驾驶汽车轨迹跟踪控制 [J]. 福州大学学报 (自然科学版), 2021, 49 (4): 500–507.
- [14] 苏东旭, 赵治国, 赵坤, 等. 基于可拓相平面稳定域划分的 Tube-MPC 车辆稳定性控制 [J]. 汽车工程, 2024, 46 (9): 1654–1667.
- [15] CUI Q, DING R, WEI C, et al. Path-tracking and lateral stabilisation for autonomous vehicles by using the steering angle envelope [J]. Vehicle System Dynamics,

2020: 1–25.

[16] 何智成, 王煜凡, 韦宝倡, 等. 基于优化动力学模型的路径跟踪控制研究 [J]. 中国机械工程, 2024, 35 (6): 1000–1009.

[17] YANG S, QIAN Y, HU W, et al. Adaptive MPC-based lateral path-tracking control for automatic vehicles [J]. World Electric Vehicle Journal, 2024, 15 (3): 95.

[18] ROKONUZZAMAN M, MOHAJER N, NAHAVANDI S. Effective adoption of vehicle models for autonomous vehicle path tracking: a switched MPC approach [J]. Vehicle System Dynamics, 2023, 61 (5): 1236–1259.

[19] 龚建伟, 刘凯, 齐建永. 无人驾驶车辆模型预测控制 [M]. 北京: 北京理工大学出版社, 2020.

[20] VAN ZANTEN A T, ERHARDT R, LANDESFEIND K, et al. VDC systems development and perspective

(上接第 95 页)

预测模型, 在预测分解炉内 CO 浓度时取得了较好的结果。

在此基础上, 本文对传统的 GPC 分解炉出口温度预测控制进行了改善, 加入了 CO 浓度这一影响因素, 设计了一种考虑 CO 浓度预测模型的分解炉多工况优化控制策略, 使得 CO 浓度在不同情况下有着不同的控制方法, 并进行了仿真验证, 取得了较好的结果。

参考文献:

- [1] 鲁来祥, 余明高, 常绪华, 等. GM (1, 1) 模型在高冒区遇煤自燃释放 CO 量预测中的应用 [J]. 煤矿安全, 2010, 41 (1): 36–38.
- [2] 丁琳, 吴昊, 藏森. 基于 BP 神经网络的大气中 CO 浓度的预测 [J]. 轻工科技, 2014, 30 (6): 86–87.
- [3] 李兴华. 瑞安煤矿 CO 煤层赋存及采空区涌出预测模型 [D]. 葫芦岛: 辽宁工程技术大学, 2016.
- [4] 魏莱, 王新民. 机器学习方法在 CO 浓度中的预测研究 [J]. 数码世界, 2020 (12): 276–277.
- [5] 王时彬, 陈日辉, 刘世涛, 等. 独头掘进面爆破后 CO 浓度变化分析及预测 [J]. 科学技术与工程, 2014, 14 (6): 101–103.
- [6] 汪海峰, 诸静. 模糊预测控制在水泥生产过程中的应用 [J]. 工业仪表与自动化装置, 2003 (2): 10–13.
- [7] 刘晓琳. 基于神经网络的水泥分解炉温度控制 [D]. 秦皇岛: 燕山大学, 2004.
- [8] 梁小平, 潘红, 李欣, 等. 生活垃圾的热解和燃烧特性的热分析实验研究 [C] //中国自然科学基金委员会工程与材料学部, 中国有色金属学会冶金物理化学学术委员会, 中国金属学会冶金物理化学学术委员会, 中国稀土学会. 2008 年全国冶金物理化学学术会议专辑 (下册). 重庆大学材料科学与工程学院; 2008: 4.
- [9] 赵巍. 城市生活垃圾热解燃烧特性及其并流条件下焚烧

[J]. SAE Transactions, 1998, 107 (6): 424–444.

[21] 贺伊琳, 马建, 杨舒凯, 等. 融合预瞄特性的智能电动汽车稳定性模型预测控制研究 [J]. 汽车工程, 2023, 45 (5): 719–734.

[22] CHEN L, PAPANDREOU G, KOKKINOS I, et al. Deep-Lab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40 (4): 834–848.

[23] MOODY J, DARKEN C. Fast learning in networks of locally-tuned processing units [J]. Neural Computation, 1989, 1 (2): 281–294.

[24] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8 (1): 22–34. 实验研究 [D]. 沈阳: 东北大学, 2012.

[10] 周强泰. 锅炉原理 [M]. 北京: 中国电力出版社, 2013.

[11] 赵联森, 龚燊. 中国生活垃圾气化处理技术的应用 [J]. 环境保护科学, 2018, 44 (5): 106–112.

[12] DESROCHES D E, DOLIGNIER J C, MARTY E, et al. Modelling of gaseous pollutants emissions in circulating fluidized bed combustion of municipal refuse [J]. Fuel, 1998, 77 (13): 1399–1410.

[13] 姚林, 张岩, 陈龙, 等. 基于自适应 VMD 注意力机制 LSTM 的时间序列预测 [J]. 控制工程, 2022, 29 (7): 1337–1344.

[14] MARIA A, EMMA V S, MIKA M, et al. Association between school meal participation and BMI Z-scores before and after the federal healthy hunger-free kids act [J]. Current Developments in Nutrition, 2022, 6 (s1): 1044–1044.

[15] 庞向坤, 黄越, 王振, 等. 基于相关系数的多变量异常数据段的检测 [J]. 控制工程, 2020, 27 (1): 194–200.

[16] 王德新, 俞胜平, 徐昌国, 等. 基于 LSTM 的 PCBA 批次质量预测 [J]. 控制工程, 2024, 31 (3): 497–502.

[17] PUTH M, NEUHÄUSER M, RUXTON D G. Effective use of Spearman's and Kendall's correlation coefficients for association between two measured traits [J]. Animal Behaviour, 2015: 10277–10284.

[18] MINGJIANG S, BOHAN Y, RUI C, et al. Logging curve prediction method based on CNN-LSTM-attention [J]. Earth Science Informatics, 2022, 15 (4): 2119–2131.

[19] 孙义经. 广义预测控制在焦炉温度控制系统中的研究及应用 [D]. 合肥: 安徽工业大学, 2016.

[20] 李天一, 郑建荣. 基于 ARMAX 模型的子空间辨识算法 [J]. 计算机仿真, 2015, 32 (1): 310–313.