



基于启发式双端优化的重载列车 空电协同控制策略研究

张征方, 史可, 刘海涛, 王跃, 冯凌
(株洲中车时代电气股份有限公司, 湖南 株洲 412001)

摘要: 重载列车长大下坡道的空电协同属于带非线性状态约束、控制约束和终端约束的最优控制问题。传统的空电协同策略不具备同时处理非线性状态约束、控制约束、长距离终端约束的能力, 因此难以保证重载列车空电协同过程中的安全性和平稳性。为了解决这个问题, 文章提出一种基于启发式双端优化的重载列车空电协同控制策略。首先, 文章分析重载列车动力学特性, 提炼出空电协同过程的非线性状态约束、控制约束和终端约束; 然后, 在非线性状态约束和控制约束内对平稳性目标进行梯度寻优, 形成基于位置域的有限集序列, 同时, 设计神经网络对非线性空气制动模型参数进行辨识, 得到空气制动力预测值, 接着, 设计A*算法, 在有限集序列内实现迭代寻优, 得到满足终端约束的空电协同控制序列; 最后, 通过半实物仿真平台验证所提出的重载列车空电协同控制策略的有效性。

关键词: 重载列车; 长大下坡; 纵向动力学; 空电协同; 非线性有限集; 启发式双端优化; 重载铁路

中图分类号: U292.92^{†1}

文献标志码: A

文章编号: 1000-128X(2025)01-0114-08

0 引言

铁路运输尤其是重载铁路运输因其运能大、效率高、成本低等优点, 在世界多国得到了广泛的应用^[1]。中国地理西高东低, 导致列车下坡制动距离和制动时间非常长, 有时候制动距离需要10 km以上。但是, 很多时候在长大下坡道电制动不能抑制列车增速, 必须使用循环空气制动, 利用机车电制动力和车辆空气制动力的多动力源协同控制来顺利通过长大下坡区段。

重载列车的空电协同控制是一个高维度、非线性、强耦合的过程^[2]。列车中的空气制动系统制动力特性与空气的密度、列车速度和闸瓦的摩擦作用有关, 存在性能离散性大的问题^[3-4]。空电协同控制中空气制动只有追加和缓解两种状态, 可调节性差, 且有最小减压量限制。电制动力响应速度快, 但是动态调节受平稳性动力学性能约束。电制动压钩状态和钩缓约束相互

作用, 影响巨大, 因此空电协同安全控制裕量小, 空电协同过程的开始和结束的位置、速度都存在强约束。如果空电协同控制不满足约束, 容易导致缓解位置、速度和电制动力不满足要求, 非常容易引起车钩断裂、列车脱轨和超速等问题。因此, 长大下坡道空电协同控制是重载列车自动驾驶控制算法核心之一, 优化空电协同控制算法, 是解决循环协同控制中对于平稳、节能、精准等要求的重要手段。

在国外, 澳大利亚实现的某条特定线路重载列车无人驾驶, 并未过多地考虑车钩力, 是通过实施自动驾驶的路线输入该路线对应优秀司机的操纵(牵引/制动以及对应的挡位都完全按照司机的操纵输入进去, 因为优秀司机的操纵是能保证列车不会出现断钩、脱轨以及车钩力超过限定值)^[5]来实现的。在国内, 西南交通大学的孙翔等学者进行了列车间的纵向撞击原理、缓冲器的动态特性和运动状态的分析研究, 建立了重载列车纵向动力学模型以及相关辅助计算分析平台^[6]。

基金项目: 中国中车“十四五”重大专项(2021CTZ023)

通信作者: 史可, 男, 博士, 高级工程师, 主要从事列车自动驾驶运动规划与控制算法研究; E-mail: shike@csrzc.com

引用格式: 张征方, 史可, 刘海涛, 等. 基于启发式双端优化的重载列车空电协同控制策略研究[J]. 机车电传动, 2025(1): 114-121.DOI:10.13890/j.issn.1000-128X.2025.01.014.

Citation: ZHANG Zhengfang, SHI Ke, LIU Haitao, et al. Research on the pneumatic-electric braking collaborative control strategy for heavy-haul trains based on heuristic dual-end optimization[J]. Electric drive for locomotives, 2025(1): 114-121.DOI:10.13890/j.issn.1000-128X.2025.01.014.

池茂儒等学者在研究重载列车运行过程状态时, 分析了列车运动过程中钩缓系统各自由度性能之间的相互联系, 建立了列车三维空间耦合动力学模型, 利用循环变量法解决了在求解长大重载列车动力学模型的自由度爆炸性问题, 并模拟分析了重载列车在不同路况条件下牵引、制动和惰行工况的动力学性能^[7]。耿志修等学者主要研究大秦重载铁路上的重载列车, 建立重载列车运动仿真计算模型和制动状态模型^[8]。常崇义等学者利用高精度的数值迭代计算方法对2万吨重载组合列车纵向力试验进行计算, 研究了列车开始制动时的速度与列车纵向作用力之间的关系^[9]。大连交通大学的魏伟等学者利用空气制动系统与纵向动力学联合仿真系统, 可同步计算列车制动与纵向冲动的相关参数^[10]。朔黄铁路公司马志强专家等考虑空气制动力发挥动态过程, 以列车运行环境和车辆机械特性为约束, 建立重载列车多目标优化操纵模型, 并采用二次规划算法进行求解^[11]。北京交通大学王悉学者挖掘列车司机驾驶经验、揭示数据特征、预测控制规律并基于机器学习的方法来设计智能驾驶算法, 保证不同编组的重载列车安全、平稳、准时地运行^[12]。根据大秦线重载列车制动技术的特点和要求, 中国铁道科学研究院马大伟等学者给出了适合大秦线重载列车制动系统的建议, 分析了纵向力相关影响因素, 提出重载列车空电协同操纵方法^[13-14]。

综上所述, 目前的研究主要倾向于空气制动缓解过程后的纵向力分析, 这些研究缺乏主动的空电协同控制策略, 且具有以下控制难点: ①无法将空电协同中的多类、非线性、时变的状态约束和控制约束转化为合适的求解目标。②传统的优化控制的预测步长受限且缺乏诱导, 不适合解决这类包含终端约束的预测优化问题。③非线性的空气制动过程, 难以实时预测准确的空气制动力。

为解决以上这些问题, 文章将提出一种基于启发式双端优化的重载列车空电协同控制策略。首先, 分析重载列车动力学特性, 提炼出空电协同过程的非线性状态约束、控制约束和终端约束; 然后, 在非线性状态约束和控制约束内对平稳性目标进行梯度寻优, 形成基于位置域的有限集序列; 同时, 设计神经网络对非线性空气制动模型参数进行辨识, 得到空气制动力预测值; 接着, 设计A*算法, 在有限集序列内实现迭代寻优, 得到满足终端约束的空电协同控制序列。

1 重载列车动力学建模与分析

1.1 列车动力学模型

重载列车在纵向上整车受力状况和纵向动力学特性取决于动力学模型^[15]。考虑编组和连接情况, 构建如下的微分方程组以描述纵向动态:

$$m \cdot \ddot{x} = F_{\text{adb}} + F_b + F_r + F_c \quad (1)$$

式中: m 为机车或车辆质量; $\ddot{x}$ 为加速度; F_{adb} 为机车

牵引力或电制动力; F_b 为空气制动力; F_r 为阻力合力 (包括基本阻力和附加阻力等); F_c 为车钩力合力。

1.2 列车空气制动模型

重载列车空气制动特性采用经验模型模拟制动和缓解工况, 具体计算公式如下:

$$\left. \begin{aligned} \Delta t &= \min \left\{ \Delta t_{\text{loco},j} + \frac{x - x_{\text{loco},j}}{v_{\text{air}}}, j = 1, \dots, N \right\} \\ P_z(t) &= P_s \cdot \{1 - \exp[-k \cdot (t - \Delta t)^c]\} \\ P_r(t) &= P_f + (P_s - P_f) \cdot \exp[-\lambda(t - \Delta t)] \end{aligned} \right\} \quad (2)$$

式中: $\Delta t_{\text{loco},j}$ 为机车滞后时间; N 为机车台数; x 为车辆位置距离; $x_{\text{loco},j}$ 为第 j 台机车位置距离; v_{air} 为空气制动波速; Δt 为各节车辆滞后时间; k 为控制制动缸压力上升速率; c 为制动缸压力拟合修正参数; P_z 制动状态制动缸压力; P_s 为制动缸稳态压力; P_r 为缓解状态制动缸压力; P_f 为缓解结束时制动缸压力; λ 为制动缸缓解速率。

空气制动经验模型得到制动缸压力后, 将瞬时计算得到的制动缸压力转换成闸瓦力, 再由闸瓦摩擦因数即可计算得到空气制动力, 一般采用《牵引计算规程》^[16]中的计算公式 [见式(3)] 进行计算。

$$F_b = \sum \left(\frac{\pi}{4} \cdot d_z^2 \cdot p_z \cdot \eta_z \cdot \gamma_z \cdot n_z \cdot \varphi_k \right) \quad (3)$$

式中: d_z 、 p_z 、 η_z 、 γ_z 、 n_z 、 φ_k 分别为制动缸直径、制动缸压力、基础制动装置传动效率、制动倍率、制动缸数、闸瓦数和摩擦因数。

1.3 列车运行约束

1.3.1 动力学约束

1) 机车牵引/制动能力约束

列车运行过程中所能发挥的最大牵引力/电制动力与列车速度等因素相关, 表示如下:

$$\left. \begin{aligned} f_i &\leq f_{T,\max}(v_i) \\ f_i &\geq f_{E,\max}(v_i) \end{aligned} \right\} \quad (4)$$

2) 加速度最大最小约束

为保证运行过程的安全, 列车加速过程中的最大加速度和最大减速度均有限制, 具体表示如下:

$$a_{\min} \leq a_i \leq a_{\max} \quad (5)$$

3) 与线路相关的牵引力/电制动力约束

为保证重载列车在线路操纵困难或高风险区段如起伏坡道、长大上/下坡、空气制动施加/缓解区域、岔道等区域安全运行, 对重载列车在这些区段的牵引力/制动力设置限制如下:

$$\left. \begin{aligned} f_i &\leq f_{L,\max}(x_i, v_i) \\ f_i &\geq f_{L,\min}(x_i, v_i) \end{aligned} \right\} \quad (6)$$

4) 牵引手柄操纵约束

为保证重载列车的操纵平稳性, 牵引手柄不能变

化太频繁,具体表示如下:

$$\left. \begin{aligned} f_i &\leq f_{M,\max}(f_{i-1}) \\ f_i &\geq f_{M,\min}(f_{i-1}) \end{aligned} \right\} \quad (7)$$

1.3.2 缓解状态约束

在空气制动过程中,最优缓解状态包括位置、速度和电制动力,这3个要素可以根据前面分析得到。为了保证安全性和平稳性,列车的缓解目标应该遵循最优缓解位置构成的约束,如式(8)所示。

$$\left. \begin{aligned} v_g - \Delta v &\leq v_N \leq v_g + \Delta v \\ s_g - \Delta s &\leq s_N \leq s_g + \Delta s \\ f_g - \Delta f &\leq f_N \leq f_g + \Delta f \end{aligned} \right\} \quad (8)$$

式中: v_N 、 s_N 、 f_N 分别为当前节点的速度、位置和电制动力; v_g 、 s_g 、 f_g 分别为目标节点的速度、位置和电制动力; Δv 、 Δs 、 Δf 分别为允许的速度、位置和电制动力

力的误差范围。

2 基于启发式双端优化的空电协同控制策略

为了实现非线性,带有状态约束、控制约束和终端约束的重载列车空电协同最优控制,本文提出一种基于启发式双端优化的重载列车空电协同控制策略,其控制框架如图1所示,其创新点如下:①对空气制动模型进行校准。采用神经网络对空气制动模型参数进行离线辨识,能够准确预测非线性时延的空气制动力。②双端有限集生成。设计平稳性目标函数,在由动力学约束转换的状态约束和控制约束下,设计梯度下降法,求解基于位置域的双端有限集序列。③启发式寻优。将缓解状态约束认为是优化目标的终端约束,设计A*算法,在基于位置域的有限集序列内完成端端间的迭代寻优,实现最优空电协同控制序列预测。




图1 基于启发式双端优化的空电协同控制框架

Fig. 1 Framework of pneumatic-electric braking collaborative control strategy based on heuristic dual-end optimization

2.1 空气制动力预测模型

为了实现精确的空气制动力预测,设计空气制动力预测模型,包括基准模块离线辨识和修正模块在线校准两个部分。

2.1.1 基准模块离线辨识

采用RBF-NN对换算摩擦因数的试验系数离线辨识出最符合实际的空气制动模型基准模块^[17-18]。空气制动模型校准与预测框架如图2所示。

空气制动模型基准模块是根据《列车牵引计算:机车牵引式列车》中对于空气制动的描述进行建模的。根据规范,建立的空气制动模型基准模块如下:

$$\begin{aligned} & \text{空气制动力: } f^{\text{air}} = f_{\text{air}}(t, v) = \\ & \begin{cases} P_{\max} \times \mu, & t_{\text{end}} \geq t \geq t_{\text{start}} + t_{\max} \\ P_{\max} \left(\frac{(t - t_{\text{start}})/t_{\text{inrecre}}}{1} \right)^{\lambda} \times \mu, & t_{\text{start}} < t < t_{\text{start}} + t_{\max} \\ P_{\max} \left(\frac{(t - t_{\text{end}})/t_{\text{damping}}}{1} \right)^{\gamma} \times \mu, & t > t_{\text{end}} \end{cases} \quad (9) \end{aligned}$$

式中: μ 为换算摩擦因数, $\mu = \frac{a+bv}{c+dv}$ (a 、 b 、 c 、 d 为试验系数); $P_{\max}$ 为稳态制动缸压力。




图2 空气制动模型校准与预测原理图

Fig. 2 Schematic diagram of calibration and prediction of pneumatic braking model

离线辨识的输入为:施加速度、减压量、电制动

力、大闸减压量、充风时间、施加时间。输出为换算摩擦因数的试验系数。离线辨识流程如下:

①确定参数。确定输入向量 $X=[x_1, x_2, \dots, x_n]^T$, n 是输入层单元数; 确定输出向量 $Y=[y_1, y_2, \dots, y_q]^T$, q 是输出层单元数; 确定希望输出向量 $O=[o_1, o_2, \dots, o_q]^T$; 确定初始化隐含层至输出层的连接权值 $W_k=[w_{k1}, w_{k2}, \dots, w_{kp}]^T$ ($k=1, 2, \dots, q$), 确定初始化隐含层各神经元的中心参数 $C_j=[c_{j1}, c_{j2}, \dots, c_{jn}]^T$; 确定初始化宽度向量 $D_j=[d_{j1}, d_{j2}, \dots, d_{jn}]$ 。

②计算隐含层第 j 个神经元的输出值 z_j , 具体如下:

$$z_j = \exp\left(-\left\|\frac{X - C_j}{D_j}\right\|^2\right), \quad j=1, 2, \dots, p \quad (10)$$

③计算输出层神经元的输出, 具体如下:

$$Y=[y_1, y_2, \dots, y_q]^T \quad (11)$$

$$y_k = \sum_{j=1}^p w_{kj} z_j, \quad k=1, 2, \dots, q \quad (12)$$

④权重参数的迭代计算。

RBF-NN 权重参数的训练方法采用的是梯度下降法。中心、宽度和调节权重参数均通过学习来自适应调节到最佳值, 迭代计算如下:

$$\left. \begin{aligned} w_{kj}(t) &= w_{kj}(t-1) - \eta \frac{\partial E}{\partial w_{kj}(t-1)} + \alpha[w_{kj}(t-1) - w_{kj}(t-2)] \\ c_{kj}(t) &= c_{kj}(t-1) - \eta \frac{\partial E}{\partial c_{kj}(t-1)} + \alpha[c_{kj}(t-1) - c_{kj}(t-2)] \\ d_{kj}(t) &= d_{kj}(t-1) - \eta \frac{\partial E}{\partial d_{kj}(t-1)} + \alpha[d_{kj}(t-1) - d_{kj}(t-2)] \end{aligned} \right\} \quad (13)$$

式中: η 为学习因子; E 为 RBF-NN 的评价函数, $E = \frac{1}{2} \sum_{l=2}^N \sum_{k=1}^q (y_{lk} - O_{lk})^2$; O_{lk} 为第 k 个神经元在第 l 个输入样本时的期望输出值; y_{lk} 为第 k 个神经元在第 l 个输入样本时的网络输出值。

⑤计算网络输出的均方根误差, 具体如下:

$$N_{\text{RMS}} = \sqrt{\frac{\sum_{i=1}^N \sum_{k=1}^q (O_{lk} - y_{lk})^2}{qN}} \quad (14)$$

上式中, ε 为迭代终止精度, 若 $N_{\text{RMS}} \leq \varepsilon$, 则训练结束, 否则转到第③步。

经过上述步骤, 可以得到换算摩擦因数 $\mu = \frac{a+bv}{c+dv}$ 中的试验系数 a 、 b 、 c 、 d 。

2.1.2 修正模块在线校准

实际空气制动施加过程中, 实际空气制动力的上升沿和下降沿非线性更强, 且具有一定的空走时间, 不能单一地利用离线辨识的空气制动模型基础模块进行计算。因此, 本文采集动态参数的历史周期序列, 采用基于最小二乘拟合的换算摩擦因数的试验系数的在线修正方法, 在空气制动模型基准模块中进行在线

修正。修正过程中不再对换算摩擦因数的试验系数 a 、 b 、 c 、 d 进行逐一校准, 而是直接对换算摩擦因数 μ 进行校准。式(15)为所采用的最小二乘法计算公式。

$$\left. \begin{aligned} \hat{b} &= \frac{\sum_{k=1}^n x_k y_k - n \bar{x} \cdot \bar{y}}{\sum_{k=1}^n x_k^2 - n \bar{x}^2} \\ \hat{a} &= \bar{y} - \hat{b} \bar{x} \end{aligned} \right\} \quad (15)$$

2.2 双端有限集生成

双端有限集生成方法: 设计平稳性目标函数, 在由动力学约束转换的状态约束和控制约束下, 设计梯度下降法, 求解基于位置域的双端有限集序列。

2.2.1 平稳性目标函数生成

在对列车运行仿真计算时, 将整列车看作一个质点, 忽略列车长度及车辆间的作用力, 仅考虑该质点所在位置处的各种外力作用, 状态变量矩阵 $x=[s, v]^T$, 控制变量 $u=[f_e]$ 。单质点模型运动学微分方程如式(16)所示。

$$\dot{x} = \begin{cases} \dot{v} = \frac{1}{M} (M \cdot g \cdot (a + bv + cv^2) + f_{\text{slope}} + f_{\text{air}}(v) + u) \\ \dot{s} = v \end{cases} \quad (16)$$

式中: f_{slope} 为列车在所处位置受到的坡道阻力; u 为列车电制动力; f_{air} 为列车在当前运行状态下的空气制动力。

定义列车施加空气制动时的初始状态量 $x_0=[s_0, v_0]^T$, 目标状态量为 $x_{\text{opt}}=[s_{\text{opt}}, v_{\text{opt}}]^T$, 目标速度为 v_{opt} , 目标位置为 s_{opt} 。按位置域将连续状态空间方程以采样周期 Δs 将初始状态 x_0 与目标状态 x_{opt} 等距离划分为 i 个离散状态, 根据运动学计算得到第 i 个采样点的状态方程如式(17)。

$$\left. \begin{aligned} \Delta s &= \frac{s_{\text{opt}} - s_0}{i} \\ s_i &= s_0 + i \cdot \Delta s \\ v_i &= v_0 + i \cdot \frac{v_{\text{opt}} - v_0}{i} \\ F_i &= M \frac{v_i^2 - v_{i-1}^2}{2 \times \Delta s} \\ u_i &= F_i - f_{\text{slope}} - M \cdot g \cdot (a + b \cdot v_i + c \cdot v_i^2) - f_{\text{air}} \end{aligned} \right\} \quad (17)$$

式中: F_i 为列车在第 i 个离散状态所受的合力。

本文主要考虑对列车运行的平稳性进行优化, 设计平稳性目标函数。平稳性目标函数考虑列车运行过程中的整车加速度变化率, 加速度变化越快, 表征列车运动状态变化越快, 车钩状态越不稳定, 因此, 保证平稳性即可获取较小的加速度, 平稳性目标函数 J 设置如下:

$$J = \sum_0^i g(x, u) = \sum_0^i \dot{a}_i^2 = \sum_0^i \left(\frac{(v_i + v_{i-1})(v_{i+1}^2 - 2v_i^2 + v_{i-1}^2)}{4(\Delta s)^2} \right)^2 \quad (18)$$

式中: $\dot{a}$ 为加速度的变化率。

2.2.2 非线性有限集序列生成

第1步, 设置初始的电制动力操纵序列, 对第 i 个采样点进行梯度下降优化, 生成非线性有限集, 此时的 $\hat{u}_i$ 仅由初始状态 x_0 与最优缓解点状态 x_{opt} 连线所得的状态序列计算得到。根据式(18)列车平稳性指标及最优控制理论构造哈密尔顿函数 H , 如式(19)。

$$H(x, u, \frac{\partial J}{\partial x^T}) = \sum_0^{n-1} \hat{a}_i^2 + \frac{\partial J}{\partial x^T} \cdot \begin{bmatrix} f(s, v) \\ v \end{bmatrix} \quad (19)$$

其中, 梯度计算如下式所示:

$$\nabla J_{x_i} = 2\hat{a}_i \times \ddot{a}_i = 2 \times \left(\frac{v_{i+1}^2 - 2 \times v_i^2 + v_{i-1}^2}{2\Delta s} \cdot \frac{2 \cdot \Delta s}{v_{i+1} + v_i} \right) \left(\frac{v_{i+2}^2 - 2 \times v_{i+1}^2 + v_i^2}{2\Delta s} \cdot \frac{2 \times \Delta s}{v_{i+2} + v_{i+1}} - \frac{v_{i+1}^2 - 2 \times v_i^2 + v_{i-1}^2}{2\Delta s} \cdot \frac{2 \times \Delta s}{v_{i+1} + v_i} \right) \quad (22)$$

第2步, 对电制动力序列 $U(\hat{u}_0, \hat{u}_1, \dots, \hat{u}_{i-1})$ 进行约束处理, 使其中每个电制动力 $\hat{u}_i$ 都满足控制约束式(4)~式(8), 处理后的电制动力序列为 $U(u_0, u_1, \dots, u_{n-1})$, 电制动力 u_i 计算公式为

$$u_i = f_{\text{lim}}(\hat{u}_i) \quad (23)$$

式中: f_{lim} 表示综合所有约束的约束函数。

第3步, 得到操纵序列 $U(u_0, u_1, \dots, u_{n-1})$ 后, 初始状态 x_0 , 间隔为 Δs , 终止位置为 s_{opt} , 根据列车运动学方程式(16)重新迭代生成一遍初始状态序列 $(x_0, x_1, \dots, x_n)$ 。

$$s_{i+1} = s_i + \Delta s \quad (24)$$

$$v_{i+1} = \sqrt{v_i^2 + \frac{\Delta s}{m} (u_i + f_{\text{ramp}}(s_i) + f_{\text{curve}}(s_i) + f_{\text{basic}}(v_i) + f_{\text{air}}(s_i, v_i))} \quad (25)$$

根据初始状态序列 $(x_0, x_1, \dots, x_n)$ 在位置 s_i 处的梯度 ∇J_i 生成电制动力集合 $u_{\Omega, i}$, 如式(26)。

$$u_{\Omega, i} = u_i + j \cdot \nabla J_i, j = 0, 1, 2, \dots, k \quad (26)$$

能获得的所有电制动力序列组合即为有限集序列 Ω , 具体见式(27)、式(28)。

$$\Omega = \{U(u_i, u_{i+1}, \dots, u_{n-1}), u_i \in \Omega_i\} \quad (27)$$

$$\Omega_i = \{u_{\Omega, i} | u_{\Omega, i} = u_i + j \cdot \nabla J_i, j = 0, 1, 2, \dots, k\} \quad (28)$$

2.3 启发式寻优

启发式寻优, 将缓解状态约束认为是优化目标的终端约束, 设计A*算法, 在基于位置域的有限集序列 Ω 内完成端端间的迭代寻优, 实现最优空电协同控制序列预测。基于A*算法的迭代寻优流程图如图3所示, 有限集序列的A*算法寻优过程如图4。计算2.2节中得到的有限集 Ω 中每个电制动力序列下的速度, 计算每个操纵序列A*算法的代价函数, 选择使代价函数最小的序列, 判断其是否满足缓解要求, 若满足要求则输出序列, 不满足要求则选取该最优序列在位置 s_i 处的电制动力 u_i , 使状态 x_i 前进至状态 x_{i+1} , 再重复有限集生成和A*算法择优的过程。基于A*算法的空电协同序列寻优的实施步骤如以下2.3.1~2.3.3节所示。

$$\nabla J = \frac{\partial J}{\partial x^T} = [\dot{g}_s(s_i, v_i) \quad \dot{g}_v(s_i, v_i)] \quad (20)$$

在控制量 u 受到控制约束的条件下, 可能不再满足 $\partial H / \partial u = 0$, 从而不一定能够求解出最优控制量 u^* 。控制量 u 在受到控制约束式(4)~式(8)下, 满足下式:

$$H(x^*, u^*, \nabla J) \leq H(x^*, u, \nabla J) \quad (21)$$

式(21)表明, 满足使哈密尔顿函数 H 取最小值的 u^* 为最优控制量。由离散状态空间方程式(18)及式(22), 梯度下降 ∇J 计算如下式所示:




图3 基于A*算法的迭代寻优流程

Fig. 3 Iterative refinement process based on A* algorithm




图4 有限集序列的A*算法寻优过程

Fig. 4 Refinement process based on A* algorithm within finite set sequence

2.3.1 代价计算

通过A*算法实现在有限集序列 Ω 中的寻优过程, A*算法的启发函数为 $f^*(U)$, 计算公式如下:

$$f^*(U) = g^*(U) + h^*(U) \quad (29)$$

估计代价 $h^*(U)$ 的物理含义表征为经过电制动力序列 $U(u_0, u_1, \dots, u_{n-1})$ 做功后, 从当前状态 $X(s_i, v_i)$ 转移到最佳缓解点位置 s_n 处的速度 v_n 与最佳缓解点速度 v_{opt} 的差异, 计算公式如式(30)。

$$h^*(U) = \left| \sqrt{2 \left(\frac{1}{2} m v_0^2 + \sum_0^{n-1} (u_i + f_{\text{ramp}, i} + f_{\text{curve}, i} + f_{\text{basic}, i} + f_{\text{air}, i}) \right) \Delta s} \right| - v_{\text{opt}} \quad (30)$$

在A*算法的迭代过程中, 计算有限集中每个电制

动力序列的启发函数 $f^*(U)$, 选择使启发函数 $f^*(U)$ 最小的电制动力序列 $U(\hat{u}_0, \hat{u}_1, \dots, \hat{u}_{i-1})$ 。

2.3.2 状态转移与更新

判断当前状态 $x_i(s_i, v_i)$ 中的 i 是否为 $n-1$ 。若 i 小于 $n-1$, 选择使启发函数 $f^*(U)$ 最小的电制动力序列 $U(\hat{u}_0, \hat{u}_1, \dots, \hat{u}_{n-1})$ 中的 $\hat{u}_i$ 为当前状态采用的电制动力, 替代初始电制动力序列中的 u_i , 从 $x_i(s_i, v_i)$ 前进到 $x_{i+1}(s_{i+1}, v_{i+1})$, 初始电制动力序列由 $U(\hat{u}_0, \hat{u}_1, \dots, \hat{u}_{i-1}, u_i, u_{i+1}, \dots, u_{n-1})$ 迭代为 $U(\hat{u}_0, \hat{u}_1, \dots, \hat{u}_{i-1}, \hat{u}_i, u_{i+1}, \dots, u_{n-1})$, 重复2.2.2节中的非线性有限集序列生成步骤。

若 i 等于 $n-1$, 判断在电制动力序列 $U(\hat{u}_0, \hat{u}_1, \dots, \hat{u}_{i-1})$ 作用下, 从 $x_{n-1}(s_{n-1}, v_{n-1})$ 转移到 $x_n(s_n, v_n)$, 末速度 v_n 是否满足缓解的速度约束($v_{\min} \leq v_n \leq v_{\max}$), 若满足, 则进入步骤4; 若不满足, 则需要进行下一轮迭代过程。当前状态调整为 $x_0(s_0, v_0)$, 计算在电制动力序列 $U(\hat{u}_0, \hat{u}_1, \dots, \hat{u}_{i-1})$ 下的启发函数 $f^*(U)$, 对 $g^*(U)$ 进行迭代, 见式(31)。

$$g^*(U) = g^*(U) + f^*(U) \quad (31)$$

初始的电制动力序列设置为 $U(\hat{u}_0, \hat{u}_1, \dots, \hat{u}_{i-1})$, 重复2.2.2节中的非线性有限集序列生成步骤。

2.3.3 迭代终止条件判断

已知初始状态 $x_0(s_0, v_0)$, 经过A*算法迭代得到最优电制动力序列 $U(\hat{u}_0, \hat{u}_1, \dots, \hat{u}_{i-1})$ 。当前状态设置为 $x_0(s_0, v_0)$, 参考2.3.1节生成基于最优电制动力序列 $U(\hat{u}_0, \hat{u}_1, \dots, \hat{u}_{i-1})$ 的有限集 Ω , 求解有限集中所有电制动力序列所对应的状态序列及平稳性目标函数值 J , 若基于最优电制动力序列的平稳性目标函数值最小, 则求得的最优电制动力序列 $U(\hat{u}_0, \hat{u}_1, \dots, \hat{u}_{i-1})$ 为最优序列; 若不是最小, 当前状态设置为 $x_0(s_0, v_0)$, 初始电制动力序列设置为使平稳性目标函数值最小的电制动力序列, 重复2.3.1~2.3.3节中的步骤。

3 仿真验证

3.1 仿真条件设计

为了验证文章所提出的基于启发式双端优化控制器控制的空电协同控制的有效性, 本文采集大秦铁路涿鹿到茶坞区间的长大下坡道K148+000—K153+000段线路数据进行仿真分析。在仿真中, 将基于启发式双端优化控制器控制的空电协同控制(FSMP-ACS)的结果与恒速控制器(CFC)的结果进行对比。文章主要分析循环空气制动的调速闸, 不考虑停车闸和车辆静态状态下施加的闸。采集的大秦铁路数据中, 编组形式为1+1编组, 货车数为210辆, 总重21 000 t。

3.2 仿真结果分析

大秦铁路仿真测试结果如图5~图8所示。图5为运行速度曲线展示。经过16次迭代后, FSMP-ACS实现

了从起始点到终点的平滑速度曲线规划。同样, CFC也能通过平均力实现从起始点到终点的速度曲线规划。图6为运行电制动力的调节过程曲线。经过16次迭代后, FSMP-ACS的电制动力调节过程能够满足复杂的控制约束。图7为平稳性指标结果。经过FSMP-ACS的不断迭代, 平稳性指标达到最优值, CFC的平稳性指标始终维持在一个值, 并劣于FSMP-ACS迭代后的平稳性指标。




图5 速度调节曲线

Fig. 5 Speed regulation curve




图6 电制动力调节曲线

Fig. 6 Electric braking force regulation curve




图7 平稳性目标函数值曲线

Fig. 7 Stability objective function value curve




图8 末速度与缓解速度差值曲线

Fig. 8 Curve of difference between final speed and speed upon release

4 结论与展望

针对重载列车在长大下坡道的空电协同控制这一种带非线性约束的最优控制问题, 本文提出基于启发式双端优化的重载列车空电协同控制策略。该策略提炼出空电协同的非线性状态约束、控制约束和终端约束, 采用神经网络对非线性时延大的空气制动模型参数进行离线辨识, 进行梯度寻优得到有限集序列, 并对有限集序列设计 A* 算法实现迭代寻优。仿真结果验证所提出的基于启发式双端优化的重载列车空电协同控制策略能够实时获取准确的非线性空气制动力, 将空电协同中的多类、非线性、时变的状态约束和控制约束转化为合适的求解目标, 解决包含终端约束的预测优化问题, 最后得到最优平稳性下的空电协同控制序列。

参考文献:

- [1] 丁莉芬. 重载列车纵向动力学建模研究[D]. 北京: 北京交通大学, 2012.
DING Lifan. Study on modelling the longitudinal dynamics of heavy haul train[D]. Beijing: Beijing Jiaotong University, 2012.
- [2] 孙树磊, 丁军君, 周张义, 等. 重载列车纵向冲动动力学分析及试验研究[J]. 机械工程学报, 2017, 53(8): 138-146.
SUN Shulei, DING Junjun, ZHOU Zhangyi, et al. Analysis and test of heavy haul train longitudinal impulse dynamics [J]. Journal of mechanical engineering, 2017, 53(8): 138-146.
- [3] LIU Wentao, SU Shuai, TANG Tao, 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.
- [4] PIECHOWIAK T. Verification of pneumatic railway brake models[J]. Vehicle system dynamics, 2010, 48(3): 283-299.
- [5] COLE C, SUN Y Q. Simulated comparisons of wagon coupler systems in heavy haul trains[J]. Proceedings of the institution of mechanical engineers, part F: journal of rail and rapid transit, 2006, 220(3): 247-256.
- [6] 孙翔, 翟婉明. 重载列车动力学研究成果及其应用[J]. 中国铁路, 1993(4): 10-12.
SUN Xiang, ZHAI Wanming. Results and application of dynamics research of heavy haul trains[J]. Chinese railways, 1993(4): 10-12.
- [7] 池茂儒, 蒋益平, 张卫华, 等. 长大重载列车系统动力学[J]. 交通运输工程学报, 2011, 11(3): 34-40.
CHI Maoru, JIANG Yiping, ZHANG Weihua, et al. System dynamics of long and heavy haul train[J]. Journal of traffic and transportation engineering, 2011, 11(3): 34-40.
- [8] 耿志修, 李学峰, 张波. 大秦线重载列车运行仿真计算研究[J]. 中国铁道科学, 2008(2): 88-93.
GENG Zhixiu, LI Xuefeng, ZHANG Bo. Simulation study of heavy haul train operation on Datong-Qinhuangdao railway[J]. China railway science, 2008(2): 88-93.
- [9] 常崇义, 王成国, 马大伟, 等. 2万t组合列车纵向力计算研究[J]. 铁道学报, 2006(2): 89-94.
CHANG Chongyi, WANG Chengguo, MA Dawei, et al. Study on numerical analysis of longitudinal forces of the 20 000 t heavy haul[J]. Journal of the China railway society, 2006(2): 89-94.
- [10] WEI Wei, HU Yang, WU Qing, et al. An air brake model for longitudinal train dynamics studies[J]. Vehicle system dynamics, 2017, 55(4): 517-533.
- [11] 马志强, 王竣渝, 魏咪, 等. 重载列车平稳运行的空电联合制动匹配控制[J]. 机车电传动, 2023(4): 71-76.
MA Zhiqiang, WANG Junyu, WEI Mi, et al. Combined electro-pneumatic braking matching control for smooth operation of the heavy-haul train[J]. Electric drive for locomotives, 2023(4): 71-76.
- [12] 王悉. 基于机器学习的重载列车智能驾驶方法研究[D]. 北京: 北京交通大学, 2017.
WANG Xi. Machine learning based intelligent operation methods for heavy haul train[D]. Beijing: Beijing Jiaotong University, 2017.
- [13] 马大伟. 关于大秦线重载列车下坡道安全运行和纵向力问题[J]. 铁道车辆, 2005, 43(1): 1-4.
MA Dawei. The running safety and longitudinal force of heavy haul trains on downhill slope of Daqin line[J]. Rolling stock, 2005, 43(1): 1-4.
- [14] 马大伟, 王成国, 张波. 我国重载列车制动技术的研究[J]. 铁道车辆, 2009, 47(5): 8-11.
MA Dawei, WANG Chengguo, ZHANG Bo. Research on braking technology for heavy haul trains in our country[J]. Rolling stock, 2009, 47(5): 8-11.
- [15] 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 Yating, YUAN Junrong, LI Zhongqi, et al. Optimization of heavy haul train operation process based on coupler constraints[J]. Acta automatica sinica, 2019, 45(12): 2355-2365.
- [16] 张中央. 列车牵引计算[M]. 北京: 中国铁道出版社, 2006.
ZHANG Zhongyang. Train traction calculation[M]. Beijing: China Railway Publishing House, 2006.
- [17] DU Guanglong, LIANG Yinhao, GAO Boyu, et al. A cognitive joint angle compensation system based on self-feedback fuzzy neural network with incremental learning[J]. IEEE transactions on industrial informatics, 2021, 17(4): 2928-2937.
- [18] 史可, 张征方, 白金磊, 等. 基于模糊神经网络的重载列车空气制动力预测方法[J]. 控制与信息技术, 2022(1): 1-6.
SHI Ke, ZHANG Zhengfang, BAI Jinlei, et al. Prediction method of air braking force of heavy load train based on fuzzy logic-based neural network[J]. Control and information technology, 2022(1): 1-6.

Research on the pneumatic-electric braking collaborative control strategy for heavy-haul trains based on heuristic dual-end optimization

ZHANG Zhengfang, SHI Ke, LIU Haitao, WANG Yue, FENG Ling

(Zhuzhou CRRC Times Electric Co., Ltd., Zhuzhou, Hunan 412001, China)

Abstract: The pneumatic-electric braking operation of heavy-haul trains on long and steep downgrade sections is fundamentally an optimal control problem, involving nonlinear state constraints, control constraints, and long-distance end constraints. Traditional collaborative control strategies for pneumatic-electric braking often struggle to simultaneously address these constraints, making it difficult to ensure the safety and stability of heavy-haul trains during the pneumatic-electric braking coordinative control process. To tackle this issue, this paper proposes a pneumatic-electric braking collaborative control strategy for heavy-haul trains based on heuristic dual-end optimization. Firstly, the dynamic characteristics of heavy-haul trains were analyzed, leading to the extraction of nonlinear state constraints, control constraints, and end constraints in the pneumatic-electric braking coordinative control process. Next, a gradient search was performed focusing on the stability objective within the nonlinear state constraints and control constraints, which resulted in the formation of a finite set sequence based on the position domain. At the same time, a neural network was designed to identify parameters for a nonlinear pneumatic braking model, thereby yielding predicted pneumatic braking forces. Subsequently, an A * algorithm was developed for iterative refinement within the finite set sequence, collaborative control sequence that satisfies the end constraints. Finally, the effectiveness of the proposed pneumatic-electric collaborative control strategy for heavy-haul trains was verified through a semi-physical simulation platform.

Keywords: heavy-haul train; long and steep downgrade section; longitudinal dynamics; pneumatic-electric braking coordinative control; nonlinear finite set; heuristic dual-end optimization; heavy-haul railway