

2-20-2021

Longitudinal Adaptive Control of Autonomous Vehicles Base on Optimization Algorithm

Zhishuai Yin

School of Automotive Engineering, Wuhan University of Technology, Wuhan 430070, China;

Jiaxiong He

School of Automotive Engineering, Wuhan University of Technology, Wuhan 430070, China;

Linzhen Nie

School of Automotive Engineering, Wuhan University of Technology, Wuhan 430070, China;

Jiayi Guan

School of Automotive Engineering, Wuhan University of Technology, Wuhan 430070, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Longitudinal Adaptive Control of Autonomous Vehicles Base on Optimization Algorithm

Abstract

Abstract: Aiming at the nonlinear, time-varying and uncertain characteristics of the longitudinal motion of autonomous vehicles, a Radial Basis Function neural network(RBFNN) Proportional Integral Derivative(PID) controller base on Particle Swarm Optimization(PSO) is designed. A RBFNN is integrated into a PID controller so that parameters of the PID controller could be adjusted self-adaptively. *To solve the problem that poor selection of initial parameters of RBFNN and PID might lead to overshoot or instability in the control system, PSO is adopted to optimize aforementioned initial parameters off-line.* Finally, a closed-loop adaptive control system model is built in MATLAB/Simulink. Simulation results show that as compared to the traditional PID controller and a non-optimized RBFNN-PID controller, the proposed PSO-RBFNN-PID controller demonstrates a higher level of controlling accuracy and stability of speed control under the New European Driving Cycle (NEDC) test.

Keywords

autonomous vehicle, longitudinal control, self-adaptive, PSO-RBFNN-PID controller

Recommended Citation

Yin Zhishuai, He Jiaxiong, Nie Linzhen, Guan Jiayi. Longitudinal Adaptive Control of Autonomous Vehicles Base on Optimization Algorithm[J]. Journal of System Simulation, 2021, 33(2): 409-420.

基于优化算法的自动驾驶车辆纵向自适应控制

尹智帅, 何嘉雄, 聂琳真, 管家意

(武汉理工大学 汽车工程学院, 湖北 武汉 430070)

摘要: 针对自动驾驶车辆纵向运动的非线性、时变以及不确定性等特性, 设计了一种基于粒子群优化(Particle Swarm Optimization, PSO)的径向基神经网络(Radial Basis Function Neural Network, RBFNN)比例积分微分(Proportional Integral Derivative, PID)控制器, RBFNN 与 PID 控制相结合自适应调整 PID 参数; 针对 RBFNN 和 PID 的初始参数选择不当会使模型产生超调甚至失稳等问题, 采用 PSO 同时离线优化 RBFNN 和 PID 的初始参数, 智能选取合理参数; 通过在 Matlab/Simulink 中搭建闭环自适应控制系统模型, 新欧洲驾驶循环工况下比较 PSO-RBFNN-PID, RBFNN-PID, PID 三种控制器的精度和稳定性。仿真结果表明, 提出的方法具有更好的控制精度和稳定性, 能够很好地实现纵向跟踪控制。

关键词: 自动驾驶车辆; 纵向控制; 自适应; PSO-RBFNN-PID 控制器

中图分类号: TP391.9; U46 文献标志码: A 文章编号: 1004-731X (2021) 02-0409-12

DOI: 10.16182/j.issn1004731x.joss.19-0372

Longitudinal Adaptive Control of Autonomous Vehicles Base on Optimization Algorithm

Yin Zhishuai, He Jiaxiong, Nie Linzhen, Guan Jiayi

(School of Automotive Engineering, Wuhan University of Technology, Wuhan 430070, China)

Abstract: Aiming at the nonlinear, time-varying and uncertain characteristics of the longitudinal motion of autonomous vehicles, a Radial Basis Function neural network(RBFNN) Proportional Integral Derivative(PID) controller base on Particle Swarm Optimization(PSO) is designed. A RBFNN is integrated into a PID controller so that parameters of the PID controller could be adjusted self-adaptively. To solve the problem that poor selection of initial parameters of RBFNN and PID might lead to overshoot or instability in the control system, PSO is adopted to optimize aforementioned initial parameters off-line. Finally, a closed-loop adaptive control system model is built in MATLAB/Simulink. Simulation results show that as compared to the traditional PID controller and a non-optimized RBFNN-PID controller, the proposed PSO-RBFNN-PID controller demonstrates a higher level of controlling accuracy and stability of speed control under the New European Driving Cycle (NEDC) test.

Keywords: autonomous vehicle; longitudinal control; self-adaptive; PSO-RBFNN-PID controller

引言

由于交通安全、效率等问题日益严重, 自动驾驶技术成为近年来汽车工程领域的研究热点。车辆控制是自动驾驶的关键技术之一, 相关研究通常包含车辆的纵向控制、横向控制以及纵横向耦合控

制, 本文关注车辆的纵向控制^[1-4]。

车辆的纵向运动具有非线性、时变性和不确定性等特点, 因此纵向控制也是自动驾驶车辆技术中的难点问题。目前大多数纵向控制方面的研究主要分为 2 个方向: (1) 基于传统的控制理论;

收稿日期: 2019-07-23

修回日期: 2019-11-25

基金项目: 国家重点研发计划(2018YFB0105203), 国家自然科学基金(51805388)

第一作者: 尹智帅(1985-), 男, 博士, 副教授, 研究方向为智能网联汽车、驾驶行为。E-mail: zyin@whut.edu.cn

(2) 基于人工智能控制。基于传统控制理论的车辆纵向控制研究主要基于 PID 控制、滑模控制 (Sliding Mode Control, SMC)、模型预测控制 (Model Predictive Control, MPC) 控制、级联控制、线性二次型控制等展开。Chien 等^[5]采用 PID 纵向控制器, 解决智能交通下的车辆纵向控制的实时性问题, 但由于其控制参数通过试凑法获取, 难以实现对智能纵向运动的最优控制。SMC 控制器可提高系统的动态响应能力, 有效克服车辆非线性、参数随机性及外界干扰等特性, 但是由于其控制增益的不连续性可使控制系统产生振荡或失稳。Thanok S 等^[6]设计了一种基于 SMC 控制的智能车纵向控制器, 使用 PSO 优化 SMC 中的滑动面和控制器的增益, 通过简化一阶线性模型和使用模糊逻辑控制制动力来进行纵向控制, 在 Matlab 中仿真并与传统的比例微分控制器进行了比较。结果表明, 所提出的基于 PSO 的 SMC 可以在智能车的纵向控制中有效的执行。Wang Qiu 等^[7]提出了一种控制自动驾驶车辆纵向运动和排除干扰的方法。建立车辆纵向动力学模型, 采用恒定时间间隔的方法设计基于 MPC 的纵向上层控制器, 下层控制器采用简单的 PID 算法来确定油门或制动的输入, 在动力学软件 veDYNA 中模拟。仿真结果表明, 所提出的方法能够跟踪所需的间距。Attia R 等^[8]采用一种基于内环和外环设计的非线性级联纵向控制方法, 级联回路确保参考速度跟踪和扭矩控制, 纵向控制器与互联结构中的横向控制器耦合。通过仿真验证了纵向控制跟踪时变参考速度的有效性。Jinghua Guo 等^[9]针对车辆非线性和参数不确定性的影响, 提出了一种新的自适应动态面纵向跟踪控制策略, 仿真和实验结果证明了该控制方法的有效性。

传统的控制理论需要对被控对象建立一个精确的数学模型, 而车辆具有复杂、高度耦合以及非线性等特点, 因此往往需要对车辆模型进行简化, 从而使得控制效果也较差。人工智能控制方法具有不依赖精确数学模型的控制特性, 对于模型未知的

复杂非线性系统或是动态特性常变的控制对象两方面, 具有明显的优势。

基于人工智能控制的纵向控制研究主要基于模糊控制、神经网络控制, 由于其在线学习能力受到广泛的关注。模糊逻辑和神经网络的研究以及它们在控制领域的应用取得了很大的进展。朱晓宏等^[10]建立汽车的动力学模型, 采用模糊控制方法设计巡航控制器, 运用自适应神经网络模糊推理系统 (Adaptive Network-based Fuzzy Inference System, ANFIS) 设计车间距控制器并通过仿真手段进行优化工作, 采用速度、车间距联合控制进行车列控制。在 Matlab/Simulink 中仿真, 仿真结果表明该方法对车辆的纵向速度控制较好。尽管模糊控制可以对复杂的非线性系统取得不错的控制效果, 然而其对于简单信息的模糊处理会使得系统控制精度降低和动态品质变差。Nie 等^[11]提出了将 RBFNN 与 PID 相结合的控制方法, 建立汽车的纵向动力学简化模型, 在 Matlab/Simulink 中建模并仿真分析, 与传统的 PID 和模糊控制相比较。仿真结果表明所提出方法控制精度高、提供更好的舒适感。然而, 该控制算法中初始参数具有随机性, 如果初始参数的选取不当, 可能导致模型出现超调甚至失稳等现象。因此, 可采用 PSO 优化初始参数。

PSO 收敛快、结构简单、可调参数少, 已经广泛应用于函数优化、神经网络、模糊控制等领域^[12]。Ye Yi 等^[13]使用基于改进后粒子群算法 (Improved Particle Swarm Optimization, IPSO) 的 PID 控制器控制非线性液压系统的位置, IPSO 进行搜索用于位置控制的 PID 增益。Zhang Ying 等^[14]利用 PSO 优化 RBF 网络参数 (连接权重 w 、隐藏节点中心 c 和宽度 b), 然后应用优化后的 RBF 神经网络预测建筑中的能源消耗。

神经网络在复杂的非线性控制方面有比较好的效果, 本文采用 RBFNN-PID 控制自适应调整, 设计了一个 PSO-RBFNN-PID 控制器, 采用 PSO 同时离线优化 RBFNN 和 PID 的初始参数。在全球

轻型汽车测试循环 (Worldwide Light-duty Test Cycle, WLTC) 工况下 PSO 离线优化并自动选出模型效果较好的初始参数。最终, 建立了一个前向的仿真模型, 包括 PSO-RBFNN-PID 控制器模型、车辆纵向动力学模型。该前向仿真模型在 NEDC 工况下在线测试, 形成闭环的控制。最后比较分析了 PSO-RBF-PID、RBF-PID、PID 三个控制器控制精度和稳定性。

1 控制系统总体框架

1.1 控制系统设计思路

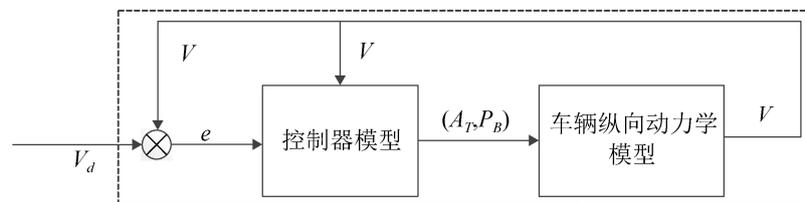
传统 PID 控制器依靠被控对象精准的数学模型, 应用在非线性、时变、不确定的系统时效果不佳。而神经网络具有优越的非线性拟合能力, 适用于车辆这一难以进行精准数学建模的复杂非线性被控对象, 因此本文基于神经网络对传统 PID 控制器进行改进; 针对车辆的不确定、时变特性和控制实时性要求, 选取局部逼近、学习速率快、并行处理效率高的 RBFNN; 进而, 设计 RBFNN 与 PID 相结合的控制器, 实现车辆控制参数的在线自适应

调整, 解决车辆非线性、时变等所引发的控制振荡、失稳等问题; 最终, 针对模型初始化参数的随机性, 引入 PSO 优化算法对 RBFNN 和 PID 的 9 个初始化参数进行离线优化, 有效地解决控制模型参数随机性所引发的控制超调、调参耗时长等问题。

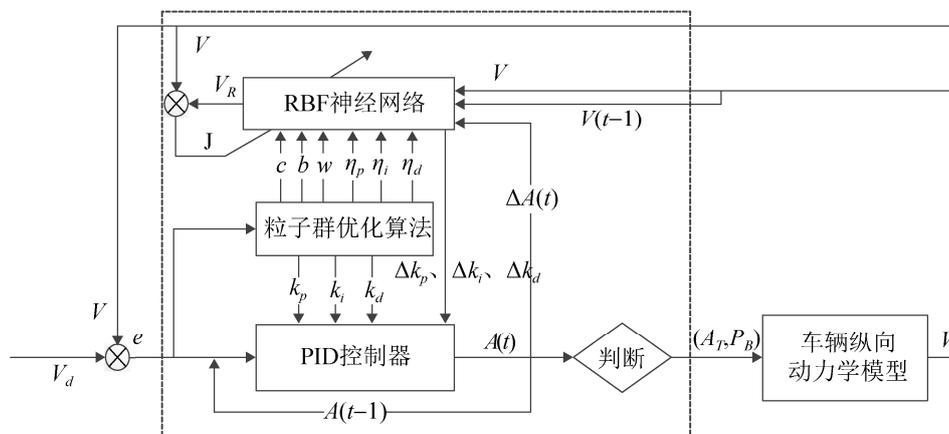
1.2 控制系统的总体框架

控制系统框架如图 1 所示, 图 1 中的符号及其定义如表 1 所示。

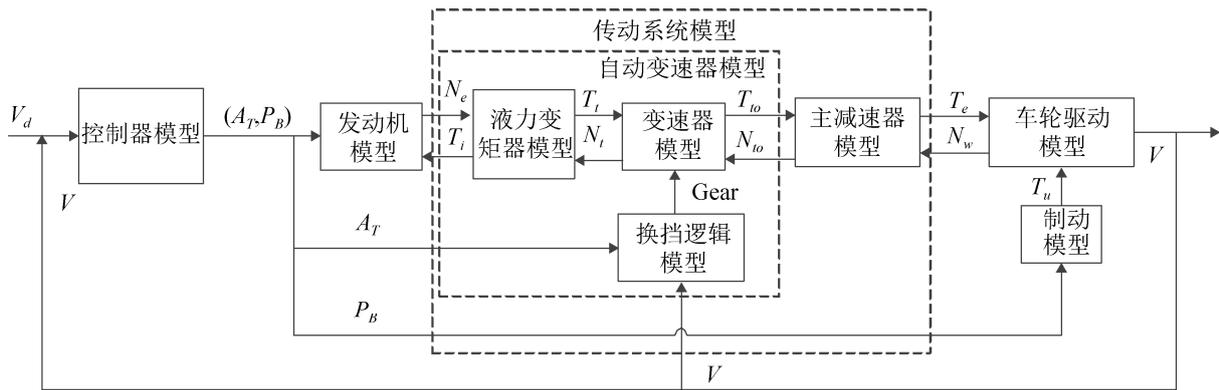
如图 1(a)所示, 控制系统的框架包含一个纵向动力学模型和一个基于 PSO-RBFNN-PID 的控制器模型, 该控制器模型采用 PSO 离线优化初始参数, RBFNN 与 PID 相结合在线自适应调整参数。动力学模型作为被控对象, 其根据输入的节气门开度 A_T , 制动主缸压力 P_B , 输出跟踪车辆的实际速度 V 。目标车辆速度和跟踪车辆速度的误差 e 以及跟踪车辆速度 V , 作为控制模型的 2 个输入在线动态调节节气门的开度和制动主缸压力, 形成一个闭环的控制。



(a) 控制系统框架模型



(b) PSO-RBFNN-PID 纵向控制器模型



(c) 车辆纵向动力学模型

图 1 控制系统框架

Fig. 1 Control system framework

表 1 控制模型的变量名

Tab. 1 Variable names of control model

变量名	变量定义
V_d	目标车速
V	实际车速
V_R	RBFNN 的输出
J	性能指标函数
c	径向基中心向量
b	宽度向量
w	权重向量
k_p, k_i, k_d	PID 三个参数
η_p, η_i, η_d	PID 三个参数学习率
$\Delta k_p, \Delta k_i, \Delta k_d$	PID 三个参数增量
A_T	节气门开度
P_B	制动主缸压力
$A(t)$	t 时刻 PID 控制器的输出
$A(t-1)$	$t-1$ 时刻 PID 控制器的输出
e	速度误差

2 控制器模型

如图 1(b)所示,设计了一个 PSO-RBFNN-PID 控制器模型,实现速度的跟踪控制。神经网络由于其强大的自学和非线性映射能力,在处理非线性控制、不确定、时变系统时具有很好的效果被广泛应用于控制系统^[15]。本文受文献[10]的启发,将 RBFNN 和 PID 相结合可在线自适应调整参数,实现更精确的速度跟踪控制。但应用 RBFNN 自适应调节 PID 参数的同时也会带来一些问题, RBFNN 初始参数(c_0, b_0, w_0)、PID 初始增益参数

(k_p, k_i, k_d)以及增益参数学习率(η_p, η_i, η_d)都是随机人为试凑的,初始参数值选择不当会直接影响到控制器的性能,比如超调或者失稳,同时参数试凑这个过程耗时较长^[16]。针对上述问题,采用 PSO 优化提及到的初始参数,智能选择较优的初始参数。PSO 是一种基于种群搜索的自适应优化计算技术,其参数较少、收敛速度快,能有效解决复杂任务。

该控制器模型选用 WLTC 工况下的速度作为目标车速 V_d , 离线优化选取初始参数;然后选用 NEDC 工况下的速度作为目标车速 V_d , 进行在线纵向速度跟踪仿真测试。

图 2 所示为全球轻型汽车测试循环工况。

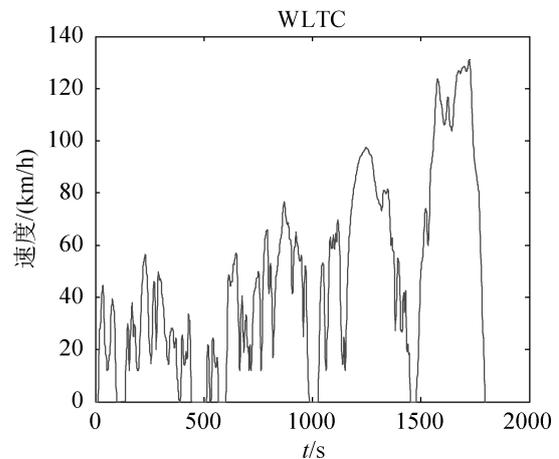


图 2 全球轻型汽车测试循环工况

Fig. 2 Worldwide light vehicle test cycle conditions (WLTC)

WLTC 工况全程分为低速、中速、高速、超高速 4 个阶段, 总时长 1 800 s, 其测试的速度范围为 0~131.3 km/h, 工况比较复杂, 因此该控制器模型选用 WLTC 工况下的速度作为离线优化算法的目标速度 V_d 。在 WLTC 工况下利用 PSO 离线算法优化九个初始参数, 并将优化之后的参数作为初始参数分别传递给 RBFNN 和 PID, RBFNN 在线自适应调整 PID 参数。

2.1 基于 RBFNN 的 PID 控制器

单一 PID 控制器的增益参数是定值, 但 P, I, D 三个环节相互影响和制约, 它们之间的关系较复杂, 并不是简单的线性关系, 同时车辆动力学系统为高阶的非线性系统。而 RBFNN 是一种前馈式神经网络, 具备并行计算和处理非线性系统的能力, 并且结构简单、学习速度快、能够处理过拟合。为实现更高的速度控制精度, 基于 RBFNN 对 PID 控制器进行改进, 将自适应的 RBFNN-PID 控制器应用于自动驾驶汽车纵向控制中。RBFNN-PID 控制框架如图 1 中(b)所示, 车辆纵向动力学模型根据输入的节气门开度和制动主缸压力, 输出实际速度 V , RBFNN 神经网络的输入为实际速度 V , $t-1$ 时刻的实际速度 $V(t-1)$, PID 控制器 $t-1$ 的输出 $A(t-1)$, 输出为 V_R 。由实际速度 V 和神经网络输出 V_R 之间的误差、PID 三个增益参数的学习率 (η_p, η_i, η_d) 来计算 PID 三个增益参数的增量 ($\Delta k_p, \Delta k_i, \Delta k_d$), 可实现 PID 三个增益参数的自适应调整。将更新后的增量、实际速度与目标速度的误差、PID 控制器 $t-1$ 时刻的输出 $A(t-1)$ 传输到 PID 控制器中, 得到 PID 控制器的输出 $A(t)$, 该值用于简化速度的控制, 当 $A(t)$ 为正值时, 传递加速信号, 将其转化为节气门的开度 A_T , 当 $A(t)$ 为负值时, 传递减速信号, 将其转化为制动主缸压力 P_B 。

2.1.1 基于 RBFNN 的 PID 增益参数自适应调整

PID 控制器通过 RBFNN 自适应调整参数, 该

控制器使用增量 PID 控制理论, 其控制的误差为:

$$e(t) = V_d(t) - V(t) \quad (1)$$

控制器的输入以及控制算法为:

$$\begin{cases} xc(1) = e(t) - e(t-1) \\ xc(2) = e(t) \\ xc(3) = e(t) - 2e(t-1) + e(t-2) \end{cases} \quad (2)$$

$$\begin{cases} A(t) = A(t-1) + \Delta A(t) \\ \Delta A(t) = K_p xc(1) + K_i xc(2) + K_d xc(3) \end{cases} \quad (3)$$

式中: $V_d(t)$ 为 t 时刻的目标信号; $V(t)$ 为被控对象的输出; $xc(1), xc(2), xc(3)$ 是 PID 控制器的 3 个输入; $A(t)$ 为 t 时刻 PID 控制器的输出, 设置 PID 控制器的参数调节的性能指标为:

$$J_c = \frac{1}{2} (V_d(t) - V(t))^2 \quad (4)$$

为了使 J_c 最小, 使用梯度下降法调节 PID 的增益参数:

$$\begin{cases} \Delta K_p = -\eta_p \frac{\partial J_c}{\partial K_p} = -\eta_p \frac{\partial J_c}{\partial V} \frac{\partial V}{\partial \Delta A} \frac{\partial \Delta A}{\partial K_p} = \\ \eta_p e(t) \frac{\partial V}{\partial \Delta A} xc(1) \\ \Delta K_i = -\eta_i \frac{\partial J_c}{\partial K_i} = -\eta_i \frac{\partial J_c}{\partial V} \frac{\partial V}{\partial \Delta A} \frac{\partial \Delta A}{\partial K_i} = \\ \eta_i e(t) \frac{\partial V}{\partial \Delta A} xc(2) \\ \Delta K_d = -\eta_d \frac{\partial J_c}{\partial K_d} = -\eta_d \frac{\partial J_c}{\partial V} \frac{\partial V}{\partial \Delta A} \frac{\partial \Delta A}{\partial K_d} = \\ \eta_d e(t) \frac{\partial V}{\partial \Delta A} xc(3) \end{cases} \quad (5)$$

式中: $\Delta k_p, \Delta k_i, \Delta k_d$ 分别为 PID 增益参数的 3 个增量; η_p, η_i, η_d 分别是 PID 增益参数的 3 个学习率, 在公式(5)中的 $\partial V / \partial \Delta A$ 为被控对象的 Jacobian 信息, 即对象的输出对控制输入的灵敏度, 其可通过 RBFNN 进行辨识获得。

式(6)和(7)中, $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$ 为神经网络的输入量, $\mathbf{h} = [h_1, h_2, \dots, h_m]^T$ 为神经网络隐层节点径向基向量, $\mathbf{c}_j = [c_{j1}, c_{j2}, \dots, c_{jn}]^T$ 是第 j 个神经元隐层节点的中心向量, $\mathbf{b} = [b_1, b_2, \dots, b_m]^T$ 为隐层节点的基宽向量, $\mathbf{w} = [w_1, w_2, \dots, w_m]^T$ 是隐层到输出层的权重向量, V_R 为神经网络的输出; $V_R(t)$ 为神经网络在 t 时刻的输出。

$$\begin{cases} h_j = \exp\left[-\frac{\|X - c_j\|^2}{2b_j^2}\right], j=1, 2, \dots, m \\ V_R = \sum_{i=1}^m w_i h_i \end{cases} \quad (6)$$

$$\frac{\partial V(t)}{\partial \Delta A(t)} \approx \frac{\partial V_R(t)}{\partial x_1} = \sum_{j=1}^m \frac{\partial V_R(t)}{\partial h_j} \frac{\partial h_j}{\partial x_1} = \sum_{j=1}^m w_j h_j \frac{c_{j1} - x_1}{b_j^2} = \sum_{j=1}^m w_j h_j \frac{c_{j1} - \Delta A(t)}{b_j^2} \quad (7)$$

定义被控对象(车辆纵向动力学模型)在 t 时刻的输出为 $V(t)$, 取神经网络的性能指标函数为:

$$J = \frac{1}{2}(V(t) - V_R(t))^2 \quad (8)$$

由公式(3)和(5)可得:

$$A(t) = A(t-1) + (K_{p0} + \Delta K_p)xc(1) + (K_{i0} + \Delta K_i)xc(2) + (K_{d0} + \Delta K_d)xc(3) \quad (9)$$

式中: k_{p0}, k_{i0}, k_{d0} 是 PID 控制器的 3 个初始值。

2.1.2 RBFNN-PID 结构设计

RBFNN 的学习率 η 和动量因子 α 取值范围为 $[0, 1]$, 取 $\eta = 0.25$, $\alpha = 0.05$, RBFNN 的 3 个输入为 $X = (x_1, x_2, x_3)$; 其中 x_1 是 PID 控制器的输出 $\Delta A(t)$, x_2 是 t 时刻的实际速度 $V(t)$, x_3 是 $(t-1)$ 时刻的实际速度 $V(t-1)$, 由众多实验经验可知, 当隐藏层的节点数为 6 时, 模型的性能比较好, 模型的输出为 V_R , 所以将 RBFNN 的网络结构设置为 3-6-1。

2.2 基于粒子群算法优化

RBFNN 的初始参数和 PID 初始参数也会影响到控制系统的性能。初始参数选择不当可能会造成系统的超调、失稳等问题。本文采用 PSO 算法离线优化 RBFNN-PID 控制器的 9 个初始参数。

设置适应度函数为^[17]:

$$f(t) = \int_0^t |e| dt \quad (10)$$

式中: t 为控制系统的仿真时间; $e = V_d(t) - V(t)$ 为

目标车速与实际车速之间的误差。

为平衡 PSO 算法的全局和局部搜索能力, 采用线性递减的方式确定粒子速度更新的惯性权重 W 。

$$W(f) = W_{\max} - (W_{\max} - W_{\min}) \frac{f}{T_{\max}} \quad (11)$$

通常当 $W_{\max}=0.9$, $W_{\min}=0.4$ 时算法性能最好, T_{\max} 是算法迭代的最大次数。

基于 PSO-RBFNN-PID 控制器的主要优化步骤为:

step 1: 初始化粒子位置和速度信息, 设置种群规模为 $N=10$, 迭代总次数为 30, 粒子位置信息维度为 9, 即需要优化的九个参数, 粒子位置信息 $P = [k_p, k_i, k_d, \eta_p, \eta_i, \eta_d, c_0, b_0, w_0]$, 取位置范围上限 $[160, 160, 160, 1, 1, 1, 40, 40, 40]$, 位置下限为 $[0.01, 0.01, 0.01, 0.01, 0.01, 0.01, 0.01, 0.01, 0.01]$, 粒子速度信息 $V \in [-0.5, 0.5]$ 。当前迭代的次数设为 $f=1$;

step 2: 计算每个粒子的适应度值, 求解出个体极值和群体极值;

step 3: 根据求解出个体极值和群体极值进行每个粒子位置、速度信息的更新和适应度值的更新, 然后更新个体极值和群体极值;

step 4: 迭代次数加一;

step 5: 如果结束条件(达到最大的迭代次数或者适应度值小于某个值)满足, 系统会结束运行, 否则返回 step 2。

优化结果由图 3 所示。

由图 3 可知, 在目标速度 V_d 为 WLTC 工况下对应的速度时, 采用粒子群优化算法, 控制系统经过 30 次迭代优化之后的九个参数分别为 $k_p=1.078$, $k_i=160$, $k_d=0.01$, $\eta_p=0.01$, $\eta_i=1$, $\eta_d=1$, $c_0=0.01$, $b_0=40$, $w_0=0.01$, 此时模型的适应度值为 1.75×10^5 , 性能最优。其中, $c=c_0 \times \text{ones}(3, m)$, $b=b_0 \times \text{ones}(m, 1)$, $w=w_0 \times \text{ones}(m, 1)$ 。

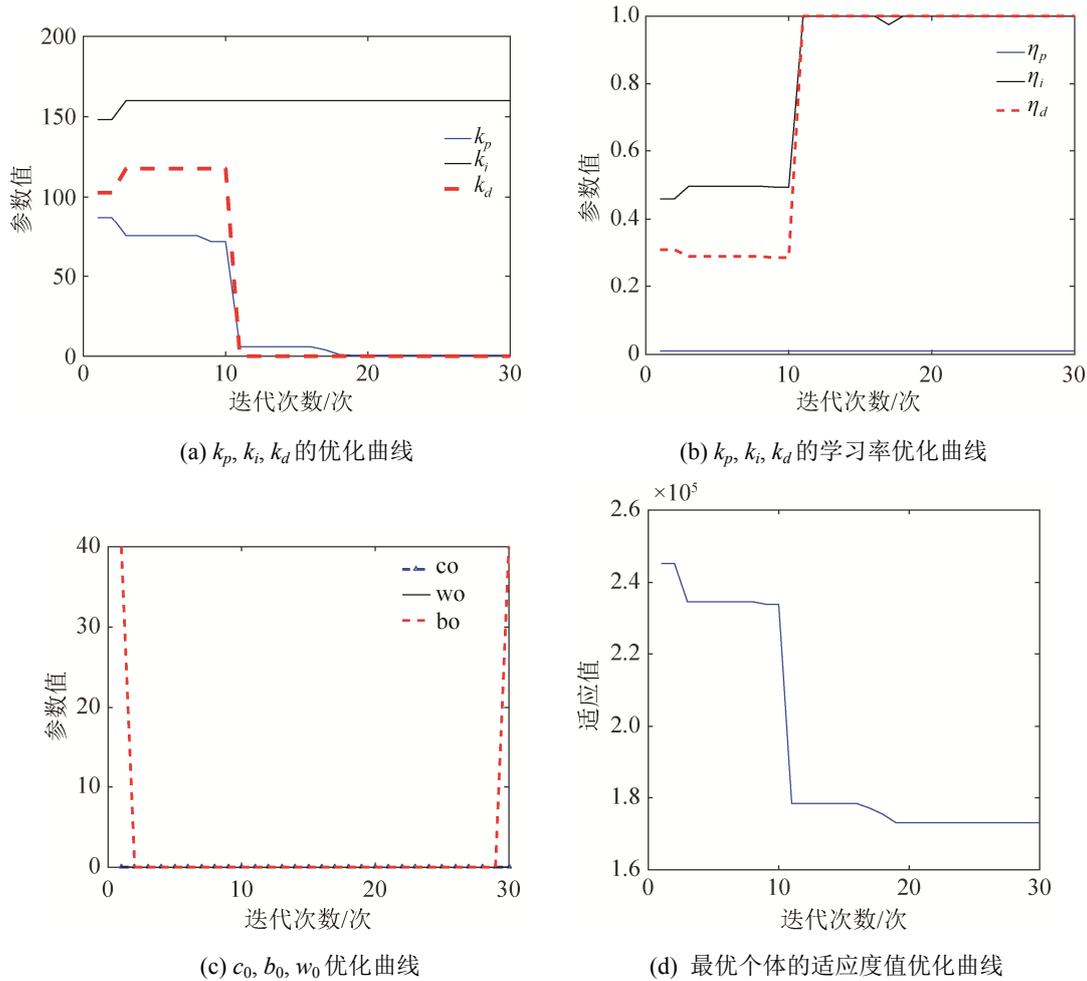


图 3 优化后的结果
Fig. 3 Optimized results

3 车辆纵向动力学模型

如图 1(c)所示, 车辆纵向动力学模型的总体框架包括发动机模型、传动系统模型、车轮驱动模型、制动模型, 其中传动系统模型包括自动变速器模型、主减速器模型。模型的输入为节气门开度或制动主缸压力, 输出为车辆的实际速度。

3.1 发动机模型

发动机模型的输入为节气门开度 A_T 和曲轴换挡要求的叶轮转矩 T_i , 输出为曲轴的转速 N_e 。它们之间的关系如下:

$$\begin{cases} T_{iq} = f(N_e, A_T) \\ N_e = \frac{1}{2\pi} \int \frac{T_{iq} - T_i}{I_e} \end{cases} \quad (12)$$

式中: T_{iq} 为发动机的有效转矩; I_e 为发动机曲轴的转动惯量。而 T_{iq}, N_e, A_T 三者之间的关系可由发动机实验的经验数据得到, 如图 4 所示。

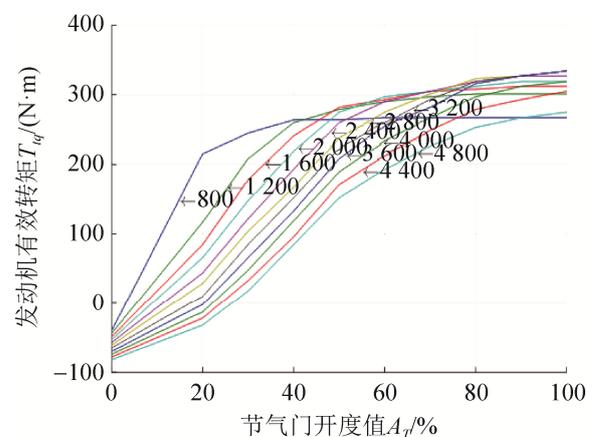


图 4 T_{iq}, N_e, A_T 三者之间的关系图
Fig. 4 Relationship among T_{iq}, N_e, A_T

3.2 传动系统模型

本研究中的汽车传动系统包括自动变速器以及主减速器，如图1(c)所示。

3.2.1 自动变速器模型

自动变速器模型包括液力变矩器模型、换挡逻辑模型以及变速器模型。

本研究中的液力变矩器模型输入为曲轴转速 N_e ，叶轮转矩 T_i ，输出为自动变速器输出轴转速 N_l 和自动变速器输入轴转矩 T_l 。

$$\begin{cases} T_l = N_e^2 / K^2 \\ T_l = T_i R_{TQ} \end{cases} \quad (13)$$

式中： K 为容量因子； R_{TQ} 为转矩因子，它们由转速比 N_l/N_e 决定，关系如下：

$$\begin{cases} K = f_2 \frac{N_l}{N_e} \\ R_{TQ} = f_3 \frac{N_l}{N_e} \end{cases} \quad (14)$$

式中： f_2 为容量系数； f_3 为变矩率系数。 K 、 R_{TQ} 均可由经验曲线得到，如图5(a)所示。

换挡逻辑模型的作用是根据节气门开度和车速调节自动变速器档位，换挡策略曲线如图5(b)所示。

变速器模型输入为自动变速器的输入轴转矩 T_l 和自动变速器输入轴转速 N_l ，输出为自动变速器的输出轴转矩 T_{io} 和自动变速器输出轴转速 N_{io} ，他们之间的关系为：

$$\begin{cases} T_{io} = T_l R_{TR} \eta_l \\ N_l = N_{io} R_{TR} \end{cases} \quad (15)$$

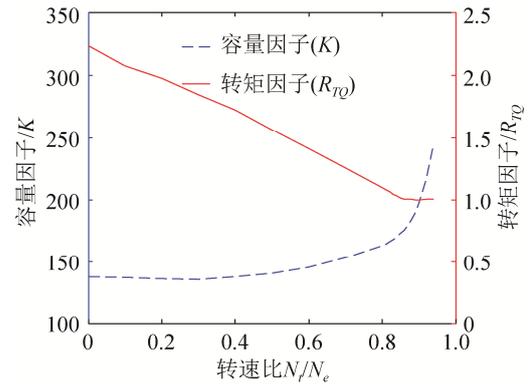
式中： η_l 为自动变速器效率； R_{TR} 为变速器传动比，其在1-4挡对应的值分别为2.39、1.45、1、0.67。

3.2.2 主减速器模型

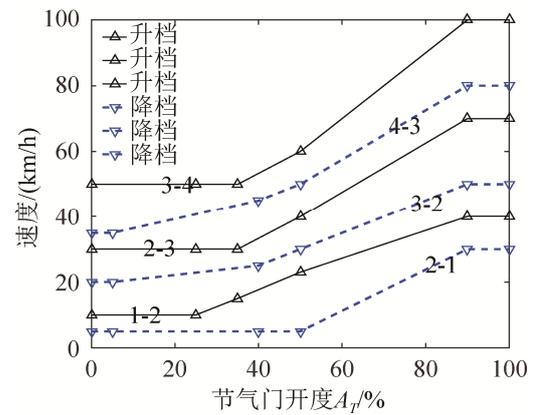
主减速器模型的输入为自动变速器的输出轴转矩 T_{io} 和自动变速器输出轴转速 N_{io} ，输出为车轮驱动力矩 T_e 和车轮转速 N_w ，他们之间的关系如下：

$$\begin{cases} T_e = T_{io} R_{fd} \eta_0 \\ N_{io} = N_w R_{fd} \end{cases} \quad (16)$$

式中： η_0 为主减速器的传动效率； R_{fd} 为主减速器传动比。



(a) 动力学模型的 K 和 R_{TQ} 参数曲线



(b) 换挡策略曲线

图5 参数曲线

Fig. 5 Curves of parameter

3.3 制动模型

制动主缸压力与主缸直径、杠杆比等参数有关，在不超过地面最大制动力的条件下，制动力矩 T_u 与制动主缸压力 P_B 的关系一般如下线性关系描述：

$$T_u = K_B P_B \quad (17)$$

式中： K_B 为制动主缸压力比例系数。

3.4 车轮驱动模型

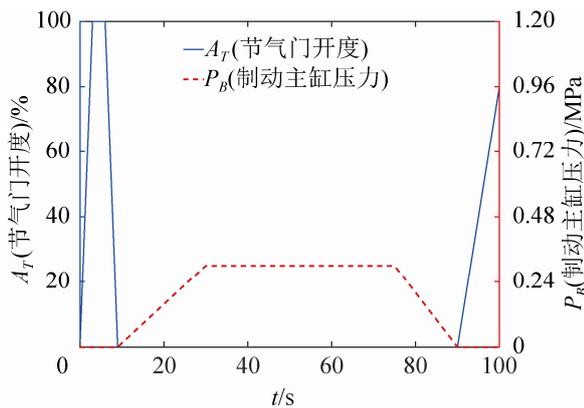
车轮驱动模型的内部转换关系为：

$$\begin{cases} V = 2\pi N_w r \\ \frac{T_e - T_u}{r} = mgf \cos \alpha + \frac{C_D A V^2}{21.15} + mg \sin \alpha + \delta m \dot{V} \end{cases} \quad (18)$$

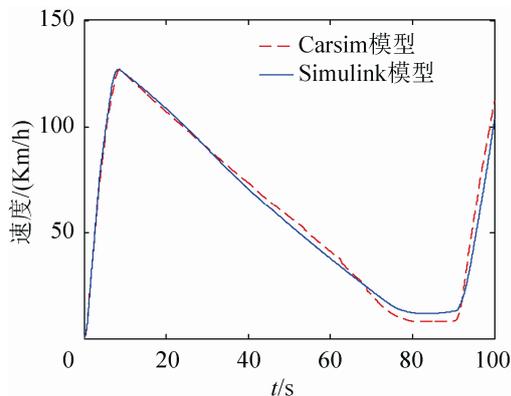
式中： r 为车轮的旋转半径； m 为车辆质量； f 为滚动阻力系数； C_D 为空气阻力系数； A 为车辆迎风面积； α 为道路坡度角，当忽略道路坡度时， $\alpha = 0$ ； δ 为车辆旋转质量换算系数。

3.5 汽车纵向动力学模型的有效性分析

CarSim 是目前获得普遍认可的车辆动力学仿真软件, 为了验证所提出的车辆纵向动力学模型的有效性, 选择 Carsim 与提出的车辆纵向动力学模型进行对比实验, 在 CarSim 中搭建车辆纵向动力学模型, 与本文中在 Matlab/Simulink 中所建的动力学模型在相同条件下(即输入相同节气门开度和制动主缸压力)进行仿真对比分析。如图 6(a)所示, 前期 $P_B=0$, A_T 快速增加到最大值保持一段时间后降低为 0, 相应的速度快速升高, 可有效模拟动力学模型启动的加速性能; 中期 P_B 先增加后减少, $A_T=0$, 相应的速度从高缓慢降低, 可有效模拟动力学模型的减速性能; 后期 $P_B=0$, A_T 快速增加, 可有效模拟动力学模型非启动时的加速性能。最后仿真结果如图 6(b)所示。



(a) 设置相同节气门开度和制动主缸压力



(b) 模型对比仿真结果

图 6 模型对比

Fig. 6 Model comparison

为了将 2 个模型中速度曲线的相关性进行评估, 使用 Person 两相关系数。其数学表达式为:

$$r_{xy} = \frac{\sum_{u=1}^l (X_u - \bar{X})(Y_u - \bar{Y})}{\sqrt{\sum_{u=1}^l (X_u - \bar{X})^2} \sqrt{\sum_{u=1}^l (Y_u - \bar{Y})^2}} \quad (19)$$

式中: r_{xy} 为两相关系数; l 为总采样点个数; X_u 为 CarSim 模型中第 i 个采样点; \bar{X} 为 CarSim 模型中采样点的采点均距; Y_u 为本文 simulink 模型中第 i 个采样点; \bar{Y} 为本文 simulink 模型中采样点的采点均距, $r_{xy} \in (-1,1)$, r_{xy} 的绝对值越趋近 1, 则两者之间的关联越强; 越趋近于 0, 则两者之间的关联越弱。相关性的强弱见表 2。

CarSim 和本文 Simulink 的动力学模型中设置相同节气门开度和制动主缸压力, 两模型的仿真结果图 6(b)中所示, 其中, 虚线部分为 CarSim 中模型输出速度随时间变化的曲线, 实线部分为本文 Simulink 中模型输出速度随时间变化的曲线, 从图中可以看出两种模型输出速度曲线趋势大致一样, 根据公式可算出 $r_{xy}=0.88$, 表现为极强相关, 说明了所建立的纵向动力学模型是有效的。

表 2 两相关性强弱

Tab. 2 Strength of correlation

极强两相	强两相	中等程度 两相	弱两相	极弱两相
0.8~1	0.6~0.8	0.4~0.6	0.2~0.4	0~0.2

4 仿真试验与结果分析

4.1 仿真架构

本研究的仿真架构如图 7 所示。其中, 在 Simulink 中构建 RBFNN 与 PID 相结合的车辆纵向运动控制器模型、车辆纵向动力学模型; 利用 CarSim 这一专业车辆动力学建模工具对 Simulink 中构建的车辆纵向动力学模型进行有效性验证; 在 MATLAB 中构建 PSO 算法对 Simulink 中控制器模型的初始参数进行离线优化。本研究选取了 WLTC 和 NEDC 两种测试工况, 其中 WLTC 工况用于

RBFNN 和 PID 的初始参数离线优化, NEDC 工况用于进行在线仿真测试。

4.2 控制模型与参数设计

控制系统的模型如图 1 中(b)所示, 包含目标速度 NEDC、RBFNN-PID 控制器、车辆纵向动力学

模型 3 个部分。PSO 优化之后的初始参数传递给 RBFNN-PID 纵向控制器, 该控制器进行在线自适应调整 PID 参数, 动力学模型为被控对象。NEDC 是欧洲续航测试标准, 由 4 个市区循环和一个市郊循环两种工况组成, 如图 8 所示。

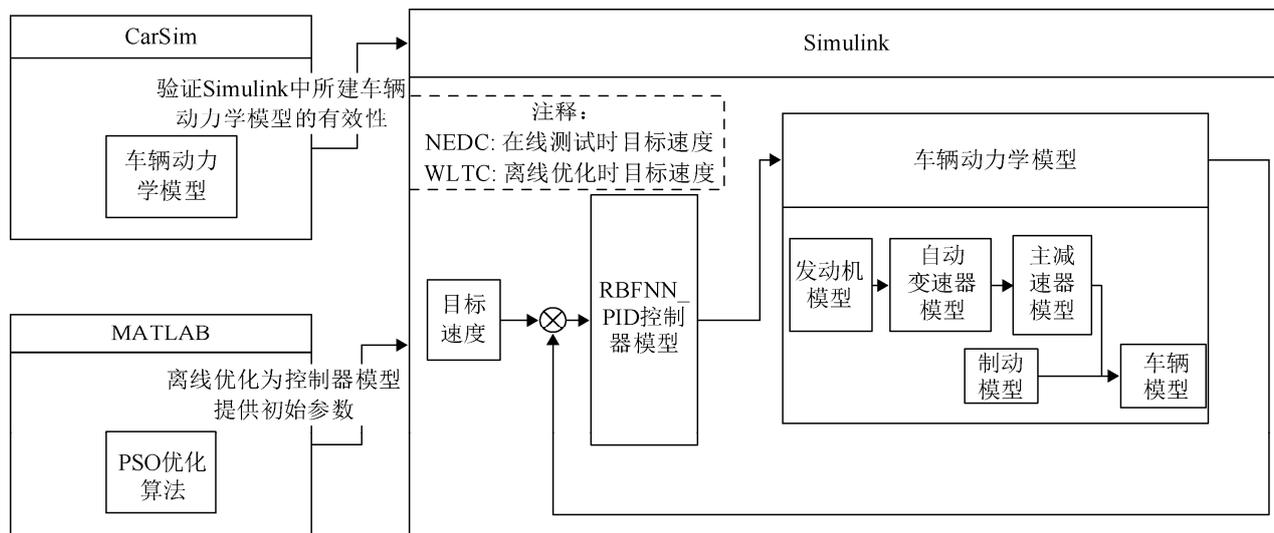


图 7 仿真架构

Fig. 7 Simulation architecture

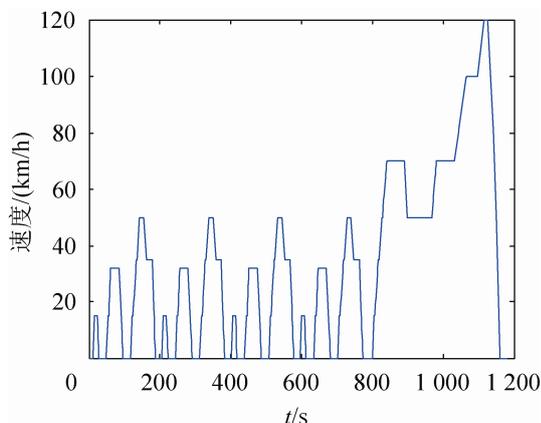


图 8. 新欧洲驾驶循环工况(NEDC)

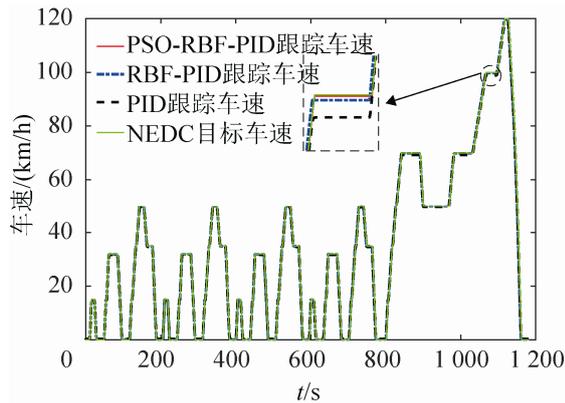
Fig. 8 New European driving cycle

图 8 中, 0~780 s 模拟的是市区工况, 在测试时反复进行加速、维持速度、减速、停止等驾驶模式共 4 次; 780 s 以后即开始模拟市郊工况, 最高时速可高达 120 km/h。该 NEDC 循环工况复杂, 且速度变化的范围跨度大, 在 0~120 km/h 之间, 因此选用 NEDC 作为跟踪的目标速度, 通过控制

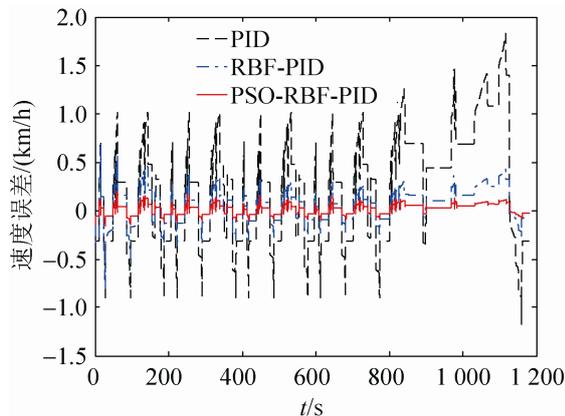
器实现速度的跟踪控制。本文将 PID 控制器, RBFNN-PID 控制器, PSO-RBFNN-PID 控制器仿真结果进行对比分析。其中 PID 控制器的初始增益参数值被设置为经典值; RBFNN-PID 控制器中 PID 的初始增益参数被设置为经典值, RBFNN 参数初始值和 PID 增益参数的学习率随机设置; PSO-RBFNN-PID 控制器的初始值设置为模型优化得到 9 个值。

4.3 控制精度及平稳性

安全性是本文在研究自动驾驶汽车需要优先考虑的问题, 而控制精度是影响自动驾驶安全的重要因素。由于 PSO-RBFNN-PID 中的 RBFNN 没有依靠数据集进行离线训练, 因此不存在过拟合的问题。本文将重点针对控制精度, 对 PID 控制器、RBFNN-PID 控制器、PSO-RBFNN-PID 控制器进行比较分析, 如图 9 所示。



(a) 3 种控制器的速度跟踪效果图



(b) 3 种控制器的速度跟踪误差

图 9 3 种控制器的速度跟踪

Fig. 9 Speed tracking of three controllers

由图 9 中(b)显示, PID 控制器的速度误差范围在 $[-1.177\ 0\ \text{m/s}, 1.831\ 6\ \text{m/s}]$, RBFNN-PID 控制器的速度误差范围在 $[-0.838\ 0\ \text{m/s}, 0.686\ 2\ \text{m/s}]$, PSO-RBFNN-PID 控制器的速度误差范围在 $[-0.155\ 9\ \text{m/s}, 0.211\ 2\ \text{m/s}]$ 。本文选用最大速度误差 e_{\max} 、均值 e_v 、方差 e_m 作为精度的性能指标。

$$\begin{cases} e_{\max} = \max\{e_1, e_2, \dots, e_Q\} \\ e_v = \frac{1}{Q} \sum_{r=1}^Q (e_r) \\ e_m = \frac{1}{Q} \sum_{r=1}^Q (e_r - e_v)^2 \end{cases} \quad (20)$$

式中: Q 为指采样的样本的总个数; e_{\max} 为局部的控制精度; e_v 为全局的控制精度; e_m 为控制的平稳性。3 种控制器的 3 个性能指标计算如表 3 所示。

表 3 速度误差的性能指标

Tab. 3 Performance indicator of Speed error / (m/s)

控制器	e_{\max}	e_v	e_m
PID	1.831 6	0.232 1	0.324 9
RBFNN-PID	0.686 2	0.055 9	0.032 0
PSO-RBFNN-PID	0.211 2	0.018 6	0.002 9

由表 3 可以看出:

(1) 局部精度: 3 种控制器的最大的速度误差 e_{\max} 是依次降低的, 因此, 采用 PSO-RBFNN-PID 控制器的局部精度优于其他 2 种控制器。

(2) 全局精度: PID 控制器的均值 e_v 比其他 2 种控制器的大得多, 全局控制精度较低, 且 PSO-RBFNN-PID 控制器的 e_v 值比 RBFNN-PID 控制器的 e_v 值小, 所以采用 PSO-RBFNN-PID 控制器的全局精度优于其他 2 种控制器。

(3) 稳定性: 采用 PSO-RBFNN-PID 控制器的方差 e_m 的值最小, 因此控制最稳定, RBFNN-PID 控制器次之, PID 控制器最不稳定。

结果表明: PSO-RBFNN-PID 控制器在控制精度和控制的稳定性方面优于 RBFNN-PID 和 PID 控制器。

5 结论

针对汽车的非线性、时变性、不确定性以及模型参数的随机性等问题, 本研究设计了一种基于 PSO-RBFNN-PID 的自适应调整参数的车辆纵向控制器。利用 PSO 算法, 确定 RBFNN 初始参数和 PID 的初始参数及学习率, RBFNN-PID 在线自适应调整参数实现纵向速度精确控制。该 PSO-RBFNN-PID 控制器可以使模型不用随机初始化参数, 模型智能选择优化参数。在 Matlab/Simulink 中建立车辆纵向动力学模型, 在 NEDC 工况下, 比较 PID、RBFNN-PID、PSO-RBFNN-PID 三种控制器的控制精度和稳定性。仿真结果表明无论是在控制精度还是稳定性上, 采用 PSO-RBFNN-PID 控制器都要优于 RBFNN-PID 控制器和 PID 控制器。

在本研究基础上, 下一步研究将重点考虑车辆

纵向动力学系统的滞后特性及其对车辆纵向控制的影响,设计控制器并展开基于实车的测试验证。

参考文献:

- [1] Gaining H, Weiping F, Wen W, et al. The Lateral Tracking Control for the Intelligent Vehicle Based on Adaptive PID Neural Network[J]. *Sensors* (S1424-8220), 2017, 17(6): 1244.
- [2] 刘贺. 考虑驾驶员风格的汽车纵向控制策略研究[D]. 长沙: 湖南大学, 2018.
Liu He. Research on Longitudinal Control Strategy of Automobile Considering Driver Style [D]. Changsha: Hunan University, 2018.
- [3] 陈天任. 车辆自动驾驶纵向控制策略研究[D]. 锦州: 辽宁工业大学, 2019.
Chen Tianren. Research on Longitudinal Control Strategy of Vehicle Autopilot[D]. Jinzhou: Liaoning University of Technology, 2019.
- [4] 王浩. 基于横向与纵向综合控制的智能车辆运动控制研究[D]. 南京: 南京航空航天大学, 2016.
Wang Hao. Research on Intelligent Vehicle Motion Control Based on Horizontal and Vertical Integrated Control[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2016.
- [5] Chien C C, Ioannou P, Lai M C. Entrainment and Vehicle Following Controllers Design for Autonomous Intelligent Vehicles[C]// 1994 American Control Conference. Baltimore, MD, USA: IEEE, 2002: 1-10.
- [6] Thanok S, Parnichkun M. Longitudinal Control of An Intelligent Vehicle Using Particle Swarm Optimization Based Sliding Mode Control[J]. *Advanced Robotics* (S0169-1864), 2015, 29(8): 525-543.
- [7] Wang Q, Qu T, Yu S Y, et al. Autonomous Vehicle Longitudinal Following Control Based on Model Predictive Control[C]// 2015 34th Chinese Control Conference. Hangzhou, China: IEEE, 2015: 8126-8131.
- [8] Attia R, Orjuela R, Basset M. Nonlinear Cascade Strategy for Longitudinal Control in Automated Vehicle Guidance[J]. *Control Engineering Practice* (S0967-0661), 2014, 29(6): 225-234.
- [9] Guo J, Luo Y, Li K, et al. Adaptive Dynamic Surface Longitudinal Tracking Control of Autonomous Vehicles[J]. *IET Intelligent Transport Systems* (S1751-956X), 2019, 13(8): 1272-1280.
- [10] 朱晓宏. 车辆自动驾驶纵向运动模糊神经控制研究[D]. 武汉: 武汉理工大学, 2003.
Zhu Xiaohong. Research on Fuzzy Neural Control of Longitudinal Motion of Vehicle Autopilot[D]. Wuhan: Wuhan University of Technology, 2003.
- [11] 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* (S1751-956X), 2018, 12(6): 485-494.
- [12] 周晶晶, 徐友春, 张自立, 等. IPZO-MPC 算法在智能车纵向速度控制中的应用[J]. *军事交通学院学报*, 2017, 19(4): 38-42.
Zhou Jingjing, Xu Youchun, Zhang Zili, et al. Application of IPZO-MPC Algorithm in Longitudinal Speed Control of Smart Cars[J]. *Journal of Military Transportation University*, 2017, 19(4): 38-42.
- [13] Ye Y, Yin C B, Gong Y, et al. Position Control of Nonlinear Hydraulic System Using an Improved PSO Based PID Controller[J]. *Mechanical Systems & Signal Processing* (S0888-3270), 2017, 83: 241-259.
- [14] Zhang Y, Chen Q J. Prediction of Building Energy Consumption Based on PSO-RBF Neural Network[C]// 2014 IEEE International Conference on System Science and Engineering. Shanghai, China: IEEE, 2014: 60-63.
- [15] Yu M, Zou Z Y, Ren F J, et al. Application of adaptive PID based on RBF neural networks in temperature control[C]// 11th World Congress on Intelligent Control and Automation. Shenyang, China: IEEE, 2014: 4302-4306.
- [16] Zhong Y C, Huang X, Meng P, et al. PSO-RBF Neural Network PID Control Algorithm of Electric Gas Pressure Regulator[J]. *Abstract and Applied Analysis* (S1085-3375), 2014(3): 1-7.
- [17] Sun X Y, Wei C, Zheng H Q, et al. A Method for Predicting Ultimate Bearing Capacity of Bolts Based on PSO-RBF Neural Network[C]. 2016 International Conference on Computational Intelligence and Applications. Jeju, South Korea: IEEE, 2016: 12-15.