

DOI:10.19651/j.cnki.emt.2211001

# 考虑坡度工况的 FCHEV 队列分层优化控制策略研究\*

朱兰馨 聂枝根

(昆明理工大学 昆明 650500)

**摘要:** 在面对坡度工况时,如何开发同时兼顾车辆间协同控制与能耗经济性的控制策略是提高交通效率与发挥车辆节能潜力的关键技术之一。以燃料电池混合动力汽车队列为研究对象,以安全行驶及优化能耗为目标,提出了一种基于改进粒子群优化算法与 Q 学习的燃料电池混合动力汽车队列分层优化控制策略。该策略中上层控制器在保证满足与前车距离或速度限制等安全约束的前提下,利用改进的粒子群优化算法获取节能速度轨迹,并使用模型预测控制框架实时调整主车速度遵循节能速度轨迹行驶。下层控制器根据上层求解的车速和需求功率等信息建立 Q 学习控制器,实现燃料电池混合动力汽车动力电池与燃料电池之间的最优能量分配。仿真结果表明,本文所提出的分层控制策略在坡度工况下,表现出良好的跟踪性能和安全性能,且优化结果与动态规划策略相似,表明该策略的能耗经济性及可行性。

**关键词:** 燃料电池混合动力汽车;分层控制;模型预测控制;粒子群算法;Q 学习

中图分类号: U469.72 文献标识码: A 国家标准学科分类代码: 510.80

## Hierarchical optimal control strategy for FCHEV queue considering gradient operation condition

Zhu Lanxin Nie Zhigen

(Kunming University of Science and Technology, Kunming 650500, China)

**Abstract:** In the face of gradient operation conditions, the development of control strategies that simultaneously take into account inter-vehicle cooperative control and energy economy is one of the key technologies for improving traffic efficiency and exploiting the energy-saving potential of vehicles. A hierarchical optimization control strategy based on improved particle swarm optimization algorithm and Q-learning for fuel cell hybrid electric vehicles queue is proposed with the objective of safe driving and optimizing energy consumption. In this strategy, the upper layer controller uses the improved particle swarm optimization algorithm to obtain the energy-saving speed trajectory under the premise of ensuring that safety constraints such as distance or speed limit from the preceding vehicle are satisfied, and utilizes the model predictive control framework to adjust the vehicle speed in real time to ensure the vehicle follows the energy-saving speed trajectory. The lower layer controller builds the Q-learning controller based on the information such as vehicle speed and demand power solved by the upper layer to realize the optimal energy distribution between the fuel cell hybrid electric vehicles power cell and the fuel cell. Simulation results show that the hierarchical control strategy proposed in this paper exhibits good tracking performance and safety performance under slope conditions, and the optimization results are similar to the dynamic planning strategy, indicating the energy consumption economy and feasibility of the strategy.

**Keywords:** fuel cell hybrid electric vehicles; hierarchical control; model predictive control; particle swarm optimization; Q-learning

## 0 引言

如今,电子化、互联化、智能化已成为汽车发展的主流。

汽车通过借助先进的驾驶辅助系统(advanced driver assistance system, ADAS)可以实现互联及自动驾驶<sup>[1-2]</sup>。ADAS 中的自适应巡航控制(adaptive cruise control, ACC)

收稿日期:2022-08-08

\*基金项目:2021 年云南省科技计划项目(202101AT070108)、2021 年昆明理工大学课程思政内涵式建设项目(201KS034)资助

系统可确保目标车辆根据前方车况实时调整速度,其发展初期核心在于实现车辆的安全跟随<sup>[3]</sup>。Cui 等<sup>[4]</sup>搭建了考虑车辆状态的多约束模型预测控制(model predictive control, MPC)速度控制器,从而提高高速工况下车辆跟踪安全性及稳定性,所提出的控制器可实现智能车辆的高速路径跟踪。为确保 ACC 系统的实时性,Huang 等<sup>[5]</sup>利用粒子群优化(particle swarm optimization, PSO)算法求解 MPC 滚动优化过程中的多约束二次规划问题,相较于 MPC 策略,提高模型求解速度同时平均绝对误差降低 77.8%。随着 ACC 系统的完善,当前的主要研究目标为实现车速规划的同时提升能耗经济性。王雪彤等<sup>[6]</sup>设计了分布式非线性 MPC 控制器,实现了异质队列车辆安全性、稳定性、燃油经济性的多目标优化,与 PID 定速巡航策略相比,能耗降低 5.3%。

然而,上述控制模型均为单一能源汽车,针对混合动力汽车队列,其纵向控制系统相比于单一能源汽车队列更加复杂,既要考虑队列的跟踪效果,又需涉及能量管理系统(energy management system, EMS)。分层控制框架独特的单向信息传递方式有效降低了该类型汽车队列控制系统的复杂度<sup>[7-9]</sup>。对于分层控制框架,合适的下层 EMS 控制器对提升其控制效果尤为重要。目前主流的 EMS 控制策略有两类<sup>[10-11]</sup>:基于规则和基于优化的策略。基于规则的控制策略依赖专家经验调节参数,难以实现实时及全局最优<sup>[12]</sup>。基于优化的策略分为全局优化和瞬时优化,其中全局优化策略以动态规划(dynamic programming, DP)为代表,DP 需提前获取工况信息,才能利用全局最优化理论分配不同能源间的输出功率<sup>[13]</sup>。瞬时最优策略的典型算法为等效燃油消耗最小策略(equivalent consumption minimization strategy, ECMS)和模型预测控制,工况依赖性低,计算量小,缺点是无法保证结果最优<sup>[14]</sup>。近年来,学者们开发了基于强化学习(reinforcement learning, RL)算法的 EMS,该 EMS 具备较好的实时性和最优性。杨宁康等<sup>[15]</sup>开发了基于 RL 的效率最优 EMS,与基于规则的策略相比,在降低能耗的同时确保电池荷电状态在维持阶段仅小范围波动。尹燕莉等<sup>[16]</sup>开发了基于 Q 学习(Q-learning, QL)的混合动力汽车队列的 EMS,该策略与 DP 相比,百公里油耗降低 2.57%。

以上研究在实现安全驾驶和降低能耗等方面均取得了突出成果,但少有文章着眼于坡度工况下的混合动力汽车队列分层策略研究。综上所述,本文提出了一种分层控制策略,用于实现队列车辆车速、能耗的协同优化。该策略上层利用改进的 PSO 算法求解节能速度轨迹,MPC 用于实时调整车速,使车辆遵循节能速度轨迹行驶,从而确保上层控制器表现出较好的实时性和最优性。下层 EMS 控制器根据上层传递的车速、需求功率等信息,利用 QL 策略实现燃料电池混合动力汽车(fuel cell hybrid electric vehicles, FCHEV)的燃料电池与动力电池之间的最优能量分配。最

后,仿真验证所提出分层控制策略的有效性。

## 1 燃料电池汽车动力系统建模

### 1.1 车辆模型

本文研究对象为基于磷酸铁锂(LiFePO<sub>4</sub>)电池组与燃料电池 2 个动力源系统的 FCHEV,其动力系统结构如图 1 所示。LiFePO<sub>4</sub> 电池组和燃料电池均用于产生电机运转所需的电能。整车具体参数如表 1 所示。

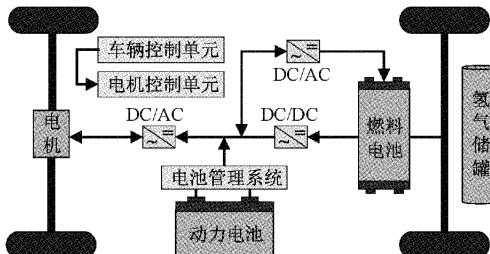


图 1 动力系统结构

表 1 整车参数

车辆参数	数值
整备质量/kg	2 200
轴距/m	1.551 9
滚动半径/m	0.317 3
迎风面积/m <sup>2</sup>	2.372
主减速比	4.44
传动效率	0.98
动力电池容量/(A·h)	54
燃料电池最大功率/kW	70
驱动电机功率/kW	40

车辆需求功率  $P_d$  计算公式为:

$$P_d = (F_f + F_w + F_i + F_j)v_d \quad (1)$$

式中: $F_f$ 、 $F_w$ 、 $F_i$ 、 $F_j$  分别为车辆行驶过程中的滚动阻力、空气阻力、坡度阻力和加速阻力; $v_d$  为速度。考虑到各零部件的传递效率,车辆在运行过程中,实际的需求功率  $P_{req}$  可表示为:

$$\begin{cases} P_{req} = P_d / \eta_d \\ \eta_d = \eta_1 \eta_2 \eta_3 \end{cases} \quad (2)$$

式中: $\eta_d$  为整车的驱动效率; $\eta_1$  为机械效率传动系统效率; $\eta_2$  为 DC/AC 变换器效率; $\eta_3$  为电机效率。

### 1.2 锂电池组模型

本文采用一阶 RC 等效电路模型模拟电池组,具体组成如图 2 所示,图中  $i_{bat}$  为电流; $u_0$  为开路电压; $C_c$  和  $R_c$  分别为极化电容和极化电阻; $u_{bat}$  为端电压。

$i_{bat}$  可表示为:

$$i_{bat} = \frac{u_0 - R_s i_{bat} - u_{bat}}{R_c} + C_c \frac{d}{d_t} (u_0 - R_s i_{bat} - u_{bat}) \quad (3)$$

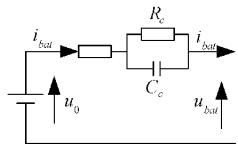
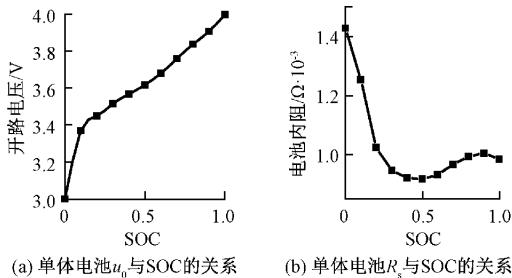


图2 锂电池结构模型

式中: $R_s$ 为欧姆内阻。电池 $t$ 时刻的荷电状态(state of charge,SOC)可由初始荷电 $S_{SOC(0)}$ 估算,电池容量 $Q_{bat}$ 、电池功率 $P_{bat}$ 和 $i_{bat}$ 遵循以下关系:

$$\begin{cases} S_{SOC(t)} = S_{SOC(0)} - \frac{100}{3600Q_{bat}} \int i_{bat} dt \\ P_{bat} = u_{bat} i_{bat} \end{cases} \quad (4)$$

基于 $S_{SOC(t)}$ ,通过插值可得到 $u_0$ 和 $R_s$ ,插值所使用的数据集如图3所示。

图3 单体电池 $u_0$ 、 $R_s$ 与SOC的关系曲线

### 1.3 电机模型

基于电机转速和转矩,电机效率表示为:

$$\eta_m = g(\omega_m, T_e), T_{e\_min} \leqslant T_e \leqslant T_{e\_max} \quad (5)$$

式中: $\omega_m$ 、 $T_e$ 为电机转速、转矩;  $\eta_m$ 为电机效率; $T_{e\_max}$ 、 $T_{e\_min}$ 分别为电机输出的最大、最小转矩。电机的效率MAP如图4所示。

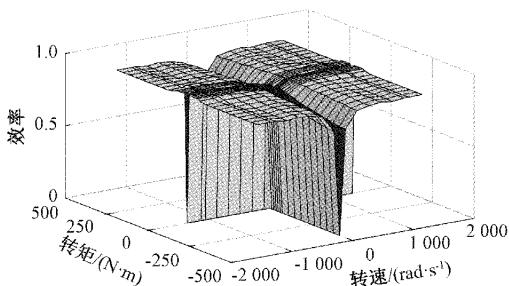


图4 电机效率MAP

### 1.4 燃料电池模型

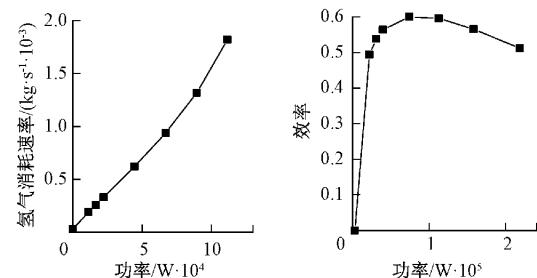
燃料电池氢气消耗速率 $m_{H2}$ 、输出功率 $P_{fc}$ 、效率 $\eta_{fc}$ 间的关系为:

$$m_{H2} = \frac{P_{fc}}{\eta_{fc} D_{H2}} \quad (6)$$

式中: $D_{H2}$ 为氢气低热值,燃料电池系统 $P_{fc}$ - $m_{H2}$ 曲线、 $P_{fc}$ - $\eta_{fc}$ 曲线如图5所示。燃料电池产生的能量经DC/DC变换器输出,即:

$$P_{DC/DC} = \eta_4 P_{fc} \quad (7)$$

式中: $P_{DC/DC}$ 为DC/DC变换器输出功率, $\eta_4$ 为DC/DC变换器效率。

图5 燃料电池 $P_{fc}$ 与 $m_{H2}$ 、 $\eta_{fc}$ 的关系曲线

FCHEV混合驱动模式下,由燃料电池和动力电池共同驱动,其燃料电池功率 $P_{fc}$ 和蓄电池功率 $P_{bat}$ 之间的分配关系如下:

$$P_{req} = P_{fc} + P_{bat} \quad (8)$$

### 2 多目标优化分层控制器模型

本文所提出的多目标优化分层控制器原理如图6所示。上层通过车间通信,获取前后车速度、位置等信息,基于改进的PSO算法获取节能速度轨迹,从而使用MPC实时调整主车遵循节能速度行驶并将速度传递到下层控制器。下层控制器基于上层传递的最优车速获取此时需求功率,并带入Q学习控制器中,实现FCHEV动力电池与燃料电池之间的最优能量分配,同时将此刻的车辆行驶距离等运动状态传递到上层控制器。

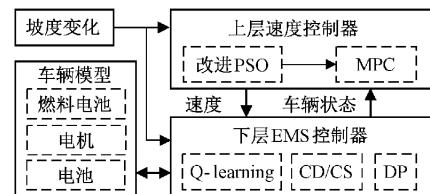


图6 分层控制框图

#### 2.1 多目标上层控制算法

##### 1) 基于MPC的速度控制器建模

本文研究对象为3辆相同参数车辆组成的队列,其模型如图7所示,图中目标车辆与其前车的车距误差 $e_x$ 为:

$$e_x = d + d_0 - d_{des} \quad (9)$$

式中: $d$ 为相对距离; $d_0$ 为两车间最小安全距离; $d_{des}$ 为目标车辆与其前车间的期望车距。本文采用可变车头时距策略, $d_{des}$ 如式(10)所示。

$$d_{des} = d_0 + hv \quad (10)$$

式中: $h$ 为时间常数; $v$ 为目标车辆车速; $a$ 为加速度。目标车辆与前车速度误差 $e_v$ 如式(11)所示。

$$e_v = v_t - v \quad (11)$$

式中: $v_t$ 表示目标车辆的前车车速。队列车辆的状态变量



图 7 队列纵向控制图

$\mathbf{x} = [e_x \ e_v \ a \ v]^T$ , 控制变量  $u$  为期望加速度  $a_{des}$ , 其纵向运动学状态空间模型如式(12)所示。

$$\dot{\mathbf{x}}(t) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}_1 u(t) + \mathbf{B}_2 \omega(t) \quad (12)$$

$$\text{式中: } \mathbf{A} = \begin{bmatrix} 0 & 1 & -h & 0 \\ 0 & 0 & -1 & 0 \\ 0 & 0 & -\frac{1}{\tau} & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}; \quad \mathbf{B}_1 = \begin{bmatrix} 0 \\ 0 \\ \frac{1}{\tau} \\ 0 \end{bmatrix}; \quad \mathbf{B}_2 = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix};$$

$\omega$  为干扰输入, 即目标车辆加速度  $a_t$ ;  $\tau$  为时间常数。MPC 目标函数  $G(t)$  计算公式如式(13)所示。

$$G(t) = w_1(e_x(t))^2 + w_2(e_v(t))^2 \quad (13)$$

式中:  $w_1$ 、 $w_2$  分别为车距误差、车速误差的权重, 系统需保证  $t$  时刻当  $e_x$  趋近于 0 时,  $e_v$  和后车加速度为 0。 $t$  时刻速度控制器还应满足式(14)约束。

$$\left\{ \begin{array}{l} e_{x,\min} \leqslant e_{x(t)} \leqslant e_{x,\max} \\ e_{v,\min} \leqslant e_{v(t)} \leqslant e_{v,\max} \\ a_{\min} \leqslant a_{(t)} \leqslant a_{\max} \\ v_{\min} \leqslant v_{(t)} \leqslant v_{\max} \end{array} \right. \quad (14)$$

式中:  $e_{x,\min}$ 、 $e_{x,\max}$  分别为前后车最小、最大车距误差;  $e_{v,\min}$ 、 $e_{v,\max}$  分别为前后车最小、最大速度误差;  $a_{\min}$ 、 $a_{\max}$  分别为乘客舒适范围内的最大减速度、最大加速度;  $v_{\min}$ 、 $v_{\max}$  表示期望的最小、最大速度。

## 2) 基于改进 PSO 算法的最优车速求解

基于 GPS 信号, 车辆行驶至某一特定路段前可获取具体道路信息。此时通过选取合适的适应度函数, 利用 PSO 算法寻优特性, 在车辆运行至该路段前即可获取最高速度轨迹。同时, 为解决 PSO 算法在寻优过程中会出现的局部最优以及聚类现象, 本文引入两种修改机制<sup>[17]</sup>: 蒸发机制和多样性机制。基于两种机制所得到的优化后的 PSO 算法更新方程为:

$$\left\{ \begin{array}{l} v_j(i+1) = \lambda[v_j(k) + \frac{f}{2}c_p \epsilon(x_{j\_pbest} - x_j(i)) + \\ \frac{f}{2}c_g \epsilon(x_{j\_gbest} - x_j(i))] \\ x_j(i+1) = x_j(i) + v_j(i+1) \end{array} \right. \quad (15)$$

式中:  $i$  为迭代次数;  $j$  为粒子编号;  $v_j$  和  $x_j$  为第  $j$  个粒子的速度和位置;  $x_{j\_pbest}$  和  $x_{j\_gbest}$  分别为个体最优、群体最优时粒子位置。 $\epsilon$  用来判断粒子群是否需要多样性机制;  $f=4.01$ ;  $c_p$  和  $c_g$  为介于 0~1 间的随机数,  $\lambda$  为压缩率, 可表示为式(16)。

$$\lambda = \frac{2}{|2-f-\sqrt{f^2-4f}|} \quad (16)$$

蒸发机制用于保证每个粒子最优解的及时更新, 即:

$$W_j(i+1) = \begin{cases} CW_j(i), & \text{s. t. } TW_j(i) \leqslant H(x_j(i+1)) \\ H(x_j(i+1)), & \text{s. t. } TW_j(i) > H(x_j(i+1)) \end{cases} \quad (17)$$

其中,  $W$  表示迭代过程中全局最优值;  $C$  为蒸发常数,  $C>1$ ;  $H(x_j(i+1))$  为当前适应度值;  $H$  表示为式(18)。

$$H(x_j(i)) = \omega_3 c_h(i) + \omega_4 d_{des}(i) \quad (18)$$

式中:  $\omega_3$ 、 $\omega_4$  为权重函数;  $c_h(i)$  表示  $i$  次迭代的氢耗;  $d_{des}(i)$  表示  $i$  次迭代时的车距。粒子的变化规律如式(19)。

$$x_{j\_pbest} = \begin{cases} x_{j\_pbest} & \text{s. t. } TW_j(i) \leqslant H(x_j(i)) \\ x_j(i+1) & \text{s. t. } TW_j(i) > H(x_j(i)) \end{cases} \quad (19)$$

蒸发常数  $C$  的选取原理如下:

$$C = \begin{cases} C_1, & \text{s. t. } H \geqslant (1+\lambda)H_{op}(j), H \leqslant (1-\lambda)H_{op}(j) \\ C_2, & \text{s. t. } (1-\lambda)H_{op}(j) < H < (1+\lambda)H_{op}(j) \end{cases} \quad (20)$$

式中:  $H_{op}(j)$  为第  $j$  个粒子历史最优适应度值。

对于多样性机制, 本文设置了多样性阈值  $D_d$ , 当多样性  $D_d$  达到阈值  $D_l$  以下时,  $\epsilon=-1$ , 粒子群为排斥模式; 当  $D_d>D_l$  时,  $\epsilon=1$ , 粒子群收缩, 直到多样性减小到  $D_l$ 。多样性机制参数定义为:

$$\epsilon = \begin{cases} 1, & \text{s. t. } \epsilon < 0 \& D_d > D_l \\ -1, & \text{s. t. } \epsilon > 0 \& D_d < D_l \end{cases} \quad (21)$$

$$D_d = \frac{x_{\max(i)} - x_{\min(i)}}{2} \quad (22)$$

式中:  $x_{\max(i)}$ 、 $x_{\min(i)}$  表示第  $i$  次迭代粒子达到的最远和最近的位置。

## 2.2 基于 Q 学习的下层能量管理策略

本文构建的 EMS 策略目标函数  $J$  可定义为:

$$J = \min F_{total} = \min \int_0^T F_{rate} dt \quad (23)$$

式中:  $F_{total}$  是整个工况的总能量消耗,  $F_{rate}$  是瞬时能耗,  $T$  是整个工况时间。在已知车辆速度  $v(t)$  和总需求功率  $P_{req}(t)$  的前提下, 只需确定电池输出功率  $P_{bat}(t)$ , 就具备合理分配车辆驱动系统能量的可能。因此式(23)可定义为:

$$J[U(t), X(t), t] = \min \int_0^T F_{rate}[U(t), X(t)] dt \quad (24)$$

式中: 控制变量  $U(t)=P_{bat}(t)$ ; 状态变量  $X(t)$  为总需求功率, 车速和荷电状态, 即  $X(t)=[P_{req}(t) \ v(t) \ SOC(t)]$ 。 $t$  时刻控制器的约束条件为式(25)。

$$\left\{ \begin{array}{l} P_{bat\_min} \leqslant P_{bat(t)} \leqslant P_{bat\_max} \\ P_{mot\_min} \leqslant P_{mot(t)} \leqslant P_{mot\_max} \\ P_{fc\_min} \leqslant P_{fc(t)} \leqslant P_{fc\_max} \\ P_{req\_min} \leqslant P_{req(t)} \leqslant P_{req\_max} \\ S_{SOC\_min} \leqslant S_{SOC(t)} \leqslant S_{SOC\_max} \end{array} \right. \quad (25)$$

式中:  $P_{mot}$  为电机功率;  $P_{bat\_max}$ 、 $P_{bat\_min}$  分别为  $P_{bat}$  的最大、

最小值;  $P_{mot\_max}$ 、 $P_{mot\_min}$  分别为  $P_{mot}$  的最大、最小值;  $P_{fc\_max}$ 、 $P_{fc\_min}$  分别为  $P_{fc}$  的最大、最小值;  $P_{req\_max}$ 、 $P_{req\_min}$  分别为  $P_{req}$  的最大、最小值;  $S_{SOC\_min}$ 、 $S_{SOC\_max}$  分别为  $S_{SOC}$  的最大、最小值。

基于 Q-learning 的 EMS 策略结构如图 8 所示,具体分为  $\{S, A, \{P\}, \phi, R\}$ ,其中  $S$  为状态集,  $A$  为控制变量,  $\{P\}$  为状态  $s$  下采用动作  $a$  的状态转移概率分布集,  $\phi$  为折扣率,  $R$  为奖励信息,  $r$  为瞬时奖励。

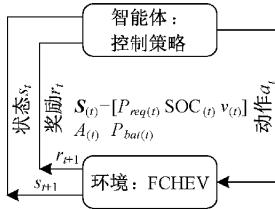


图 8 强化学习结构

$t$  时刻的  $s, a, r$  可表示为:

$$\begin{cases} s_t \in S = \{P_{req(t)}, v(t), SOC(t)\} \\ a_t \in A = \{P_{bat(t)} \mid P_{bat\_min} \leq P_{bat(t)} \leq P_{bat\_max}\} \\ r_t \in R = \{-m_{H_2}(s_t, a_t)\} \end{cases} \quad (26)$$

对于每一个状态  $s$ , 值函数  $Z_\pi$  为累积折扣回报:

$$Z_\pi(s) = E(\sum_{t=0}^T \phi r_t) \quad (27)$$

式中:  $\pi$  为策略;  $E$  为累积奖励反馈量,  $Z_\pi$  满足贝尔曼方程如式(28)所示。

$$Z_\pi(s, a) = r(s, a) + \phi \sum_{s' \in S} P_{s \rightarrow s'}^a Z_\pi(s', a') \quad (28)$$

式中:  $s'$ 、 $a'$  分别为状态  $s$  执行动作  $a$  后的下一个可能状态及动作;  $P_{s \rightarrow s'}^a$  表示状态  $s$  执行动作  $a$  后到下一个状态  $s'$  的概率, 对应最优价值函数  $Z_\pi^*$  为式(29)。

$$Z_\pi^*(s) = \max_{a \in \pi} E(\sum_{t=0}^T \phi r_t) \quad (29)$$

其贝尔曼方程形式为:

$$Z_\pi^*(s) = \max_{a \in \pi} r(s, a) + \phi \sum_{s' \in S} P_{s \rightarrow s'}^a Z_\pi^*(s') \quad (30)$$

在 Q-learning 算法中, 对应于  $s, a$  的 Q 值为:

$$Q_\pi(s, a) = r(s, a) + \phi \sum_{s' \in S} P_{s \rightarrow s'}^a Q_\pi(s', a') \quad (31)$$

则最优 Q 函数可表示为:

$$Q_\pi^*(s, a) = r(s, a) + \phi \sum_{s' \in S} P_{s \rightarrow s'}^a \max_{a'} Q_\pi^*(s', a') \quad (32)$$

强化学习算法中 Q 值的迭代更新规则可以表示为:

$$Q_\pi(s, a) = Q_\pi(s, a) + \delta(r + \phi \max_a Q_\pi(s', a) - Q_\pi(s, a)) \quad (33)$$

式中:  $\delta$  是学习效率,  $\delta \in [0, 1]$ 。Q 和 Z 的关系为式(34)。

$$\begin{cases} Z_\pi^*(s) = \max_{a \in A} Q_\pi(s, a) \\ Q_\pi(s, a) = r(s, a) + \phi \sum_{s' \in S} P_{s \rightarrow s'}^a Z_\pi^*(s') \end{cases} \quad (34)$$

求解  $s-a$  的计算流程如算法 1 所示。

### 算法 1 Q-learning 算法流程

1. 初始化  $Q$  矩阵;
2. 初始化状态  $S$ ;
3. 根据状态  $s$  选择一个动作  $a$  执行;
4. 执行  $a$  动作后观察奖励  $r$  和新的状态  $S'$ ;
5. 根据式(34)更新  $Q$  矩阵;
6. 重复步骤 2~5, 直至循环到最大迭代次数时终止。

求解最优值函数来确定最优控制策略:

$$\pi^*(s) = \operatorname{argmax}_{a \in A} (r(s, a) + \phi \sum_{s' \in S} P_{s \rightarrow s'}^a Z_\pi^*(s')) \quad (35)$$

## 3 策略验证结果分析

### 3.1 上层 MPC 算法跟踪性能验证分析

为验证上层 MPC 速度控制器的跟踪性和鲁棒性, 设定队列车辆运行存在突发干扰的工况。具体为起始时车 2、3 跟随车 1 以可变车头时距策略安全行驶。8 s 时, 车 0 突然变道切入队列所行驶车道, 并位于车 1 前, 此时 MPC 算法基于车-车通信所采集的车 0 速度, 重新规划车 1、2、3 的速度, 从而确保队列安全行驶。8 s 后车 0 存在加速、匀速及加速工况, 车 1、2、3 均能准确跟踪。车辆速度及位移的最终结果如图 9 所示, 由图可知上层基于 MPC 策略所搭建的速度控制器在前车出现干扰车辆时, 领航车即刻调整速度与干扰车辆组成新的队列, 表明所提策略具有鲁棒性。行驶时后方车辆与前车一致保持安全距离, 且自身速度会随前车速度的改变而调整, 整个行驶途中车辆未发生碰撞, 故该策略具备良好的安全性和跟踪性能。

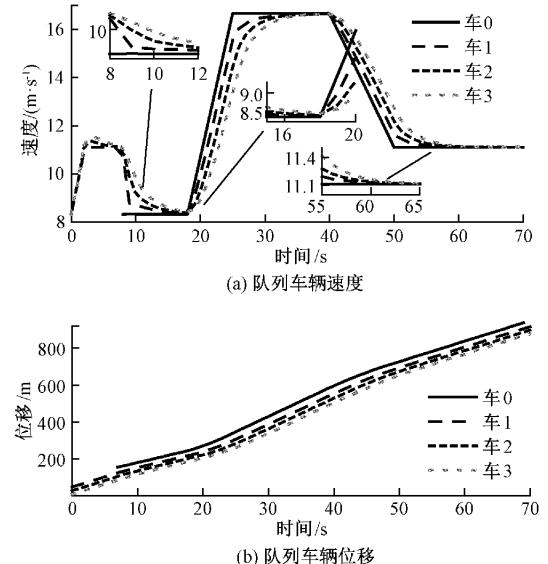


图 9 上层控制器结果图

### 3.2 变坡度工况下的策略验证分析

汽车队列行驶工况 1 设置为变坡度工况, 道路坡度信

息如图 10 所示,在整个周期中,有 4 个上坡路段和 3 个下坡路段,坡度从 0%~5% 不等。

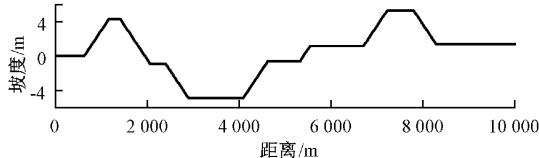


图 10 道路坡度信息

设定该路段速度限制为 0~15 m/s,队列初始速度为 10 m/s。改进的 PSO 算法会根据 GPS 信息及式(18)离线规划节能速度,即当 FCHEV 行驶于水平路段时,以略低于 10 m/s 速度运行。爬坡路段 FCHEV 会在即将到达坡度位置预加速以增加动能。当由上坡路段变化成水平路段时,FCHEV 速度逐渐降低到水平路段最优经济车速。同样,下坡路段车速降低至特定值直到下坡结束。继而,MPC 基于式(13)实时调整主车速度,使车辆遵循节能速度轨迹行驶,车辆行驶速度曲线由图 11(a)所示。由图 11(b)可得,上层速度控制器通过及时调节车辆加速度,实时更改车辆间距,确保队列车辆不发生碰撞。上层以定速行驶为对比量,为确保车辆在相同时间行驶固定的距离,队列车辆定速行驶时的速度分别为 9.651 7、9.639 8、9.639 8 m/s。由图 11(c)可得,相较于定速行驶,队列中 3 辆车以基于改进 PSO 和 MPC 搭建的速度规划策略行驶时,需求功率分别降低 8.26%、8.48%、8.49%。

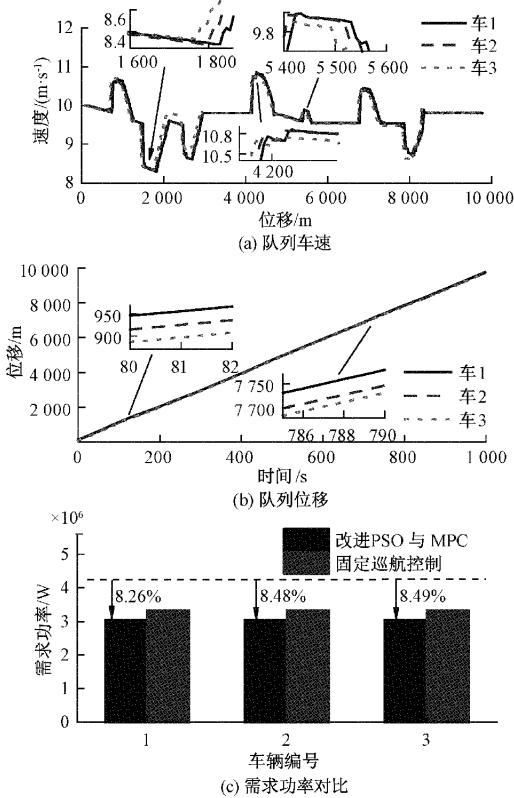


图 11 上层控制器结果图

下层 EMS 采用 DP 策略和 CD/CS 策略作为对比量,图 12 为基于 3 种策略的 SOC 曲线,对比 CD/CS 策略,基于 QL 策略的 SOC 曲线下降的更为缓慢,减少了动力电池大功率放电的动作。基于 QL 策略的 SOC 曲线下降速率在初始阶段略快于 DP 策略,但后续保持一致,由此证明了 QL 策略的有效性。3 种不同策略的氢耗、SOC、燃料电池启停次数如表 2 所示。对比 CD/CS 策略,基于 QL 策略,3 辆车分别节省氢气 7.57%、7.14%、6.88%,证明其节能优势。此外,DP 策略作为全局最优策略,基于 QL 的 EMS 的氢耗与 DP 策略基本相似,同时基于 QL 策略的燃料电池启停次数较 DP 策略少。

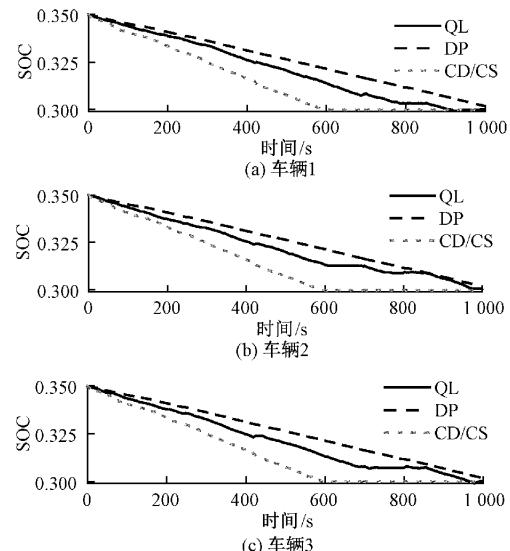


图 12 3 种策略下 SOC 对比

表 2 3 种策略结果对比

车	QL 策略			DP 策略			CD/CS 策略		
	SOC /%	氢耗 /g	启停 次数	SOC /%	氢耗 /g	启停 次数	SOC /%	氢耗 /g	启停 次数
1	30.02	43.32	223	30.18	42.40	310	30.00	46.87	400
2	30.05	43.38	171	30.17	42.54	313	29.99	46.72	400
3	30.03	43.69	185	30.18	42.28	306	29.99	46.92	401

## 4 结 论

本文以 FCHEV 队列为研究对象,设计了综合考虑行车安全性、燃油经济性以及车辆自身限制等条件的分层控制策略。该策略中上层搭建了基于改进 PSO 和 MPC 的速度控制器,下层提出了基于 QL 的能量管理策略。面对坡度工况时,所提出的上层速度控制策略在实现车辆安全行驶的基础上,降低整车需求功率。上层速度规划策略与定速行驶相比,队列车辆的需求功率分别降低了 8.26%、8.48%、8.49%。下层 QL 策略与 CD/CS 策略相比,车辆燃料电池启停次数有所减少,队列车辆的氢耗分别降低了

7.57%、7.14%、6.88%。同时QL策略结果近似于DP策略,由此体现了所提策略的有效性。综上所述,所提出的考虑坡度工况的FCHEV队列分层优化控制策略具有一定的有效性和可行性,可为后续研究提供参考。

## 参考文献

- [1] HINA M D, GUAN H, SOUKANE A, et al. CASA: An alternative smartphone-based ADAS [J]. International Journal of Information Technology & Decision Making, 2022, 21(1): 273-313.
- [2] NYLEN A B, REYES M L, ROE C A, et al. Impacts on driver perceptions in initial exposure to ADAS technologies [J]. Transportation Research Record, 2019, 2673(10): 354-360.
- [3] 张野,张建国.基于分布式滑模的智能网联汽车变车距队列控制[J].电子测量技术,2020,43(22):62-66.
- [4] CUI Q, DING R, ZHOU B, et al. Path-tracking of an autonomous vehicle via model predictive control and nonlinear filtering[J]. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2017, 232(9): 1237-1252.
- [5] HUANG C, NAGHDY F, DU H P. Fault tolerant sliding mode predictive control for uncertain steer-by-wire system[J]. IEEE Transactions on Cybernetics, 2019, 49(1): 261-272.
- [6] 王雪彤,罗禹贡,江发潮,等.纯电动商用车异质队列的多目标控制[J].汽车工程,2020,42(4): 505-512,559.
- [7] 唐小林,李珊珊.网联环境下基于分层式模型预测控制的车队能量控制策略研究[J].机械工程学报,2020,56(14): 119-128.
- [8] QIU L, QIAN L, ZOMORODI H, et al. Global optimal energy management control strategies for connected four wheel drive hybrid electric vehicles[J]. IET Intelligent Transport Systems, 2017, 11(5): 264-272.
- [9] 郭景华,王班,王婧瑶,等.智能网联混合动力汽车队列模型预测分层控制[J].汽车工程,2020,42(10): 1293-1301,1334.
- [10] HASSANZADEH M, RAHMANI Z. A predictive controller for real-time energy management of plug-in hybrid electric vehicles[J]. Energy, 2022, 249: 123663.
- [11] YUE M, MASRY Z, JEMEI S, et al. An online prognostics-based health management strategy for fuel cell hybrid electric vehicles[J]. International Journal of Hydrogen Energy, 2021, 46(24): 13206-13218.
- [12] GUO L, ZHANG X, ZOU Y, et al. Cost-optimal energy management strategy for plug-in hybrid electric vehicles with variable horizon speed prediction and adaptive state-of-charge reference[J]. Energy, 2021, 232: 120993.
- [13] LI G, GORGES D. Ecological adaptive cruise control and energy management strategy for hybrid electric vehicles based on heuristic dynamic programming[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(9): 3526-3535.
- [14] 周维,刘鸿远,徐彪,等.功率分流式混合动力矿用自卸车预测性等效燃油消耗最小控制策略研究[J].机械工程学报,2021,57(2): 200-209.
- [15] 杨宁康,韩立金,刘辉,等.基于效率优化的混合动力车辆强化学习能量管理策略研究,汽车工程[J].2021,43(7): 1046-1056.
- [16] 尹燕莉,黄学江,潘小亮,等.基于PID与Q-Learning的混合动力汽车队列分层控制[J].吉林大学学报(工学版),2023,53(5):1481-1489.
- [17] WANG X, UFNALSKI B, GRZESIAK L M. Adaptive speed control in the PMSM drive for a non-stationary repetitive process using particle swarms[C]. 10th International Conference on Compatibility, Power Electronics and Power Engineering, 2016: 464-471.

## 作者简介

朱兰馨,硕士研究生,主要研究方向为智能网联汽车及混合动力汽车能量管理。

E-mail: 1336510518@qq.com

聂枝根(通信作者),副教授,博士,硕士研究生导师,主要研究方向为车辆动力学仿真、智能车辆控制。

E-mail: Niezhigen@126.com