

文章编号: 1005-0523(2024)05-0094-11



重载列车运行过程的建模与RBFNN滑模控制

李中奇^{1,2}, 曾祥泉^{1,2}, 余剑烽^{1,2}

(1. 华东交通大学电气与自动化工程学院, 江西 南昌 330013; 2. 华东交通大学轨道交通基础设施性能监测与保障国家重点实验室, 江西 南昌 330013)

摘要:【目的】为解决重载列车在复杂线路条件下难以实现高精度轨迹跟踪控制的问题, 提出了一种重载列车多质点模型和径向基函数神经网络滑模控制(RBFNNNSMC)方法。【方法】首先, 考虑空气制动和钩缓装置约束, 建立重载列车多质点模型, 并对人为测量误差和车辆参数差异等导致的模型不确定性问题, 利用RBFNN对其进行估计。其次, 设计一种非线性干扰观测器(NDO)对列车运行中受强风、雨雪等外界快时变干扰进行实时估计。然后, 设计Lyapunov函数对整个系统进行稳定性证明。【结果】基于大秦线的实际线路数据, 进行RBFNNNSMC方法、PID方法和SMC方法的速度跟踪对比实验。仿真结果表明, RBFNNNSMC方法的速度误差在 ± 0.15 km/h以内, 优于其他两种方法。加入NDO后, RBFNNNSMC方法的抗干扰能力也更强。【结论】基于NDO的RBFNNNSMC方法的跟踪精度相较于SMC方法在无干扰和受干扰情况下分别提升27.3%和28.9%, 鲁棒性有所提升。

关键词: 重载列车; 多质点模型; 空气制动; 滑模控制; 径向基函数神经网络; 非线性干扰观测器

中图分类号: U239.4

文献标志码: A

本文引用格式: 李中奇, 曾祥泉, 余剑烽. 重载列车运行过程的建模与RBFNN滑模控制[J]. 华东交通大学学报, 2024, 41(5): 94-104.

Modeling and RBFNN Sliding Mode Control for the Operation Process of Heavy Haul Trains

Li Zhongqi^{1,2}, Zeng Xiangquan^{1,2}, Yu Jianfeng^{1,2}

(1. School of Electrical and Automation Engineering, East China Jiaotong University, Nanchang 330013, China;

2. State Key Laboratory of Performance Monitoring and Protecting of Rail Transit Infrastructure,

East China Jiaotong University, Nanchang 330013, China)

Abstract: 【Objective】To address the challenge of achieving high-precision trajectory tracking control for heavy haul trains under complex track conditions, this paper proposes a multi-mass model for heavy haul trains and a radial basis function neural network sliding mode control (RBFNNNSMC) method. 【Method】First, considering the constraints of air brakes and coupler devices, a multi-mass model of the heavy haul trains was established, and the model uncertainty problems caused by human measurement errors and vehicle parameter differences were estimated by using RBFNN. Second, a nonlinear disturbance observer (NDO) was designed to be utilized for real-time estimation of strong wind, rain, snow, and other external fast time-varying disturbances during the operation of trains. Then, a Lyapunov function was designed to prove the stability of the entire system. 【Result】Based

收稿日期: 2024-06-21

基金项目: 国家自然科学基金项目(52162048)

on actual track data from the Daqin Railway, speed tracking comparison experiments were conducted using the RBFNNSMC method, PID method, and SMC method. Simulation results show that the speed error of the RBFNNSMC method is within ± 0.15 km/h, which is superior to the other two methods. Furthermore, the inclusion of the NDO significantly enhances the RBFNNSMC method's disturbance rejection capability. **[Conclusion]** The tracking accuracy of the RBFNNSMC method based on NDO is improved by 27.3% and 28.9% respectively compared to the SMC method in the absence and presence of disturbances, with enhanced robustness as well.

Key words: heavy haul trains; multi-mass model; air braking; sliding mode control; radial basis function neural network; nonlinear disturbance observer

Citation format: LI Z Q, ZENG X Q, YU J F. Modeling and RBFNN sliding mode control for the operation process of heavy haul trains[J]. Journal of East China Jiaotong University, 2024, 41(5): 94-104.

【研究意义】重载列车因其具有货运量大、运输经济性高、适应性强等优势备受关注^[1]。传统的人工驾驶行车准点率不高,给列车运行控制带来较大的纵向冲动,驾驶员的疲劳程度也会给行车过程带来安全隐患^[2],因此研究重载列车安全、平稳的自动驾驶技术势在必行。自动驾驶技术的关键在于确保高精度且稳定的速度跟踪控制^[3]。然而,自动驾驶控制器的设计难度大,这主要是由于列车模型建立的不够准确,以及复杂多变的线路条件和列车运行过程中受到的外界干扰等因素造成的^[4]。

【研究进展】设计控制系统首先要建立准确的模型。多质点模型因其能够准确的表述不同车厢的实时状态成为当前建立模型的主流方法。Wang等^[5]基于多质点模型设计了考虑输入饱和的鲁棒跟踪控制系统,但其模型中将车钩装置简化为弹簧系统,忽略了车钩装置的复杂性。付雅婷等^[6]在多质点模型中着重考虑钩缓装置的约束问题,但是忽略了电制动和空气制动的配合,导致其控制力超出合理范围。Liu等^[7]研究了双机牵引的重载列车在长大下坡过程中差异化协同控制对列车纵向力的影响,其模型中考虑循环空气制动与电制动的协同作用,从而有效减小列车纵向力。

模型建立之后,需要针对重载列车复杂的运行过程设计控制系统,进而实现高精度的跟踪控制。PID控制是重载列车控制领域的应用方法之一,但是其参数需要提前设定,且对于复杂环境适应性不强。为了克服这些局限性,更多的学者开始探索其他的控制策略,如李中奇等^[1]对重载列车多智能体模型设计了鲁棒一致性控制方法,极大的减小了外

界干扰的影响。鲁棒控制器虽能补偿不确定性,但补偿能力有限,若系统不确定性超出设计范围,控制器可能无法维持系统稳定,存在应用局限。孙鹏飞等^[4]将迭代学习和模型预测控制方法相结合,减小了列车纵向冲动,保证了列车的平稳运行,其迭代学习增益是利用线性二次型最优控制获得的,然而,该控制方法具有对模型依赖性强、对外界干扰敏感等缺陷。Liu等^[8]针对长陡下坡段的循环空气制动问题,提出了一种基于深度Q网络(Deep-Q-Network, DQN)算法的智能控制方法,但是DQN算法具有过拟合、算力消耗较大以及难以处理连续状态等问题。上述各种控制方法存在的缺陷主要集中于模型依赖性强、对未知干扰敏感、计算复杂度高等。

滑模控制(sliding mode control, SMC)方法对系统参数变化和外界干扰展现出良好的鲁棒性而备受瞩目。一些学者利用SMC在重载列车、四旋翼无人飞行器和永磁直线同步电机上分别进行了应用,结果表明,SMC增强了控制系统的鲁棒性,具有优良的轨迹跟踪效果^[9-11]。然而SMC也存在固有缺陷,如对模型的不确定性和快速时变扰动比较敏感,如果模型参数或者扰动发生较大的变化,会影响控制效果。但值得注意的是,研究表明径向基函数神经网络(radial basis function neural network, RBFNN)能够有效补偿模型中的不确定性。例如,文献[12-13]分别利用RBFNN对列车和双臂机械手的模型不确定性进行了有效估计和补偿。另外,由于RBFNN的映射关系在中心点确定后就固定下来,因此相较于迭代学习和DQN,RBFNN响应更

快、计算效率更高。考虑SMC和RBFNN的优势,刘杨等^[14]对二者进行了结合,将其应用于高速列车,实现了不错的轨迹跟踪效果,但是他们将列车视为单质点进行考虑,忽略了车辆间的耦合作用,而且抗干扰能力也有待提高。

面对实际工程系统中那些未知的、非线性的快时变干扰,单纯的RBFNN与SMC的结合仍显不足。为此,引入非线性干扰观测器(nonlinear disturbance observer, NDO)来观测和补偿SMC难以抵消的干扰至关重要,如:Ding等^[15]利用NDO有效补偿了列车在运行过程中受到外界干扰的影响。

【创新特色】根据以上分析,本文针对重载列车的运行过程提出了一种RBFNN和SMC相结合的控制方法RBFNNSMC,并在其中加入了NDO,整个系统的控制目标是在模型具有不确定性和快时变扰动的情况下跟踪期望的轨迹。本文的主要贡献包括建立一种重载列车多质点模型,该模型不但考虑了每节车厢受到的各种阻力,还将钩缓装置和空气制动加入模型中;针对该模型,提出了一种基于NDO的RBFNNSMC方法,其中,NDO用于精准估计快时变干扰,而RBFNN的引入使得系统能够实时学习并逼近模型中的复杂非线性关系。

【关键问题】本文构建的重载列车模型反映了更为真实的运行状况,设计的控制方法在面临模型不确定性和外部扰动时,依然能保证整个控制系统的稳定性,实现对目标轨迹的高精度追踪。

1 重载列车纵向动力学分析

万吨重载列车在铁轨上行驶过程中,不同的车厢所处的坡道位置信息差异较大。因此将重载列车的每一节车厢视为1个质点进行受力分析,以此提高模型的精度。在行驶过程中,重载列车纵向受力情况如图1所示,图1中相关参数见后文。




图1 重载列车纵向受力示意图

Fig. 1 Longitudinal force diagram of heavy haul trains

1.1 重载列车纵向作用力计算

1.1.1 机车牵引力/电制动力

重载列车在运行中,其动力与电制动力主要来源于机车的牵引与制动系统,而且列车的纵向冲劲很大程度上取决于机车的牵引/制动力大小,尤其是在空气制动过程中,合理控制牵引/制动力的大小可以防止脱钩事件的发生,保证列车的安全运行。HXD1机车牵引力及电制动力为^[5]

$$F_T = \begin{cases} 760, & v \in [0, 5] \\ 779 - 3.8v, & v \in (5, 65] \\ 34\,560/v, & v \in (65, 120] \end{cases} \quad (1)$$

$$F_B = \begin{cases} 92.2v, & v \in [0, 5] \\ 461, & v \in (5, 75] \\ 34\,560/v, & v \in (75, 120] \end{cases} \quad (2)$$

式中: F_T 为牵引力,kN; F_B 为电制动力,kN; v 为运行速度,km/h。

从式(1)、式(2)可以看出,HXD1机车的最大牵引力为760 kN,最大电制动力为461 kN。

1.1.2 运行阻力

重载列车在运行时会遇到多种阻力,其中最主要是基本运行阻力和附加阻力。基本运行阻力是列车与空气、钢轨之间的摩擦引起的。附加阻力是列车在坡道、弯道等线路条件下受到的外力。

参考标准《列车牵引计算第1部分:机车牵引式列车》(TB/T 1407.1—2018),基本运行阻力和附加阻力可分别表示为式(3)~式(5)。

$$F_w = A + B \times v + C \times (v)^2 \quad (3)$$

$$F_{ip} = I \quad (4)$$

$$F_{iq} = \frac{600}{R} \quad (5)$$

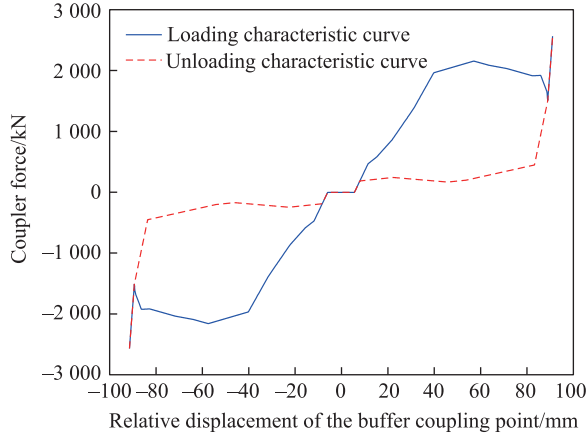
式中: F_w 为单位基本运行阻力,N/kN; F_{ip} 为单位坡道附加阻力,N/kN; F_{iq} 为单位曲线附加阻力,N/kN; A, B, C 为基本阻力系数; I 为坡道坡度,上坡为正,下坡为负; R 为曲线半径,m。

1.1.3 车钩力

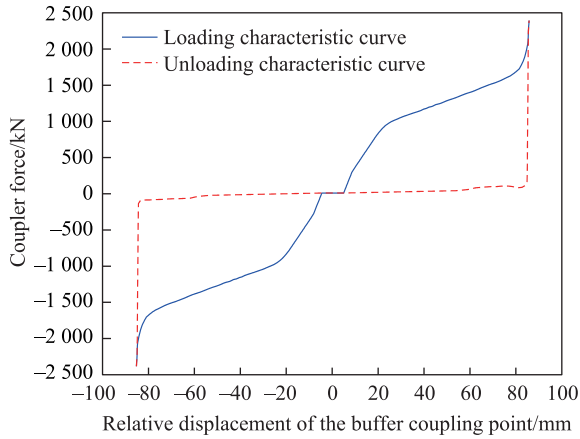
车厢之间的紧密连接主要依赖车钩和缓冲器组成的钩缓装置,整个列车只有机车提供前进的原动力,其他车厢前进的动力都是通过钩缓装置进行传递产生的。HXD1机车使用QKX100型缓冲器,C80货车采用MT-2型缓冲器。

车钩力可以利用下面的步骤获取:首先进行落锤实验,对两种缓冲器进行加载和减载测试;然后

提取缓冲器耦合点的相对位移与车钩力,形成缓冲器特性曲线,如图2所示;最后利用特性曲线表示车钩力。QKX100缓冲器带来的车钩力采用式(6)表示^[6]。



(a) Buffer characteristic curve of QKX100



(b) Buffer characteristic curve of MT-2

图2 缓冲器阻抗特性曲线

Fig. 2 Buffer resistance characteristic curve

$$F_c = \begin{cases} f_l & \Delta v \geq v_e \\ f_3 + (f_l - f_3) \frac{\Delta v}{v_e} \operatorname{sgn}(\Delta v) & -v_e < \Delta v < v_e \\ f_u & \Delta v \leq -v_e \end{cases} \quad (6)$$

式中: F_c 为车钩力,kN; f_l 为加载时的阻抗力,kN; f_u 为减载时的阻抗力,kN; f_3 为阻抗力的均值,kN; $f_3 = \frac{f_u + f_l}{2}$; Δv 为相邻两车的速度之差,km/h; v_e 为缓冲器转换速度,km/h。

MT-2缓冲器带来的车钩力 F_c 利用式(7)~式(9)计算得到^[6]。首先获取当前时刻的 f_u 和 f_l ,然后利用式(8)计算得到临时 F_c ,再将临时 F_c 代入式

(9)进行判定,满足式(9)时的车钩力就是临时 F_{c0} 。否则,车钩力为式(7)计算结果。

$$F_c(s_t, v_t) = \begin{cases} f_l(s_t) & |s_t| \geq |s_{t-\Delta t}| \\ f_u(s_t) & |s_t| < |s_{t-\Delta t}| \end{cases} \quad (7)$$

$$F_c(s_t, v_t) = F(s_{t-\Delta t}, v_{t-\Delta t}) + k(s_t - s_{t-\Delta t}) \quad (8)$$

$$|f_u(s_t)| \leq |F_c(s_t, v_t)| \leq |f_l(s_t)| \quad (9)$$

式中: s 为车辆行驶位移,下标 $t, \Delta t$ 分别为车辆当前时刻和前一时刻; $F_c(s_t, v_t)$ 为车钩力,kN; $f_l(s_t)$ 为加载时的阻抗力,kN; $f_u(s_t)$ 为减载时的阻抗力,kN; k 为缓冲器的刚度,N/m。

1.1.4 空气制动力

空气制动力是通过空气制动系统产生的,它利用压缩空气推动制动装置与车轮紧密接触,通过摩擦力使列车减速直至停止。空气制动力是重载列车实现安全制动的关键因素,其计算公式为

$$F_a = \beta_c \sum (\varphi \cdot \sum K) \quad (10)$$

式中: F_a 为空气制动力,kN; β_c 为常用制动因数; φ 为实算摩擦因数; K 为一块闸瓦实算压力,kN。

HXD1机车合成闸片、C80货车高磨合成闸瓦的实算摩擦因数 φ_H, φ_C 计算公式如下

$$\varphi_H = 0.441 \frac{K + 200}{4K + 200} \cdot \frac{2v + 150}{3v + 150} \quad (11)$$

$$\varphi_C = 0.481 \frac{K + 200}{4K + 200} \cdot \frac{2v + 150}{3v + 150} \quad (12)$$

HXD1机车实算闸瓦压力为

$$K' = \frac{\pi}{4} d_z^2 \cdot p_z \cdot r_z \cdot \eta_z \cdot 10^{-6} \quad (13)$$

车轮踏面制动闸片压力为

$$K = \frac{r_z}{R_c} \cdot K' \quad (14)$$

C80货车踏面制动每块实算闸瓦压力为

$$K = \frac{\pi}{4} d_z^2 \cdot p_z \cdot \eta_z \cdot \gamma_z \cdot (n_z/n_k) \cdot 10^{-6} \quad (15)$$

式中: d_z 为制动缸直径,mm; p_z 为制动缸空气压力,kPa; η_z 为制动传动效率; r_z 为制动盘摩擦半径,mm; R_c 为机车车轮半径,mm; γ_z 为制动效率; n_z 为制动缸个数; n_k 为闸瓦个数。

1.2 空气制动的触发与缓解

空气制动触发与缓解都是根据列车速度和所在位置(坡度、坡长)两个因素进行判断的。空气制动在列车运行速度超过60 km/h,并且前方2.5 km内存在4个坡度大于8%、长度超过500 m的大下坡路段时才会被触发。此外,两次空气制动的连续触

发之间,必须确保至少 160 s 的间隔。当列车速度降至比设定速度低 10 km/h 时,进行空气制动的缓解。然而,若列车速度低于 35 km/h,则不应缓解制动,因为过快的缓解可能导致纵向冲击过大,存在列车断钩的风险。

重载列车实施空气制动时,机车会先发出相应的制动指令。随后,这一制动信号会经过制动主管内的空气传递至后续车厢。这意味着不同位置的车厢接收到制动信号的时间不一致,因此,在仿真过程中需要考虑空气制动延时的影响。

1.3 重载列车纵向动力学模型

本文建立只有一台机车的列车模型,控制力只作用在机车上,后面的货车均由钩缓装置连接。建模时,尽管考虑了多车厢受力因素,但力的系数受测量与计算误差、车辆参数差异及外部因素影响,导致模型始终存在不确定性;另外,列车运行中还会受到强风和雨雪等外部干扰。

综合以上分析,重载列车纵向动力学模型表示为

$$\begin{cases} m_0 \ddot{s}_0 = u_0 - F_{C0} - F_{W0} - F_{f0} - F_{a0} + \Delta F_0 + \sigma_0(t) \\ \vdots \\ m_i \ddot{s}_i = F_{C,i-1} - F_{Ci} - F_{Wi} - F_{fi} - F_{ai} + \Delta F_i + \sigma_i(t) \\ \vdots \\ m_n \ddot{s}_n = F_{C,n-1} - F_{Wn} - F_{fn} - F_{an} + \Delta F_n + \sigma_n(t) \end{cases} \quad (16)$$

式中: m_i 为第*i*节车厢的质量,kg; s_i 为第*i*节车厢的位移,km; \ddot{s}_i 为第*i*节车厢的加速度, m/s^2 ; $F_{C,i-1}$ 和 F_{Ci} 分别为第*i*节车厢受到的前车钩力和后车钩力,kN; u_0 为机车的控制力,kN; $\sigma_i(t)$ 为第*i*节车厢受到的外界扰动,kN;令 $F_i = F_{C,i-1} - F_{Ci} - F_{Wi} - F_{fi} - F_{ai}$, ΔF_i 为 F_i 的不确定部分,kN,其中 $i=0, 1, 2, \dots, n$ 。

2 基于NDO的RBFNN滑模控制

针对第1节建立的重载列车模型,本节设计自适应神经网络滑模控制系统以实现列车的轨迹跟踪控制。首先,对非线性系统设计具有良好适用性的滑模控制器,利用一种自适应趋近律来削弱滑模控制中的抖振问题;然后针对模型中存在的非线性,利用RBFNN的逼近特性对其进行估计,将估计结果反馈给控制器;最后考虑到列车在实际运行过程中受到外界干扰问题,设计NDO对干扰进行观测,将观测结果反馈给控制器。

2.1 控制器设计

由式(16),可以得到机车的状态空间表达式

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{F}(\mathbf{x}) + \mathbf{G} \cdot u_0 + \mathbf{H} \cdot d(t) \\ \mathbf{y} = \mathbf{J}(\mathbf{x}) \end{cases} \quad (17)$$

式中: $\mathbf{x} = [x_1 \ v_1]^T$, $\mathbf{G} = [0 \ \frac{1}{m_0}]^T$, $\mathbf{H} = [0 \ 1]^T$, $F(\mathbf{x}) = [v_1 \ f(\mathbf{x}) + \Delta f]^T$, $f(\mathbf{x}) = -\frac{F_{C0} + F_{W0} + F_{f0} + F_{a0}}{m_0}$, $J(\mathbf{x}) = v_1$, x_1 是机车的位移,km; v_1 是机车的速度,km/h; Δf 是 $f(\mathbf{x})$ 的不确定部分; m/s^2 ; $d(t)$ 为机车受到的干扰,kN。

为了实现跟踪目标,首先定义机车的位移和速度跟踪误差为

$$\begin{cases} e(t) = x_1 - x_{1d} \\ \dot{e}(t) = v_1 - v_{1d} \end{cases} \quad (18)$$

式中, x_{1d} 、 v_{1d} 分别是期望位置、期望速度。然后,设计滑模面为:

$$s = \dot{e}(t) + \lambda_1 e(t) + \lambda_2 \int_0^t e(\tau) d\tau \quad (19)$$

式中: λ_1 、 λ_2 均为大于零的常数, τ 为列车运行时刻, s_0 。对式(19)求导,并将式(17)、(18)代入其中得:

$$\begin{aligned} \dot{s} &= \ddot{e}(t) + \lambda_1 \dot{e}(t) + \lambda_2 e(t) = \\ & \dot{v}_1 - \dot{v}_{1d} + \lambda_1 \dot{e}(t) + \lambda_2 e(t) = \\ & f(\mathbf{x}) + \Delta f + \frac{1}{m_0} u_0 + d(t) - \dot{v}_{1d} + \lambda_1 \dot{e}(t) + \lambda_2 e(t) \end{aligned} \quad (20)$$

传统的指数趋近律在远离滑模面时,其趋近速度较慢,而在接近滑模面时,其趋近速度不可调节,使得状态频繁且迅速地穿越滑模面,这导致系统发生明显的抖振问题。为加快机车状态在远离滑模面时的趋近速度并减小抖振问题,对传统趋近律进行改进,提出快速自适应趋近律^[16]。

$$\dot{s} = -\zeta |s|^\alpha \operatorname{sgn}(s) - \zeta \operatorname{sgn}(s) \quad (21)$$

式中: $\zeta > 0$, $\alpha > 0$, $\zeta = \kappa \tan(\operatorname{sig}|e(t)|)$,其中 $\kappa > 0$,

$$\tan(\operatorname{sig}|e(t)|) = \frac{1 - e^{-|e(t)|}}{1 + e^{-|e(t)|}}$$

令式(20)等于式(21),即可导出滑模控制律:

$$u_1 = -m_0 [f(\mathbf{x}) + \Delta f + d(t) - \dot{v}_{1d} + \lambda_1 \dot{e}(t) + \lambda_2 e(t) + \zeta |s|^\alpha \operatorname{sgn}(s) + \zeta \operatorname{sgn}(s)] \quad (22)$$

2.2 RBFNN逼近模型中不确定部分

RBFNN是一种基于径向基函数的前馈神经网络,具有简洁的学习过程和良好的逼近性能,适用于实时控制任务。机车系统式(17)中的不确定部分 Δf 与列车速度、位移相关,是非线性的函数,而对于未知非线性函数可采用RBFNN进行逼近,即用

权值和足够数量的基函数组成的神经网络表示。

令 $\delta = \Delta f$, 即有

$$\delta = \mathbf{W}^T \mathbf{h}(\boldsymbol{\chi}) + \varepsilon \quad (23)$$

$$\mathbf{W} = [w_1, w_2, \dots, w_j]^T \quad (24)$$

$$h_j(\boldsymbol{\chi}) = \exp\left(-\frac{\|\boldsymbol{\chi} - \mathbf{c}_j\|^2}{2b_j^2}\right) \quad (25)$$

式中: $\boldsymbol{\chi} = [e(t) \ \dot{e}(t)]^T$ 为网络输入向量; $h(\boldsymbol{\chi})$ 为高斯基函数的输出; \mathbf{W} 表示逼近 δ 的理想权值; ε 为神经网络逼近误差; \mathbf{c}_j 表示隐藏层中第 j 个基函数的中心向量; b_j 表示第 j 个节点宽度。

假设 $1 \|\mathbf{W}\|$ 和 ε 均存在上界 W_D, ε_D 即 $\|\mathbf{W}\| \leq W_D, \varepsilon \leq \varepsilon_D, W_D > 0, \varepsilon_D > 0$ 。

实际上,理想的神经网络权值往往难以直接求得。因此,我们通常采用式(26)对 δ 进行逼近,以达到更好的效果。

$$\hat{\delta} = \hat{\mathbf{W}}^T \mathbf{h}(\boldsymbol{\chi}) \quad (26)$$

式中, $\hat{\mathbf{W}}$ 为 \mathbf{W} 的估计值。同时,定义估计误差为:

$$\tilde{\mathbf{W}} = \mathbf{W} - \hat{\mathbf{W}} \quad (27)$$

为了证明控制器的稳定性,设计RBFNN的自适应律为式(28),其中, γ 为正实数。

$$\dot{\hat{\mathbf{W}}} = \gamma s \mathbf{h}(\boldsymbol{\chi}) \quad (28)$$

结合式(22)、式(23)、式(26)得到基于RBFNN的控制律为

$$u_2 = -m_0 [f(\mathbf{x}) + \hat{\delta} + d(t) - \dot{v}_{1d} + \lambda_1 \dot{e}(t) + \lambda_2 e(t) + \zeta |s|^\alpha \operatorname{sgn}(s) + \zeta \operatorname{sgn}(s)] \quad (29)$$

2.3 NDO设计

为在控制器中补偿未知的快时变干扰,需设计1个NDO对干扰进行观测,并将观测结果及时传递给控制器。

针对机车系统式(17),可以设计NDO为

$$\begin{cases} \dot{z} = -l(\mathbf{x})\mathbf{H} \cdot z - l(\mathbf{x})[\mathbf{H} \cdot p(\mathbf{x}) + F(\mathbf{x}) + \mathbf{G} \cdot u_0] \\ \dot{\hat{d}} = z + p(\mathbf{x}) \end{cases} \quad (30)$$

式中: z 是干扰观测器式(30)的内部状态, $p(\mathbf{x})$ 是待设计的函数, $l(\mathbf{x})$ 为式(31)。

$$l(\mathbf{x}) = \left[\frac{\partial p(\mathbf{x})}{\partial x_1} \quad \frac{\partial p(\mathbf{x})}{\partial v_1} \right] \quad (31)$$

定义观测器观测误差为

$$\tilde{d} = \hat{d} - d \quad (32)$$

将式(17)、式(30)代入式(32)的导数得到干扰观测误差的动态变化方程式

$$\begin{aligned} \dot{\tilde{d}} &= \dot{\hat{d}} - \dot{d} = \\ & \dot{z} + \frac{\partial p(\mathbf{x})}{\partial \mathbf{x}} \dot{\mathbf{x}} - \dot{d} = \\ & -l(\mathbf{x})\mathbf{H} \cdot z - l(\mathbf{x})[\mathbf{H} \cdot p(\mathbf{x}) + F(\mathbf{x}) + \mathbf{G} \cdot u_0] + \\ & l(\mathbf{x})[F(\mathbf{x}) + \mathbf{G} \cdot u_0 + \mathbf{H} \cdot d] - \dot{d} = \\ & -l(\mathbf{x})\mathbf{H} \cdot [z + p(\mathbf{x})] + l(\mathbf{x})\mathbf{H} \cdot d - \dot{d} = \\ & -l(\mathbf{x})\mathbf{H} \cdot \hat{d} + l(\mathbf{x})\mathbf{H} \cdot d - \dot{d} = \\ & -l(\mathbf{x})\mathbf{H} \cdot \tilde{d} - \dot{d} \end{aligned} \quad (33)$$

假设2系统式(17)所受的干扰和干扰的导数存在上界 D_1, D_2 , 即 $\|d(t)\| < D_1, \|\dot{d}(t)\| < D_2, D_1 > 0, D_2 > 0$ 。

定理1 在假设2得到满足的情况下,如果 $l(\mathbf{x})$ 被选择,使得式(34)渐近稳定

$$\dot{\tilde{d}} + l(\mathbf{x})\mathbf{H} \cdot \tilde{d} = 0 \quad (34)$$

则干扰观测误差系统式(33)是局部输入状态稳定的^[17]。

本文设置 $p(\mathbf{x}) = \omega v_1$, 其中 $\omega > 0$, 则 $l(\mathbf{x})\mathbf{H} = \omega$, 满足定理1条件。再将NDO式(30)观测结果反馈给控制律式(29),可以得到基于NDO的自适应神经网络滑模控制律:

$$u_3 = -m_0 [f(\mathbf{x}) + \hat{\delta} + \hat{d} - \dot{v}_{1d} + \lambda_1 \dot{e}(t) + \lambda_2 e(t) + \zeta |s|^\alpha \operatorname{sgn}(s) + \zeta \operatorname{sgn}(s)] \quad (35)$$

2.4 控制器的稳定性证明

选取Lyapunov函数为式(36)来证明本文设计的控制器的稳定性。

$$L = \frac{1}{2} s^2 + \frac{1}{2\gamma} \tilde{\mathbf{W}}^T \tilde{\mathbf{W}} \quad (36)$$

式中: γ 是大于0的常数,因此 $L \geq 0$ 。将式(20)代入式(36)的导数,可得

$$\begin{aligned} \dot{L} &= s\dot{s} + \frac{1}{\gamma} \tilde{\mathbf{W}}^T \dot{\tilde{\mathbf{W}}} = \\ & s [f(\mathbf{x}) + \Delta f + \frac{1}{m_0} u_0 + d(t) - \dot{v}_{1d} + \\ & \lambda_1 \dot{e}(t) + \lambda_2 e(t)] + \frac{1}{\gamma} \tilde{\mathbf{W}}^T \dot{\tilde{\mathbf{W}}} \end{aligned} \quad (37)$$

将式(23)代入式(37),并取 $u_0=u_3$,可得

$$\begin{aligned} \dot{L} &= s[\mathbf{W}^T h(\boldsymbol{\chi}) + \varepsilon - \tilde{\mathbf{W}}^T h(\boldsymbol{\chi}) + d - \hat{d} - \\ &\zeta|s|^\alpha \operatorname{sgn}(s) - \zeta \operatorname{sgn}(s)] + \frac{1}{\gamma} \tilde{\mathbf{W}}^T \dot{\hat{\mathbf{W}}} = \\ &s[-\tilde{\mathbf{W}}^T h(\boldsymbol{\chi}) + \varepsilon - \tilde{d} - \zeta|s|^\alpha \operatorname{sgn}(s) - \zeta \operatorname{sgn}(s)] + \\ &\frac{1}{\gamma} \tilde{\mathbf{W}}^T \dot{\hat{\mathbf{W}}} = \\ &-s\tilde{\mathbf{W}}^T h(\boldsymbol{\chi}) + \frac{1}{\gamma} \tilde{\mathbf{W}}^T \dot{\hat{\mathbf{W}}} + s(\varepsilon - \tilde{d}) - \zeta|s|^{\alpha+1} - \zeta|s| \end{aligned} \quad (38)$$

再将式(28)代入式(38),可得

$$\dot{L} = s(\varepsilon - \tilde{d}) - \zeta|s|^{\alpha+1} - \zeta|s| \quad (39)$$

由于RBFNN逼近误差 ε 和观测器观测误差 \tilde{d} 都是很小的实数, ζ, α 均是大于0的实数。因此只要选取 $\zeta \geq |\varepsilon - \tilde{d}|$,则可以满足 $\dot{L} \leq 0$ 。

当 $\dot{L} \equiv 0$ 时, $s \equiv 0$ 。根据拉萨尔不变集原理^[18],当 $t \rightarrow \infty$ 时 $s \rightarrow 0$,即系统是渐近稳定的。

3 实验与仿真

3.1 仿真模型及参数介绍

本文采用大秦线HXD1型机车和C80货车组成的“1+105”编组形式的重载列车进行仿真实验。HXD1机车的质量和长度分别为184 t和35.222 m,C80货车的质量和长度分别为100 t和12 m。HXD1机车和C80货车的基本阻力系数 A, B, C 分别是1.20、0.006 5、0.000 279和0.92、0.004 8、0.000 125;空气制动力计算参数见表1,针对该编组的列车,列车管减压量为50 kPa时,空气制动波速为200 m/s,缓解波速为36 m/s。全车长1.3 km,列车空气制动触发需要6 s左右,空气制动缓解需要36.1 s;模型不确定部分 δ 设为 $f(x)$ 的1%;控制器参数设置如下:

RBFNNSMC方法: RBFNN结构取为2-5-1,其中2、5、1分别表示网络的输入层、隐藏层、输出层的节点个数,初始权值设为0, $b_j = 0.005, \lambda_1 = 1.0, \lambda_2 = 0.1, c_1 = c_2 = 0.01 \times [-1 \ -0.5 \ 0 \ 0.5 \ 1], \zeta = 0.005, \kappa = 0.05, \alpha = 5, \gamma = 0.01, \omega = 1\ 000$ 。

SMC方法: $\lambda_1 = 1.0, \lambda_2 = 0.1, \zeta = 0.005, \kappa = 0.05, \alpha = 5$ 。SMC方法也采用式(21)所示的趋近律。

PID方法: 比例、积分、微分系数分别为 $10^7, 1, 1$ 。

为了验证第2节提出的重载列车自动驾驶控制方法在轨迹跟踪方面的精确性和系统的鲁棒性,采集大秦线大同南站到东井集站的实际运行数据进

行仿真实验。该区间内的路况信息以及王牌司机驾驶该列车通过该区段的路况和速度信息如图3和图4所示。

假设3 由于获取的线路数据有限,假设在该路段以

表1 重载列车空气制动力参数

Tab.1 Parameters for air braking force of heavy haul trains

Parameters	HXD1	C80
d_z/mm	225	254
P_z/kPa	450	430
γ_z	2.4	6.6
η_z	0.9	0.9
n_z	16	1
n_k	32	8
R_z/mm	1 250	
r_z/mm	448	

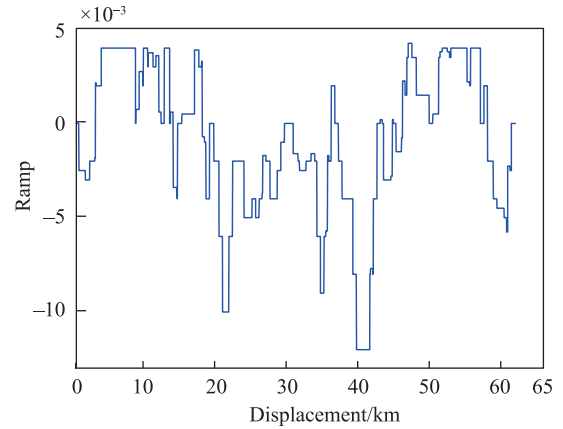


图3 路况信息

Fig. 3 Information on road conditions

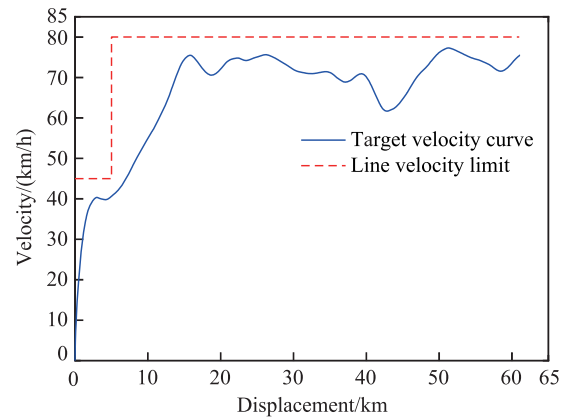


图4 实际驾驶速度及其限速

Fig. 4 Actual driving velocity and its velocity limits

前都是平直道,即坡道、弯道均为0。

3.2 控制器性能对比实验与仿真分析

为验证本文设计的控制器控制性能优劣,将RBFNNSMC控制方法与PID控制方法和SMC方法对采集的速度曲线进行跟踪对比实验。3种控制方法对目标速度曲线的跟踪效果和跟踪误差分别见图5和图6。

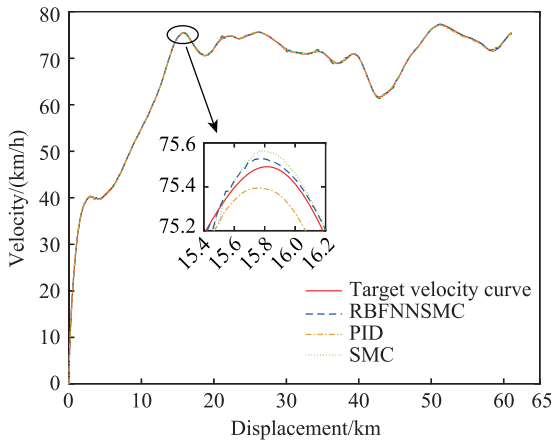


图5 3种方法的速度跟踪效果

Fig. 5 Velocity tracking effect for three methods




图6 3种方法的速度跟踪误差

Fig. 6 Velocity tracking error for three methods

从图5和图6可以看出,RBFNNSMC、SMC两种方法的速度跟踪误差有逐渐收敛的趋势,RBFNNSMC的速度跟踪误差在 ± 0.15 km/h以内,而SMC的速度跟踪误差在 ± 0.2 km/h以内。但是PID的速度跟踪误差曲线却和控制力曲线(图9)相似,收敛性较差,速度误差在 $-0.15\sim 0.27$ km/h以内。由此可知,上述3种方法对于目标速度曲线均有较好的跟踪效果,其中RBFNNSMC的跟踪性能最好、

SMC次之、PID效果最差。

图7和图8分别为RBF对模型不确定部分 δ 的估计效果和估计误差图,从中可以看出,RBF对于 δ 的估计效果较好,估计误差基本保持在 5×10^{-5} 以内。相反,SMC不存在对 δ 的估计功能,因此无法对其进行补偿。由此可以推出,RBFNNSMC跟踪效果优于SMC的原因之一是RBF对 δ 有较好的估计效果。

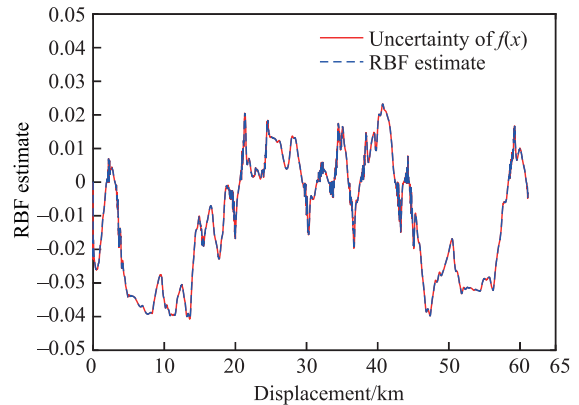


图7 RBF估计效果

Fig. 7 RBF estimation effect




图8 RBF估计误差

Fig. 8 RBF estimation error

图9、图10分别为3种方法控制力变化的对比图和部分钩缓装置的车钩力变化图。从该区段的线路信息(图3)可以得知:在该区段内的20、34 km和39 km附近有长大下坡路段,空气制动触使得机车的最大电制动力维持在461 kN以内(图9)。另外,从图10中可知,车钩力的变化始终保持在安全范围内,这一结果验证了本文研究的钩缓装置模型在模拟列车平稳安全运行过程中的有效性。但




图9 3种方法的控制力

Fig. 9 Control force for three methods

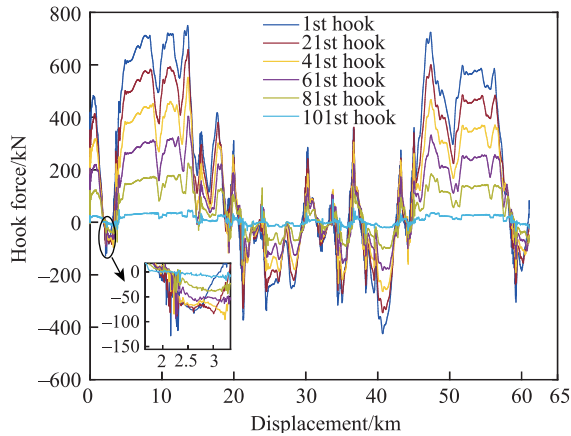


图10 部分钩缓装置的车钩力

Fig. 10 Hook force for partial hook retarders

是,由于车钩力是通过查表方式得到的,使得相邻车辆车钩力产生跳变,从而导致部分控制力出现频繁变化现象。但是从图9的局部放大图可以看出:针对车钩力的变化,RBFNNSMC和SMC的控制力的变化较为平稳,而PID的控制力却出现跳变情况,这在工程实际中容易导致执行器发生故障。因此,从控制力和车钩力变化方面可以看出,RBFNNSMC方法的平稳性优于PID。

3.3 抗干扰性能对比实验与仿真分析

为了验证本文设计的控制器抗干扰性能优劣,在不改变模型参数和控制器参数条件下,给上述3种方法加上相同的快速时变干扰,以检验它们对于未知扰动的抵抗能力。为反映扰动的时变性、不确定性和随机性,设计干扰为式(40)^[1]。并将干扰施加在列车的机车和第10,20,30,⋯,100号车厢上。

$$\sigma_i(t) = m_i \{ 0.002 + 0.001 \sin(t + 1) + 0.0003 \sqrt[3]{v} [\sin(2t + 2) + \cos(3t + 1)] \} \quad (40)$$

加上扰动后,3种方法对目标速度曲线的跟踪效果和跟踪误差如图11、图12所示。从图11可以看出3种方法对于速度曲线仍然具有一定的跟踪效果,但是从图12跟踪误差对比图及其局部放大图可以发现,SMC和PID2种方法受扰动影响较大,跟踪误差呈现出与干扰相似频率的振荡,相反,增加了NDO的RBFNNSMC方法的跟踪误差基本保持不变。

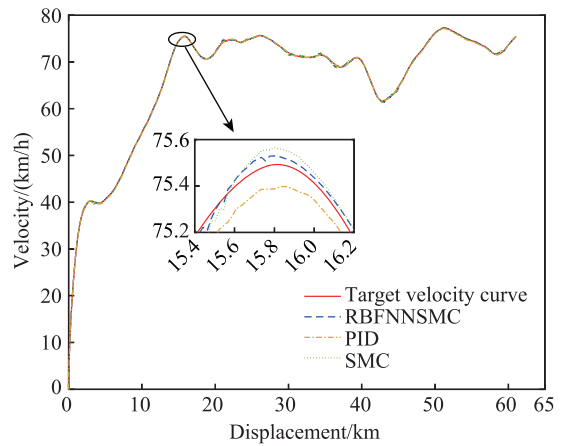


图11 加干扰后3种方法的速度跟踪效果

Fig. 11 Velocity tracking effect (post-disturbance) for three methods

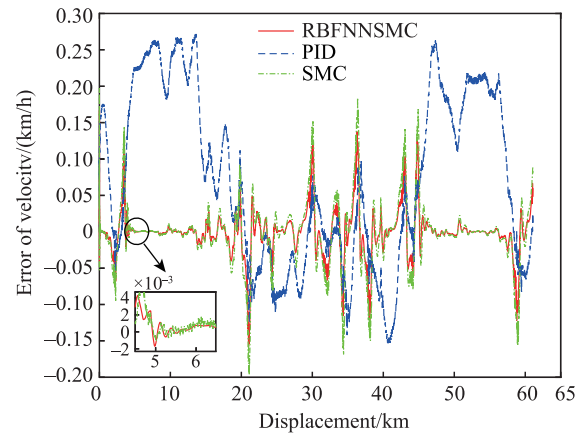


图12 加干扰后3种方法的速度跟踪误差

Fig. 12 Velocity tracking errors (post-disturbance) for three methods

为了更直观的分析加干扰前后3种方法的跟踪精度变化,引入均方根误差(root mean square error, RMSE)这一性能指标对其进行评价^[4],利用图6和

图12中的数据带入式(41)计算出速度跟踪误差的RMSE,从而得到表2。

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (v_{1k} - v_{1dk})^2} \quad (41)$$

式中: v_{1k} 、 v_{1dk} 分别为 k 时刻机车的实际速度和期望速度,km/h; N 是时间序列。

表2为在加干扰前后,PID、SMC和基于NDO的RBFNNSMC 3种方法的速度跟踪误差的RMSE,km/h。从中可以看出,基于NDO的RBFNNSMC在加干扰前后,其RMSE几乎不变且小于PID和SMC。同时利用此数据也可以计算出,在不受干扰情况下,基于NDO的RBFNNSMC比SMC跟踪精度提高了27.3%;受干扰情况下,跟踪精度提高了28.9%。

表2 加干扰前后3种方法的RMSE

Method	Pre-disturbance	Post-disturbance
PID	0.140 2	0.143 6
SMC	0.043 2	0.044 3
RBFNNSMC	0.031 4	0.031 5

4 结论

本文考虑列车模型的不确定性和外部扰动问题,建立了包含钩缓装置和空气制动的重载列车模型,研究了基于NDO的RBFNNSMC方法,并设计Lyapunov函数证明其稳定性,最后通过与经典PID方法和SMC方法对目标速度曲线进行对比实验,得到了以下结论。

1) RBFNNSMC方法实现了比PID、SMC方法对给定的速度曲线更精确的跟踪控制,速度误差在 ± 0.15 km/h以内,提高了列车运行的准点率。

2) 针对钩缓装置带来的车钩力跳变,RBFNNSMC方法的控制力变化更加稳定,保证了列车的安全平稳运行。

3) 基于NDO的RBFNNSMC方法在快时变扰动下观测效果显著,较PID和SMC方法鲁棒性更强,跟踪精度相较于SMC方法在无干扰和受干扰情况下分别提升27.3%和28.9%。

综上,基于NDO的RBFNNSMC方法不仅提高

了轨迹跟踪精度,还增强了系统的鲁棒性,展示出在复杂线路条件下的应用潜力。

参考文献:

- [1] 李中奇,王睿.重载列车多智能体模型的鲁棒一致性控制方法[J].控制与决策,2023,38(5):1448-1456.
LI Z Q, WANG R. Robust consistency control method for multi-agent model of heavy haul train[J]. Control and Decision, 2023, 38(5): 1448-1456.
- [2] 何闻.考虑纵向冲动的重载列车自动驾驶操纵研究[D].北京:中国铁道科学研究院,2023.
HE W. Research on automatic operation considering longitudinal impulse of heavy haul trains[D]. Beijing: China Academy of Railway Sciences, 2023.
- [3] 李中奇,周靓,杨辉,等.基于预测控制的动车组迭代学习控制方法[J].交通运输工程学报,2023,23(1):280-290.
LI Z Q, ZHOU L, YANG H, et al. Iterative learning control method for EMUs based on predictive control[J]. Journal of Traffic and Transportation Engineering, 2023, 23(1): 280-290.
- [4] 孙鹏飞,张传鑫,蒋春宏,等.结合迭代学习和模型预测的重载列车运行控制[J].中国铁道科学,2023,44(2):111-119.
SUN P F, ZHANG C X, JIANG C H, et al. Operation control of heavy-haul train based on combination of iterative learning and model prediction[J]. China Railway Science, 2023, 44(2): 111-119.
- [5] WANG X, SU S, CAO Y, et al. Robust cruise control for the heavy haul train subject to disturbance and actuator saturation[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(8): 8003-8013.
- [6] 付雅婷,原俊荣,李中奇,等.基于钩缓约束的重载列车驾驶过程优化[J].自动化学报,2019,45(12):2355-2365.
FU Y T, YUAN J R, LI Z Q, et al. Optimization of heavy haul train operation process based on coupler constraints [J]. Acta Automatica Sinica, 2019, 45(12): 2355-2365.
- [7] LIU W, SU S, TANG T, et al. Study on longitudinal dynamics of heavy haul trains running on long and steep downhill[J]. Vehicle System Dynamics, 2022, 60(12): 4079-4097.
- [8] LIU W, SU S, TANG T, et al. A DQN-based intelligent control method for heavy haul trains on long steep downhill section[J]. Transportation Research Part C: Emerging

- Technologies, 2021, 129: 103249.
- [9] HE J, YANG X, ZHANG C, et al. Sliding mode consistency tracking control of multiple heavy haul trains under input saturation and safety distance constraints[J]. Journal of the Franklin Institute, 2023, 360(12): 9028-9049.
- [10] BAEK J, KANG M. A synthesized sliding-mode control for attitude trajectory tracking of quadrotor UAV systems [J]. IEEE/ASME Transactions on Mechatronics, 2023, 28(4): 2189-2199.
- [11] XU D, DING B, JIANG B, et al. Nonsingular fast terminal sliding mode control for permanent magnet linear synchronous motor via high-order super-twisting observer[J]. IEEE/ASME Transactions on Mechatronics, 2021, 27(3): 1651-1659.
- [12] YANG J, ZHANG Y, JIN Y. Optimization of urban rail automatic train operation system based on RBF neural network adaptive terminal sliding mode fault tolerant control[J]. Applied System Innovation, 2021, 4(3): 51.
- [13] 裴香丽, 田颖, 张明路. 水下机械手水动力学分析及控制方法研究[J]. 船舶力学, 2022, 26(5): 679-690.
PEI X L, TIAN Y, ZHANG M L. Research on hydrodynamic analysis and control method of underwater manipulators[J]. Journal of Ship Mechanics, 2022, 26(5): 679-690.
- [14] 刘杨, 谭志勇, 初宪武, 等. 基于自适应RBF观测器的列车输出反馈控制[J]. 控制工程, 2022, 29(6): 1104-1110.
LIU Y, TAN Z Y, CHU X W, et al. High-speed train output feedback control based on adaptive RBF observer[J]. Control Engineering of China, 2022, 29(6): 1104-1110.
- [15] DING B, XU D, JIANG B, et al. Disturbance-observer-based terminal sliding mode control for linear traction system with prescribed performance[J]. IEEE Transactions on transportation electrification, 2020, 7(2): 649-658.
- [16] 李永恒, 刘陵顺, 胡云安, 等. 基于自适应趋近律的滑模控制方法[J]. 华中科技大学学报(自然科学版), 2019, 47(1): 109-113.
LI Y H, LIU L S, HU Y A, et al. Sliding mode control method based on adaptive reaching law[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2019, 47(1): 109-113.
- [17] CHEN W H, BALLANCE D J, GAWTHROP P J, et al. A nonlinear disturbance observer for robotic manipulators [J]. IEEE Transactions on industrial Electronics, 2000, 47(4): 932-938.
- [18] 武宪青, 何熊熊. 欠驱动基准系统的约束控制[J]. 控制理论与应用, 2015, 32(12): 1692-1697.
WU X Q, HE X X. Constrained control for the underactuated benchmark system[J]. Control Theory & Applications, 2015, 32(12): 1692-1697.



通信作者: 李中奇(1975—), 男, 教授, 博士, 博士生导师, 研究方向为轨道交通自动化与运行优化、列车运行过程建模及优化控制。E-mail: lzq0828@163.com。

(责任编辑: 龚凯, 吴海燕)