

文章编号:1671-8879(2018)05-0238-11

# 无人驾驶汽车 RBF 神经网络滑模 横向控制策略

贺伊琳,马 建,赵 丹,刘晓东,张一西,张 凯

(长安大学 汽车学院,陕西 西安 710064)

**摘 要:**为了加强无人驾驶汽车横向运动控制,提出了一种优化型径向基函数(RBF)神经网络的滑模控制策略。根据视觉导航无人驾驶汽车单点预瞄模型与车辆二自由度模型得出横向运动状态方程,在滑模控制的基础上,采用 RBF 神经网络在线拟合滑模变结构的切换控制量,并基于改进的粒子群算法优化网络结构,使其快速达到滑模面,减小抖振。基于 MATLAB/CarSim 联合仿真平台,对建立的无人驾驶汽车横向运动状态模型及提出的控制策略进行不同工况下的仿真验证;基于 A&D 5435 建立无人驾驶汽车快速原型开发平台,完成实车试验。结果表明:基于优化的 RBF 神经网络滑模横向控制策略能精确实现对车辆横向运动的控制,一定程度上减小了系统建模不确定性带来的影响,能有效抑制方向盘转角的抖振,将横向距离偏差与航向角偏差控制在一定范围内,可靠跟踪期望路径;车辆等速循迹行驶试验时,提出的控制策略的方向盘转角试验结果与仿真结果最大相对误差为 5.8%,横向偏差的最大相对误差为 6.2%,航向角偏差的最大相对误差为 5.4%,试验结果与仿真结果一致性较好;Alt 3 from FHWA 仿真行驶工况下,相比于传统滑模控制策略,提出控制策略下的最大横向距离偏差误差和航向角偏差误差分别降低了 90.8%和 67.6%,双移线工况下误差分别降低了 63.4%和 69.9%,蛇形工况下误差分别降低了 54.4%和 39.6%。

**关键词:**汽车工程;横向运动控制策略;滑模控制;无人驾驶汽车;RBF 神经网络;粒子群算法

**中图分类号:**U461.91

**文献标志码:**A

## Lateral control strategy of RBF neural sliding mode for autonomous vehicles

HE Yi-lin, MA Jian, ZHAO Dan, LIU Xiao-dong, ZHANG Yi-xi, ZHANG Kai

(School of Automobile, Chang'an University, Xi'an 710064, Shaanxi, China)

**Abstract:** To enhance the lateral motion control of autonomous vehicles, a sliding mode control strategy based on improved RBF neural network was proposed. First, the state equation of lateral motion was obtained based on the single point preview model and the two-freedom model of the vehicle. Subsequently, the RBF neural network was used to replace the switching control of the sliding mode structure. On the basis of sliding mode control, the RBF network was optimized using an improved particle swarm optimization method, which enabled a faster sliding mode plane

收稿日期:2018-04-10

基金项目:国家自然科学基金项目(51507013);中国博士后基金项目(2017M613034);

中央高校基本科研业务费专项资金项目(310822162019,310822161015)

作者简介:贺伊琳(1989-),女,陕西西安人,工程师,工学博士研究生,E-mail:heyilin@chd.edu.cn。

通讯作者:马 建(1957-),男,陕西西安人,教授,博士研究生导师,E-mail:majian@chd.edu.cn。

reaching and a more efficient buffeting reduction. The vehicle lateral motion model and the proposed control strategy were verified under various conditions simulation experiments using the MATLAB/CarSim software. Further, a rapid prototype development system of autonomous vehicles was built with A&D 5435, on which vehicle tests were carried out. The results show that precise control for vehicle lateral motion can be realized through a sliding mode control strategy based on the improved RBF neural network. The uncertainty of system modeling is compensated to a certain extent and buffeting of the steering wheel angle can be reduced. Moreover, the lateral distance deviation and heading angle deviation are controlled within acceptable range. The vehicle's trajectory highly matches the desired path. When the vehicle is driven with a constant speed on the testing ground, the relative error of maximum difference of the steering wheel angle between the experimental and simulation results is 5.8%. The relative error of maximum difference of the lateral deviation between the experimental and simulation results is 6.2%, and the relative error of maximum difference of the heading angle deviation between the experimental and simulation results is 5.4%, based on the designed control strategy. The test results are consistent with the simulation results. Compared with the traditional sliding mode control strategy, under Alt 3 from FHWA condition, the relative error of maximum lateral deviation and heading angle deviation are reduced by 90.8% and 67.6%, respectively by using improved RBF neural network sliding mode control strategy. Under the double lane change condition, the relative errors are reduced by 63.4% and 69.9% respectively, and the under S-shaped lane condition, the relative errors are reduced by 54.4% and 39.6% respectively. 2 tabs, 10 figs, 22 refs.

**Key words:** automotive engineering; lateral motion control strategy; sliding mode control; autonomous vehicle; RBF neural network; particle swarm optimization

## 0 引言

随着汽车控制技术和信息科学等学科的发展,无人驾驶汽车已成为现阶段研究热点。无人驾驶汽车依靠环境感知、车辆定位、路径规划及运动控制等实现车辆自主行驶,其中横向运动控制系统根据传感器获得的反馈信息,基于特定控制策略使车辆跟踪期望路径,是决定车辆性能的关键<sup>[1-2]</sup>。车辆是高度非线性系统,且运行环境复杂多变,对车辆横向运动的控制是国内外研究重点之一<sup>[3]</sup>。

目前,无人驾驶汽车横向运动控制的方法主要有非线性理论控制、基于模型的控制与智能算法控制。非线性理论控制包括鲁棒控制、预测控制、滑模控制和自适应控制等;基于模型的控制需建立车辆模型,结合比例-积分-微分(PID)控制或最优控制等方法实现;智能算法控制包括模糊控制和神经网络控制等。文献[4-5]基于纯跟踪算法提出改进策略,利用线性(PI)调节器调节路径曲率对横向偏差的影响,然而道路环境或车辆运行状态发生变化时,需重新整定PI调节器的控制参数。文献[6]提出最优控制方法,将横向运动模型简化为线性时变模型,基于

该模型设计最优控制方法,但当外界干扰较大时,跟踪精度会下降。文献[7]基于神经网络,提出自适应路径跟踪算法,以车辆状态和待执行路径之间的关系作为输入,以Stanley控制策略中的设计目标参数 $k$ 为输出,然而 $k$ 值的初始值选择较为困难,且难以抵抗外界对模型的干扰。为解决上述控制策略对不确定因素较为敏感的问题,文献[8]提出基于 $\mu$ 综合的鲁棒控制方法,当车辆模型变化时,可在一定程度上实现对车辆模型参数变化的适应性;然而由于采用 $\mu$ 综合方法生成的控制器阶次较高,需对控制器做降阶处理,影响控制精度。文献[9]基于滑模控制方法提出一种轨迹跟踪控制律,具有较强的鲁棒性,但忽略了控制过程中的抖振,控制效果不理想。也有文献针对减弱滑模控制引起的抖振展开研究。文献[10]提出了一种抗饱和和自适应滑模控制方法实现机器人轨迹跟踪,然而控制精度依赖于观测器观测增益的选择。文献[11]研究滑模控制策略控制机器人跟踪轨迹时的转弯角速度,在滑模面附近引入边界层,对滑模控制器采用脉冲函数代替符号函数,但其误差只收敛到零附近一个很小邻域,在一定程度上抑制了抖振,同时也牺牲了控制精度。文献[12]



$$\begin{aligned} a_4 D_L; A_2 = a_3; A_3 = a_4 - a_3 D_L; B_1 = a_1 + a_3 D_L; B_2 = \\ -a_1 v_x - a_3 v_x D_L; B_3 = -a_3 v_x; C_1 = -c_1 - c_2 D_L; \\ C_2 = -c_2; D_1 = (a_1 D_L - a_2 + a_3 D_L^2 - a_4 D_L) v_x K_L; \\ D_2 = (a_3 D_L - a_4) v_x K_L + v_x K_L. \end{aligned}$$

将车辆理想位姿偏差作为参考量,车辆实际位姿偏差  $p$  参考理想值变化,该模型即为车辆横向运动控制参考模型。

## 2 横向滑模控制算法

汽车是高度非线性与强耦合的系统,在横向运动中易受侧向风、路面不平度的影响,且行驶环境复杂多变<sup>[16]</sup>。滑模控制系统的结构不断发生变化,控制量作用于系统,使系统状态按预定轨迹滑动。由于设计滑动模态时未考虑系统参数和外界干扰,因此系统进入滑动模态后对参数变化和外界有界扰动不敏感,具有极强的鲁棒性,可有效消除由负载变化和位置变化引起的系统参数摄动及一定范围内的外部随机干扰<sup>[17]</sup>。同时,考虑到在车辆的横向运动控制中,车速、预瞄距离、横向偏差与航向角偏差等变量均对转向轮转角产生重要影响<sup>[18]</sup>,而滑模控制对系统各部分之间的耦合不必作专门解耦,每个控制分量可进行独立设计。因此,本文基于滑模变结构实现无人驾驶汽车的横向运动控制。

设计滑模面函数为

$$s = c_s e + \dot{e} \quad (5)$$

式中:  $s$  为滑模面;  $e$  为系统控制误差;  $c_s$  为滑模面的设计参数,  $c_s = \begin{bmatrix} c_{s1} & 0 \\ 0 & c_{s2} \end{bmatrix}$ ,  $c_{s1}$ 、 $c_{s2}$  均为正数。

系统控制误差为

$$e = p - p_d \quad (6)$$

式中:  $p_d$  为期望位姿偏差,令  $p_d = 0$ 。

为保证系统状态在滑模面上滑动,当系统运动到滑模面附近时,需满足滑动模态的到达条件,即

$$s\dot{s} < 0 \quad (7)$$

$$\dot{s} = c_s \dot{e} + \ddot{e} = c_s \dot{e} + A\dot{p} + Bp + C\delta + D \quad (8)$$

令  $\dot{s} = 0$ , 得等效控制量  $\delta_{eq}$  为

$$\delta_{eq} = -(\sqrt{C_1^2 + C_2^2})^{-1} C^T (A\dot{p} + Bp + c_s \dot{e}) \quad (9)$$

当系统未达到滑模面时,设计切换控制量  $\delta_r$  将系统状态引向滑模面,因此车辆横向运动(前轮转角)的控制量可表示为

$$\delta = \delta_{eq} + \delta_r \quad (10)$$

切换控制量常用的设计方法有常数切换、函数切换与比例切换等,控制量的高频切换与非连续变化特性易引发输出控制量的抖振,恶化控制效果。

若将其直接应用于无人驾驶汽车的横向运动控制,将降低路径跟踪精度,同时频繁切换会加速部件磨损,且当车辆高速行驶或在低附着系数路面行驶时,甚至可能造成车辆失稳,影响乘坐舒适性和安全性。

## 3 基于优化的 RBF 神经网络滑模控制系统

### 3.1 RBF 神经网络滑模控制策略

针对上节问题,采用神经网络逼近滑模控制的切换控制量,既保证滑模控制抵抗外界干扰的能力,又可依靠神经网络的自主学习能力克服系统的不确定性,降低切换增益,减弱抖振。

RBF 神经网络将径向基函数作为隐含层神经元的基,构成隐含层空间,通过隐含层的转换,将低维模式输入数据变换到高维空间,在高维空间中解决低维空间中的线性不可分问题,有效逼近非线性函数,且所求解不易陷入局部最优。因此,本文采用 RBF 神经网络对滑模控制的切换控制量进行逼近。

RBF 神经网络属于 3 层前馈网络,由输入层、隐含层、输出层组成,其结构如图 2 所示。图 2 中:  $x_i$  为输入层神经元;  $h_j$  为隐含层径向基函数;  $w_j$  为权值;  $i = 1, 2, \dots, n$ ,  $j = 1, 2, \dots, m$ ; 网络输出  $y_{out}$  为

$$y_{out} = wh \quad (11)$$

式中:  $w = (w_1, w_2, \dots, w_m)^T$ ;  $h = (h_1, h_2, \dots, h_m)^T$ 。

由式(11)可知,网络输出与隐含层径向基函数及权值有关。本文采用 RBF 神经网络,隐含层数量为 1 层,隐含层神经元个数为 3 个。




图 2 RBF 神经网络结构

Fig. 2 Structure of RBF neural network

### 3.2 改进型粒子群算法

根据上节分析,RBF 神经网络的隐含层函数对网络输出产生关键影响。选择高斯函数作为其隐含层函数,有

$$h_j = \exp\left(-\frac{\|x - c_j\|}{2b_j^2}\right) \quad (12)$$

式中:  $x$  为神经网络的输入向量,  $x = (x_1, x_2, \dots,$

$x_n^T$ ;  $c_j$  为隐含层第  $j$  个神经元的中心值;  $b_j$  为隐含层第  $j$  个神经元的宽度向量。

由此可知,隐含层神经元的中心值、宽度向量和隐含层与输出层之间的权值影响控制输出。文献[19]采用粒子群算法优化网络结构初始值,然而在粒子搜索过程中,可能会在某个位置停止搜索,影响对解空间的搜索能力。因此,本文引入惯性权重,在局部最优与全局最优之间寻求平衡,基于改进的粒子群算法对 RBF 神经网络参数进行优化<sup>[20]</sup>。

在粒子群中,相比于当前时刻,下一时刻粒子  $I$  的第  $D$  维速度更新状态与位置更新状态可分别表示为

$$v_{ID}^{(K+1)} = \omega v_{ID}^{(K)} + q_1 r_1 (p_{ID}^{(K)} - x_{ID}^{(K)}) + q_2 r_2 (p_{ID}^{(K)} - x_{ID}^{(K)}) \quad (13)$$

$$x_{ID}^{(K+1)} = x_{ID}^{(K)} + v_{ID}^{(K+1)} \quad (14)$$

式中:  $\omega$  为粒子更新的惯性权重;  $v_{ID}$  为粒子的速度;  $q_1$ 、 $q_2$  为学习因子,用以调整学习的最大步长;  $r_1$ 、 $r_2$  为区间  $(0, 1)$  内均匀分布的伪随机数;  $x_{ID}$  为当前位置;  $p_{ID}$  为历史最优位置;  $p_{ID}$  为最佳粒子的最佳坐标集合;  $k$  为当前时刻,  $k+1$  表示下一时刻。

$\omega$  取值较大表示搜索范围较大,易得到全局最优解,但在局部收敛时误差较大;  $\omega$  较小表示在粒子临近区域进行搜索,仅能保证局部最优。根据粒子适应度动态调整惯性权重<sup>[20]</sup>,有

$$\omega = \begin{cases} \omega_{\min} + (\omega_{\max} - \omega_{\min})(f - f_{\min}) / (f_{\text{avg}} - f_{\min}) e^{-q} & f \leq f_{\text{avg}} \\ \omega_{\max} & f > f_{\text{avg}} \end{cases} \quad (15)$$

式中:  $\omega_{\max}$ 、 $\omega_{\min}$  分别为设定的  $\omega$  上限和下限;  $f$  为粒子当前适应度;  $f_{\text{avg}}$  为粒子群体的平均适应度;  $f_{\min}$  为粒子群体的最小适应度;  $q$  为适应度  $f$  修正系数。

当惯性权重更新后,若粒子适应度优于上一时刻,则以该粒子的位置作为当前最优位置,直到粒子的适应度或迭代次数满足终止搜索的条件。

### 3.3 基于改进型粒子群算法的 RBF 神经网络构建

RBF 神经网络的训练目标是使实际输出接近预测输出,因此构建适应度函数为

$$f = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M (y_{ij}' - y_{d_{ij}}')^2 \quad (16)$$

式中:  $N$  为训练样本数量;  $M$  为输出神经元数量;  $y_{ij}'$  为网络的实际输出;  $y_{d_{ij}}'$  为期望输出。

初始化神经网络的优化目标为  $c_j$ 、 $b_j$  和  $w_j$ , 对优化参数进行编码,构建粒子搜索空间。以式(16)为适应度函数,依照改进型粒子群算法对参数进行优化,将满足适应度的粒子位置与适应度值进行解

码处理,作为 RBF 神经网络的结构参数。

为保证系统在滑模面上滑动,将神经网络的学习指标  $E$  设定为

$$E = ss \quad (17)$$

网络权值变化率  $\Delta\omega_j$  的学习算法采用梯度下降法进行设计

$$\Delta\omega_j = -\eta \frac{\partial E}{\partial \omega_j} \quad (18)$$

式中:  $\eta$  为网络的学习速率。

将式(8)、式(17)带入式(18),得

$$\Delta\omega_j = -\eta C^T sh_j \quad (19)$$

因此,网络权值调整的方法为

$$\omega_j(t+1) = \omega_j(t) + \Delta\omega_j(t) + \alpha[\omega_j(t) - \omega_j(t-1)] \quad (20)$$

式中:  $\alpha$  为动量因子。

当  $\eta$  较大时可加快网络的训练速度,但若取值过大,可能导致训练误差增大,同时会对网络稳定性造成不利影响。因此,在训练过程中实时更新学习速率,当学习指标的递推误差减小时,增大学习速率,学习指标的递推误差增大时,减小学习速率;当误差变化率超过设定阈值,则学习速率的减小幅度增大<sup>[21]</sup>,因此,设置权值调整学习速率为

$$\eta(k) = \begin{cases} \beta_1 \eta(k-1) & E(k) \leq E(k-1) \\ \beta_2 \eta(k-1) & E(k-1) < E(k) \leq \beta^* E(k-1) \\ \beta_3 \eta(k-1) & E(k) > \beta^* E(k-1) \\ \eta(k-1) & \text{其他} \end{cases} \quad (21)$$

式中:  $E(\cdot)$  为学习指标;  $\eta(\cdot)$  为学习速率;  $\beta_1$ 、 $\beta_2$ 、 $\beta_3$ 、 $\beta^*$  为常量。

### 3.4 基于优化的 RBF 神经网络滑模控制策略

在所构建的 RBF 神经网络基础上,以滑模面函数及其导数作为网络输入,网络输出用于拟合滑模控制的切换控制量,结合等效控制量,得到无人驾驶汽车横向运动控制的前轮转角  $\delta$  为

$$\delta = \delta_{eq} + \delta_{NN} \quad (22)$$

式中:  $\delta_{NN}$  为神经网络对前轮转角  $\delta$  的控制部分。

基于优化的 RBF 神经网络滑模横向控制策略如图 3 所示。以理想车辆运动学模型为参考模型,被控车辆状态与其进行比较,将二者差值作为滑模控制系统的输入,结合滑模控制与神经网络控制的输出为前轮转角,实现车辆的横向运动控制。其中,滑模控制算法能抵抗外界干扰,保证控制系统的稳定性,神经网络控制算法具有自学习能力,能有效降

低切换增益,从而减弱控制系统的抖振。




图 3 基于优化的 RBF 神经网络滑模控制策略

Fig. 3 Optimized RBF neural network sliding mode control strategy

## 4 仿真与试验分析

### 4.1 CarSim/Simulink 联合仿真平台

为验证提出的优化型 RBF 神经网络滑模控制策略在无人驾驶汽车横向运动控制方面的性能,本文基于 MATLAB/CarSim 联合仿真环境构建无人驾驶汽车横向运动控制模型。

在仿真平台下,基于 CarSim 搭建整车模型,基于 MATLAB 搭建横向运动控制策略模型。整车模型输出车辆的位姿信号,结合理想车辆运动学模型确定当前时刻的横向偏差和航向角偏差。横向控制策略模型根据车辆的位姿偏差,决策下一时刻的方向盘转角,实时调整车辆横向运动状态,形成完整的闭环控制系统。两部分模型在不同软件平台下采用自带的求解器求解,通过 CarSim 软件输入与输出参数接口模块进行数据交互。无人驾驶汽车横向运动控制的 MATLAB/CarSim 联合仿真平台架构如图 4 所示。




图 4 MATLAB/CarSim 联合仿真平台架构

Fig. 4 Platform of MATLAB/CarSim co-simulation

实现 MATLAB/CarSim 联合仿真的前提是对 CarSim 输入、输出参数接口进行正确的配置,CarSim 输入、输出接口参数配置如表 1 所示。

### 4.2 仿真结果及分析

基于图 4 联合仿真平台,在 3 种工况下对基于常值切换函数的滑模控制策略、基于 RBF 神经网络的滑模控制策略、基于优化的 RBF 神经网络滑模控制策略的控制效果进行仿真与对比分析。

#### 4.2.1 Alt 3 from FHWA 工况

在 CarSim 3D Road 路况中选择 Alt 3 from

表 1 CarSim 输入、输出接口参数配置

Tab. 1 Input and output interfaces of parameters for CarSim

| 类别   | 参数名称            | 参数含义         |
|------|-----------------|--------------|
| 输入参数 | IMP_STEER_Sw    | 方向盘转角        |
| 输出参数 | $V_x$           | 车速           |
|      | $L_{x\_Sen\_1}$ | 预瞄距离         |
|      | $X_{RdS\_1}$    | 预瞄点 1 处的横坐标  |
|      | $Y_{RdS\_1}$    | 预瞄点 1 处的纵坐标  |
|      | $L_{Drv\_1}$    | 预瞄点 1 处的横向偏差 |
|      | $A_{Comp}$      | 车辆航向角        |

FHWA 路况进行仿真,该道路是 CarSim 中常被用于路径跟踪测试的道路。整车仿真参数设置如表 2 所示。车辆初始位置为(195.83,−110.795),见图 5(a),设置车速为 60 km/h,预瞄距离为 20 m<sup>[22]</sup>。

表 2 整车仿真参数

Tab. 2 Vehicle simulation parameters

| 项目                                | 数值               |
|-----------------------------------|------------------|
| 整备质量/kg                           | 1 105            |
| 轴距/mm                             | 2 460            |
| 前(后)轮距/mm                         | 1 460(1 460)     |
| 前(后)轮胎侧偏刚度/(N·rad <sup>−1</sup> ) | −49 000(−50 160) |
| 转向系传动比                            | 15.8             |

仿真结果如图 5 所示。图 5 中:SMC 为滑动模态控制;RBF-SMC 为基于 RBF 神经网络的滑动模态控制;IPSO-RBF-SMC 为基于粒子群优化的 RBF 神经网络滑动模态控制。

由图 5(a)可知,3 种控制策略下车辆的运行轨迹均可按照期望轨迹的趋势变化,当路径曲率较大时,实际轨迹与理想轨迹之间存在一定程度的偏离,其中传统滑模控制偏离最大,本文提出的基于优化的 RBF 神经网络滑模控制策略下车辆轨迹最接近期望轨迹。由图 5(b)可知,传统滑模控制策略下方向盘转角出现明显抖振,2 种 RBF 神经网络滑模控制策略下方向盘转角曲线变化平缓,抖振减弱。由图 5(c)可知:3 种控制策略的车辆横向偏差在道路曲率变化较大时均出现了一定的波动,滑模控制策略下的横向偏差最大,其横向偏差变化范围为−0.104~0.109 m;未优化的 RBF 神经网络滑模控制策略横向偏差变化范围为±0.034 m,优化后的 RBF 神经网络滑模控制策略的横向偏差始终保持在±0.01 m 范围内。由图 5(d)可知,优化的 RBF 神经网络滑模控制策略的航向角偏差变化范围为±0.011 rad,而传统滑模控制策略与未优化的 RBF 神经网络滑模控制策略的航向角偏差变化范围分别为±0.12 rad 和−0.033~0.034 rad;相比于传统




Fig. 5 Simulation results under Alt 3 from FHWA condition

滑模控制,该控制策略下最大横向偏差相对误差与航向角偏差相对误差分别降低了 90.8%和 67.6%。

4.2.2 双移线工况

在无人驾驶汽车路径跟踪研究中,双移线工况可用来模拟车辆前方出现障碍物时,车辆换道避障

且避障结束后继续回到原车道行驶的行为,是车辆行驶的典型行为之一。设置车速为 20 km/h,预瞄距离为 8 m,双移线工况仿真结果如图 6 所示。




Fig. 6 Simulation results under double lane change condition

由图 6(a)可知:车辆直线行驶时能很好地跟踪期望轨迹,换道过程中轨迹曲率发生突变时车辆实

际轨迹与期望轨迹存在一定偏差;相比于传统滑模控制与未优化的 RBF 神经网络滑模控制,本文控制策略轨迹跟踪效果最好。由 6(b)可知,滑模控制策略抖动明显,而基于 RBF 神经网络的滑模控制策略减弱了方向盘抖动。由图 6(c)、6(d)可知:在换道过程中车辆的横向偏差有轻微波动,换道结束后误差能快速收敛到零,直线路径的跟踪效果良好,最大位姿偏差出现在 21.8 s 处,其中滑模控制策略下的横向偏差变化范围为  $-0.161 \sim 0.159$  m,航向角偏差变化范围为  $-0.173 \sim 0.124$  rad;未优化的 RBF 神经网络滑模控制下横向偏差变化范围为  $-0.102 \sim 0.071$  m,航向角偏差变化范围为  $-0.072 \sim 0.060$  rad;基于优化的 RBF 神经网络滑模控制策略下横向偏差变化范围限制在  $-0.059 \sim 0.040$  m,航向角偏差变化范围限制在  $-0.052 \sim 0.038$  rad,相比于传统滑模控制,该控制策略下最大横向偏差相对误差和航向角偏差相对误差分别降低了 63.4% 和 69.9%。

#### 4.2.3 蛇形工况

蛇形工况路径曲率变化频繁,方向盘转角也处于不断的变化中,此时对横向运动控制策略的要求较高。设置车速为 20 km/h,预瞄距离为 8 m,仿真结果如图 7 所示。

由图 7(a)可知,在 3 种控制策略下车辆均可跟踪蛇形曲线行驶,然而在曲率较大时,车辆实际轨迹与期望轨迹之间存在一定偏差,相比于传统滑模控制策略与未优化的 RBF 神经网络滑模控制策略,本文控制策略下的轨迹最接近理想轨迹。由图 7(b)可以看出,传统滑模控制策略下方向盘转角依然存在明显抖动,基于 RBF 神经网络的滑模控制策略能明显减弱抖动。由图 7(c)、7(d)可知:与前述工况仿真结果类似,滑模控制策略下的横向偏差与航向角偏差变化范围分别为  $-0.134 \sim 0.160$  m 和  $-0.115 \sim 0.139$  rad;未优化的 RBF 神经网络滑模控制策略下横向偏差与航向角偏差变化范围分别为  $\pm 0.092$  m 和  $-0.099 \sim 0.101$  rad;优化的 RBF 神经网络滑模控制策略下横向偏差与航向角偏差最小,其变化范围分别为  $-0.071 \sim 0.073$  m 和  $-0.078 \sim 0.084$  rad。相比传统滑模控制策略,本文控制策略最大横向偏差相对误差和最大航向角偏差相对误差分别降低了 54.4% 和 39.6%。

综上所述,由于切换控制量的不连续变化,滑模控制策略输出的方向盘转角出现明显抖动。采用 RBF 神经网络的输出拟合滑模控制的切换控制量,




图 7 蛇形工况仿真结果

Fig. 7 Simulation results under S-lane condition

能减弱抖动,在直线行驶时车辆具有良好的轨迹跟踪能力,仅在道路曲率出现变化时轨迹出现小幅波动,横向偏差和航向角偏差限制在一定范围内。基于粒子群优化的 RBF 神经网络滑模控制策略优化了网络结构参数,车辆的运行轨迹最接近期望轨迹,



横向偏差和航向角偏差最小。仿真结果表明,本文控制策略能改善滑模控制的效果,减弱抖振,且优化后的参数能进一步提高控制效果。

4.3 试验结果与分析

在开发的无人驾驶试验车基础上,利用 A&D 5435 半实物仿真系统和 MATLAB/Simulink 的代码自动生成技术,搭建无人驾驶汽车半实物仿真试验平台,以验证提出的控制策略在无人驾驶汽车横向运动控制的性能,试验平台如图 8 所示。基于 MATLAB 的 Real-Time Workshop,将本文提出的优化型 RBF 神经网络滑模控制策略下载到 A&D 5435 中, GPS 传感器实时记录车速、车辆位置与运行轨迹,惯性导航系统采集车辆的横摆角信号,方向盘转角传感器采集方向盘转角信号, A&D 5435 输出电机控制信号控制转向电机,实现对前轮转角的控制。同时 A&D 5435 还能对试验过程中车辆信息进行动态显示、记录和保存。为保证半实物仿真平台与 MATLAB/CarSim 联合仿真车辆参数的一致性,半实物仿真选用的车辆基本参数与表 2 一致。

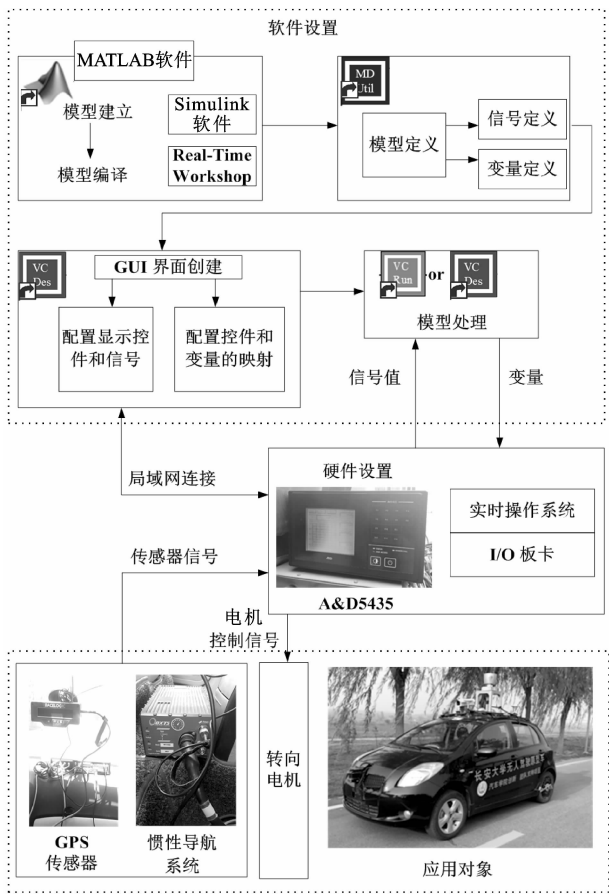


图 8 试验平台

Fig. 8 Experiment Platform

在汽车综合性能试验场的环形跑道上进行循迹

试验,验证试验车在本文控制策略下的轨迹跟踪能力。试验环道由直道和弯道组成,设定轨迹见图 9。试验过程中始终保持 20 km/h 恒定车速,驾驶人驾驶车辆在测试道路上沿道路中心线行驶, GPS 传感器与惯性导航系统记录的车辆位置与横摆角为理想值,无人驾驶汽车在上述道路上行驶,选择相同的路径起始点,相应传感器记录的数据为实际值。车辆处于稳定状态,忽略质心侧偏角的影响,横摆角近似等于航向角。传感器测得的理想值与实际值之差为横向偏差与航向角偏差,方向盘转角传感器测量方向盘转角。试验结果与仿真结果对比见图 10。




图 9 设定轨迹

Fig. 9 Appointed track

由图 10 可知,方向盘转角试验结果与仿真结果最大相对误差为 5.8%,横向偏差的最大相对误差为 6.2%,航向角偏差的最大相对误差为 5.4%,表明试验结果与仿真结果一致性较好。本文控制策略在直线路段,车辆运动的横向偏差与航向角偏差在 0 附近变化;在曲率较大处,通过控制方向盘转角跟踪期望轨迹,但相比于直线路段,出现了一定的位姿偏差,最大横向偏差和航向角偏差分别为 0.182 m 和 0.048 rad;弯道结束后,车辆迅速恢复直线行驶。

通过实车试验可知,本文提出的优化型 RBF 神经网络滑模横向控制策略能够在实车上实现对期望轨迹的跟踪,将车辆的位姿偏差控制在一定范围内,验证了本文控制策略可适用于控制过程复杂多变的无人驾驶汽车横向运动控制。

5 结 语

(1)针对无人驾驶汽车横向运动控制,提出基于粒子群优化的 RBF 神经网络滑模控制策略。根据车辆单点预瞄模型与二自由度模型得出车辆运动状态方程,设计了滑模横向控制器;为减弱滑模控制引发的抖振,结合神经网络与滑模控制,组成自学习逆模控制系统,采用优化的 RBF 神经网络拟合滑模控




图 10 试验结果与仿真结果对比

Fig. 10 Comparisons of experimental results and simulation results

制的切换控制量。基于 MATLAB/CarSim 联合仿真平台与 A&D 5435 快速原型开发平台,仿真分析与试验验证了本文控制策略的效果。

(2)仿真与试验综合表明,相比于传统滑模控制算法,基于优化的 RBF 神经网络滑模控制策略能有效减弱抖振,采用改进的粒子群算法对神经网络结构进行优化可进一步提高控制效果,横向偏差和航向角偏差被限制在一定的范围内且变化平稳,使车辆具有良好的轨迹跟踪能力。本文控制策略提高了无人驾驶汽车横向运动控制的精度,取得了良好的控制效果。

(3)本文从汽车横向动力学角度研究无人驾驶汽车的轨迹跟踪性能,并未考虑纵向车速变化对横向运动的影响。纵横向动力学耦合下的汽车轨迹跟

踪是今后的重要研究内容。

## 参考文献:

## References:

- [1] NETTO M S, CHAIB S, MAMMAR S. Lateral adaptive control for vehicle lane keeping[C]//IEEE. Proceedings of the 2004 American Control Conference. New York: IEEE, 2004: 2693-2698.
- [2] 刘子龙,杨汝清,杨明,等.无人驾驶车辆横向位置最优跟踪控制[J].上海交通大学学报,2008,42(2): 257-265.  
LIU Zi-long, YANG Ru-qing, YANG Ming, et al. Lateral position tracking optimal control of unmanned vehicle[J]. Journal of Shanghai Jiaotong University, 2008, 42(2): 257-265.
- [3] LI X, FANG X, WANG C, et al. Lane detection and tracking using a parallel-snake approach[J]. Journal of Intelligent & Robotic Systems, 2015, 77(3/4): 597-609.
- [4] PARK M, LEE S, HAN W, et al. Development of lateral control system for autonomous vehicle based on adaptive pure pursuit algorithm[C]//IEEE. Proceedings of the 14th International Conference on Control, Automation and Systems. New York: IEEE, 2014: 1443-1447.
- [5] SAMUEL M, HUSSEIN M, MOHAMAD M B. A review of some pure-pursuit based path tracking techniques for control of autonomous vehicle[J]. International Journal of Computer Applications, 2016, 135(1): 35-38.
- [6] BROGGI A, ZELINSKY A, OZGUNER U, et al. Handbook of robotics[M]. Berlin: Springer Handbook of Robotics, 2016.
- [7] ZHU Q, HUANG Z, LIU D, et al. An adaptive path tracking method for autonomous land vehicle based on neural dynamic programming[C]//IEEE. Proceedings of IEEE International Conference on Mechatronics and Automation. New York: IEEE, 2016: 1429-1434.
- [8] 宋彦,赵盼,陶翔,等.基于 $\mu$ 综合的无人驾驶车辆路径跟随串级鲁棒控制方法[J].机器人,2013, 35(4): 417-424.  
SONG Yan, ZHAO Pan, TAO Xiang, et al. UGV robust path following control under double loop structure with  $\mu$  synthesis [J]. Robot, 2013, 35(4): 417-424.
- [9] 廖煜雷,庄佳园,李晔,等.欠驱动无人艇轨迹跟踪的滑模控制方法[J].应用科学学报,2011, 29(4): 428-434.

- LIAO Yu-lei, ZHANG Jia-yuan, LI Ye, et al. Sling-mode trajectory tacking control for underactuated autonomous surface vehicle[J]. Journal of Applied Sciences, 2011, 29(4): 428-434.
- [10] 郭一军, 俞立, 徐建明. 基于扩张状态观测器的轮式移动机器人抗饱和和自适应滑模轨迹跟踪控制[J]. 系统科学与数学, 2017, 37(5): 1179-1193.
- GUO Yi-jun, YU Li, XU Jian-ming. Anti-windup adaptive sliding mode trajectory tracking control of wheeled mobile robot based on extended state observer[J]. Journal of Systems Science and Mathematical Sciences, 2017, 37(5): 1179-1193.
- [11] 杨兴明, 李文静, 朱建. 基于 RBF 神经网络的机器人的路径跟踪控制[J]. 合肥工业大学学报: 自然科学版, 2015, 38(11): 1477-1483.
- YANG Xing-ming, LI Wen-jing, ZHU Jian. Path tracking control of mobile robot via RBF neural network[J]. Journal of Hefei University of Technology: Natural Science, 2015, 38(11): 1477-1483.
- [12] 李琳辉, 李明, 郭景华, 等. 基于视觉的智能车辆模糊滑模横向控制[J]. 大连理工大学学报, 2013, 53(5): 735-741.
- LI Lin-hui, LI Ming, GUO Jing-hua, et al. Fuzzy sliding mode lateral control of intelligent vehicle based on vision[J]. Journal of Dalian University of Technology, 2013, 53(5): 735-741.
- [13] 李兵. 基于联合仿真的智能车辆路径跟踪控制研究[D]. 大连: 大连理工大学, 2014.
- LI Bing. Research of intelligent vehicle trajectory tracking control based on collaborative simulation [D]. Dalian: Dalian University of Technology, 2014.
- [14] 杨超, 郭佳, 张铭钧. 基于 RBF 神经网络的作业型 AUV 自适应终端滑模控制方法及实验研究[J]. 机器人, 2018, 40(3): 336-345.
- YANG Chao, GUO Jia, ZHANG Ming-jun. Adaptive terminal sliding mode control method based on RBF neural network for operational AUV and its experimental research[J]. Robot, 2018, 40(3): 336-345.
- [15] 倪兰青, 林菜, 王凯正. 基于预瞄的智能车辆路径跟踪控制研究[J]. 重庆理工大学学报: 自然科学版, 2017, 31(3): 27-33.
- NI Lan-qing, LIN Fen, WANG Kai-zheng. Research on path-following control of intelligent vehicles based on preview model[J]. Journal of Chongqing University of Technology: Natural Science, 2017, 31(3): 27-33.
- [16] URMSON C, ANHALT J, BAGNELL D, et al. Autonomous driving in urban environments: Boss and the urban challenge[J]. Journal of Field Robotics, 2008, 25(8): 425-466.
- [17] SOLEA R, FILIPESCU A, MINZU V, et al. Sliding-mode trajectory-tracking control for a for-wheel-steering vehicle[C]//IEEE. Proceedings of 8th International Conference on Control and Automation (ICCA). New York: IEEE, 2010: 382-387.
- [18] ERCAN Z, GOKASAN M, BORRELLI F. An adaptive and predictive controller design for lateral control of an autonomous vehicle[C]//IEEE. Proceedings of IEEE International Conference on Vehicular Electronics and Safety. New York: IEEE, 2017: 13-18.
- [19] 张健, 刘定一. 一种应用 PSO 优化 RBF 神经网络的方法[J]. 计算机仿真, 2014, 31(11): 269-272.
- ZHANG Jian, LIU Ding-yi. A method of application of PSO to optimize RBF neural network[J]. Computer Simulation, 2014, 31(11): 269-272.
- [20] 闵喜瑞. 基于径向基函数(RBF)神经网络滑模变结构厚度控制[D]. 唐山: 华北理工大学, 2016.
- MIN Xi-rui. The gauge control based on radial basis function neural network sliding mode variable structure[D]. Tangshan: North China University of Science and Technology, 2016.
- [21] 刘耀达. RBF 神经网络在滑模变结构控制中的应用研究[D]. 青岛: 青岛科技大学, 2011.
- LIU Yao-da. Application of RBF neural network in sliding mode control system[D]. Qingdao: Qingdao University of Science and Technology, 2011.
- [22] KATSUMI H, EIJI K. Three look-ahead distance scheme for lateral control of vision-based vehicles [C]//IEEE. Proceedings of SICE Annual Conference. New York: IEEE, 2014: 660-665.