DOI：10.13234/j.issn.2095-2805.2025.6.309 **中图分类号**：TM921 **文献标志码**：A

燃料电池客车模型预测控制能量管理策略

徐 鑫[1](中国电源学会学生会员)，武小花[1,2](中国电源学会会员)，杨佳珞[1]，舒俊豪[1]

(1.西华大学汽车测控与安全四川省重点实验室，成都 610039；2.四川省新能源汽车智能控制与仿真测试技术工程研究中心，成都 610039)

摘要：为提高燃料电池客车燃料经济性，针对基于规则能量管理策略依赖工程经验和参数校准的问题，提出1种模型预测控制的能量管理策略。为减少计算量，策略采用分层控制方式实现。在顶层，采用动态规划能量管理策略确定锂电池荷电状态最佳参考轨迹；在底层，采用径向基函数神经网络预测未来车辆速度，以预测时域内燃料电池功率高效输出与荷电状态跟随最佳参考轨迹为目标，并通过二次规划算法求解出功率分配最优决策。详细研究了速度预测模型和预测时域范围的确定、荷电状态参考轨迹对所提策略的影响及不同策略下荷电状态变化和燃料经济性。结果表明，在初始荷电状态为0.7时，所提模型预测控制策略的燃料经济性能够达到动态规划策略燃料经济性的92.99%以上，相比基于规则的策略，燃料经济性至少提高11.78%。随着初始荷电状态的增加，所提策略表现出更好的燃料经济性。

关键词：燃料电池客车；能量管理策略；速度预测；动态规划；模型预测控制

Model Predictive Control-based Energy Management Strategy for Fuel Cell Buses

XU Xin[1], *Student Member*, *CPSS*, WU Xiaohua[1,2], *Member*, *CPSS*, YANG Jialuo[1], SHU Junhao[1]

(1. Vehicle Measurement Control and Safety Key Laboratory of Sichuan Province, Xihua University, Chengdu 610039, China; 2. Sichuan New Energy Vehicle Intelligent Control and Simulation Testing Technology Engineering Research Center, Chengdu 610039, China)

Abstract: To improve the fuel economy of fuel cell buses, an energy management strategy based on model predictive control was proposed to solve the problem that the rule-based energy management strategy depends on engineering experience and parameter calibration. This strategy was implemented in a layered control manner to reduce the amount of computation. At the top level, a dynamic programming energy management strategy was used to determine the best reference trajectory for the lithium battery's state-of-charge (SOC). At the bottom layer, radial basis function neural network was used to predict the future vehicle speed, with the goal of predicting the efficient output of fuel cell power and SOC to follow the best reference trajectory in the time domain. In addition, the optimal decision making on power distribution was solved by the quadratic programming algorithm. The determination of the speed prediction model and prediction time-domain, the influence of SOC reference trajectories on the proposed strategy, and the changes in SOC and fuel economy under different strategies were studied in detail. Results show that when the initial SOC is 0.7, the fuel economy under the proposed model predictive control-based strategy can reach more than 92.99% of the fuel economy under the dynamic programming strategy, which is at least 11.78% higher than that under the rule-based strategy. Furthermore, the proposed strategy exhibits better fuel economy as the initial SOC increases.

收稿日期：2022-10-27；**修回日期**：2023-01-03，2023-02-10；**录用日期**：2023-03-16；**网络首发日期**：2023-04-27

基金项目：四川省科技计划资助项目(2020YFQ0037，2021YFG0071)；成都市科技局资助项目(2021-RK00-00024-ZF)；四川省西华大学研究生创新基金资助项目(YCJJ2021092)

This work is supported by Sichuan Science and Technology Plan under the grants 2020YFQ0037 and 2021YFG0071; Chengdu Science and Technology Bureau under the grant 2021-RK00-00024-ZF; Graduate Innovation Fund of Xihua University, Sichuan Province under the grant YCJJ2021092

Keywords: Fuel cell bus; energy management strategy; speed prediction; dynamic programming; model predictive control

随着能源和环境问题的凸显，发展新能源汽车已经成为汽车领域应对这一问题的共识[1]。电池的有限容量和较长的充电时间限制着纯电动汽车的应用。燃料电池汽车既有纯电动汽车无污染、低噪声的特点，又具备与传统内燃机汽车相当的续航里程和燃料加注时长，正成为学术界和工业界的研究热点。为了弥补燃料电池对车辆功率需求动态响应不及时及无法实现制动能量回收的缺点，通常在燃料电池基础上添加辅助能源，如电池/超级电容[2]。由此产生在不同能量源之间合理分配功率需求以满足车辆燃料经济性、系统耐用性等目标的能量管理策略 EMS(energy manage-ment strategy)问题[3]。

学者们围绕 EMS 问题提出了基于规则和基于优化 2 类策略[4-9]，功率跟随与模糊规则是具有代表性的 2 种规则策略。文献[10]提出了变参数和荷电状态 SOC(state-of-charge)调节方法的功率跟随策略，提高了燃料电池混合动力系统的经济性并使得功率波动率最优；文献[11]针对混合动力汽车设计了基于模糊逻辑和 Elman 神经网络的自适应 EMS，通过与传统策略进行比较，结果表明所提策略可以提高燃油经济性并具有更快的响应速度。基于规则的 EMS 计算效率高，但依赖工程经验和参数校准且难以保证最优。基于优化的 EMS 通过优化算法实现最优控制，根据先验信息依赖程度可进一步分为以动态规划 DP(dynamic programming)、庞特里亚金极小值原理 PMP(Pontryagin's minimum principle)等为代表的全局优化策略和以等效消耗最小化策略 ECMS(equivalent consumption minimization strategy)、模型预测控制 MPC(model predictive control)等为代表的瞬时优化策略。文献[12]提出了 1 种考虑电池寿命的混合动力汽车 DP 策略，通过考虑各子系统效率使得混合动力汽车再生能源回收率提高了 3%；文献[13]针对混合动力汽车提出 1 种粒子群优化的 PMP 策略，仿真结果表明该策略能够提高节能减排比 1.6%~2.0%。瞬时优化通过权衡优化效果和计算时间实现策略在线运行；文献[14]基于自适应 ECMS 保证了燃油经济性和电池 SOC 稳定；文献[15]提出了 1 种基于信息融合模型和交通预测模型的 MPC 策略，仿真结果表明插电式混合动力汽车的燃油经济性提高了 8.65%，且具有良好的鲁棒性。基于全局优化的策略通过最小化整个工况内的成本函数，得出最优控制结果，但计算量大难以实时应用。基于瞬时优化的策略中，与传统 ECMS 策略相比，MPC 考虑了未来车辆的功率需求且避免了 ECMS 等效因子对全局工况的依赖。速度预测模型影响 MPC 优化效果，文献[16]针对指数变化、随机马尔可夫链和基于神经网络的车速预测方法进行对比分析，仿真结果表明神经网络相较于其他预测方法整车燃油经济性最佳。为减少计算量，学者们提出采用分层控制实现 MPC。文献[17]提出了 1 种用于燃料电池汽车的分层 MPC 框架，上层控制器用于燃料电池和锂电池之间的 EMS，下层控制器用于通过优化过氧比来实现燃料电池功率跟踪。然而，上述研究都较少针对燃料电池客车分析结合基于 DP 和 MPC 策略的优势，同时应用分层控制，设计出可在线运行的 EMS。

本文针对燃料电池客车，在 MPC 理论的基础上提出 1 种分层 MPC 的在线 EMS。在顶层，采用基于 DP 的 EMS 确定 SOC 最佳参考轨迹；在底层，以典型工况数据集训练并验证基于径向基函数神经网络 RBF-NN (radial basis function neural network)的速度预测模型，采用二次规划建立预测时域内优化问题并求解燃料电池客车动力系统功率分配决策。分析不同速度预测模型和预测时域范围的预测精度和燃料经济性，SOC 参考轨迹对所提 MPC 策略的影响并在中国城市客车行驶工况 CHTC-B (China heavy-duty commercial vehicle test cycle for bus)和经调整的中国重型商用车辆瞬态工况 C-WTVC (China world transient vehicle cycle)上对比所提 MPC 策略、DP 策略和规则(Rule)策略的 SOC 变化和燃料经济性。

1　燃料电池客车动力系统结构

本文研究对象是某示范运行的燃料电池客车，其动力系统结构如图 1 所示，主要包括电机、燃料电池系统和锂电池[18]。整车控制器在监控车辆状态的同时接收驾驶员指令，并输出各能量源功率分配结果指令给底层控制器。底层控制器主要包括燃料电池控制器、电池管理系统、高压配电单元及电机控制器。根据整车控制器的功率分配指令，燃料电池系统和锂电池协同工作以响应电机的功率需求。整车动力系统的参数取自实车数据[19]，根据研究重点，本文在建模过程中侧重于动力总成组件(电机、燃料电池系统和锂电池)，不考虑其他附属组件的功率损耗，即其效率视为 100%。有关建模的其他详细信息参考文献[20]。

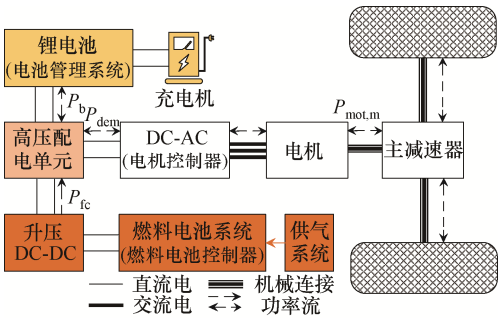


图 1　燃料电池客车动力系统结构

Fig. 1 Structure of fuel cell bus power system

2　能量管理策略

燃料电池客车能量管理问题本质上是在每个时间步长下得出燃料电池与锂电池之间的功率分配，以满足燃料电池客车功率需求的同时提高燃料经济性。

2.1　基于 DP 的策略

燃料电池客车能量管理是典型的多阶段决策问题，因此适用于 DP 求解。由于整车部件的响应需要一定时间，本文设定采样时间为 1 s 并对工况进行离散。燃料电池为整车提供主要功率需求，本文将燃料电池输出功率设为决策变量，锂电池 SOC 仅取决于初始 SOC 以及当前时刻前的锂电池功率累积效应，即无后效性，本文将锂电池 SOC 设为状态变量。为满足整车功率需求的同时提高燃料经济性，本文以燃料电池氢耗和锂电池等效氢耗之和最小为优化目标，构建目标函数为

$$\begin{cases} \min J=\sum_{k=0}^{N-1}\left[\int_k^{k+1}(\dot{m}_{fc}+\dot{m}_b)\mathrm{d}t\right] \\ \dot{m}_{fc}=\dfrac{P_{fc,k}}{\eta_{fc}\cdot L_{H_2}} \\ \dot{m}_b=\dfrac{\eta_b^{-\mathrm{sgn}(P_{b,k})}\cdot P_{fc,k}}{\eta_{fc}\cdot L_{H_2}} \end{cases} \tag{1}$$

式中：N 为工况长度；$\dot{m}_{fc}$、$\dot{m}_b$ 分别为燃料电池氢耗率、锂电池等效氢耗率；P_{fc}、P_b 分别为燃料电池输出功率、锂电池输出功率；η_{fc}、η_b 分别为燃料电池、锂电池的效率；L_{H_2} 为氢气的低热值，120 kJ/g。

燃料电池客车在运行过程中，由于各动力总成组件受到自身物理性质限制，故 DP 策略的状态变量和决策变量约束为

$$\begin{cases} S_{OC,min}\leqslant S_{OC,k}\leqslant S_{OC,max} \\ P_{fc,min}\leqslant P_{fc,k}\leqslant P_{fc,max} \\ P_{b,min}\leqslant P_{b,k}\leqslant P_{b,max} \\ P_{mot,min}\leqslant P_{mot,m,k}\leqslant P_{mot,max} \\ S_{OC,k+1}=S_{OC,k}-\dfrac{\Delta T}{V_b\cdot Q_b}\cdot P_{b,k} \\ S_{OC,0}=S_{OC,ini} \\ S_{OC,N}=S_{OC,end} \\ P_{dem,k}=P_{fc,k}+P_{b,k}-P_{aux,k} \\ P_{dem,k}=\dfrac{\eta_{mot}^{-\mathrm{sgn}(P_{mot,m,k})}\cdot v}{\eta_{FD}}\left[mgf_r\cos\theta+\right. \\ \qquad \left.\dfrac{1}{2}\rho AC_D v^2+mg\sin\theta+\sigma m\dfrac{\mathrm{d}v}{\mathrm{d}t}\right] \end{cases} \tag{2}$$

式中：$S_{OC,k}$、$S_{OC,min}$、$S_{OC,max}$、$S_{OC,0}$、$S_{OC,ini}$、$S_{OC,N}$、$S_{OC,end}$ 分别为当前时刻 SOC 值(k 为当前时刻)；SOC 最小值、SOC 最大值、k=0 时刻 SOC、工况初始时刻 SOC、工况结束时刻 SOC、电池终态 SOC；ΔT 为采样时间；g 为重力加速度；$P_{fc,min}$、$P_{fc,max}$ 分别为燃料电池的最小功率、最大功率；P_{aux}

为燃料电池附件消耗功率；$P_{b,min}$、$P_{b,max}$分别为锂电池的最小功率、最大功率；$P_{mot,m}$、$P_{mot,min}$、$P_{mot,max}$分别为电机的机械功率、最小功率、最大功率；V_b、Q_b分别为锂电池的端电压、容量；P_{dem}为电机的需求功率；η_{mot}、η_{FD}分别为电机效率、主减速器效率；v为车辆速度；m为车辆质量；f_r为滚动阻力系数；θ为道路坡度；ρ为空气密度；A为车辆迎风面积；C_D为空气阻力系数；σ为旋转质量换算系数。

2.2 基于 MPC 的策略

MPC 将全局优化问题转化成每一时刻下预测时域内的局部优化问题且具有反馈修正环节。在 DP 策略能量管理的基础上结合当前智能网联技术的发展，提出 1 种分层 MPC 策略，基本框架如图 2 所示。在顶层，假设智能交通系统给出了 1 条理想的行驶工况，采用基于 DP 的 EMS 求出 SOC 最佳参考轨迹，输入到目标车辆。考虑到实际运行过程中可能出现的顶层算力不足问题，设计线性 SOC 参考轨迹作为替代方案，线性 SOC 参考模型为

$$S_{OC,ref}=S_{OC,k}-\frac{k}{T_{trip}}(S_{OC,k}-0.7) \tag{3}$$

式中：$S_{OC,ref}$为 SOC 参考轨迹；T_{trip}为剩余工况持续时间。

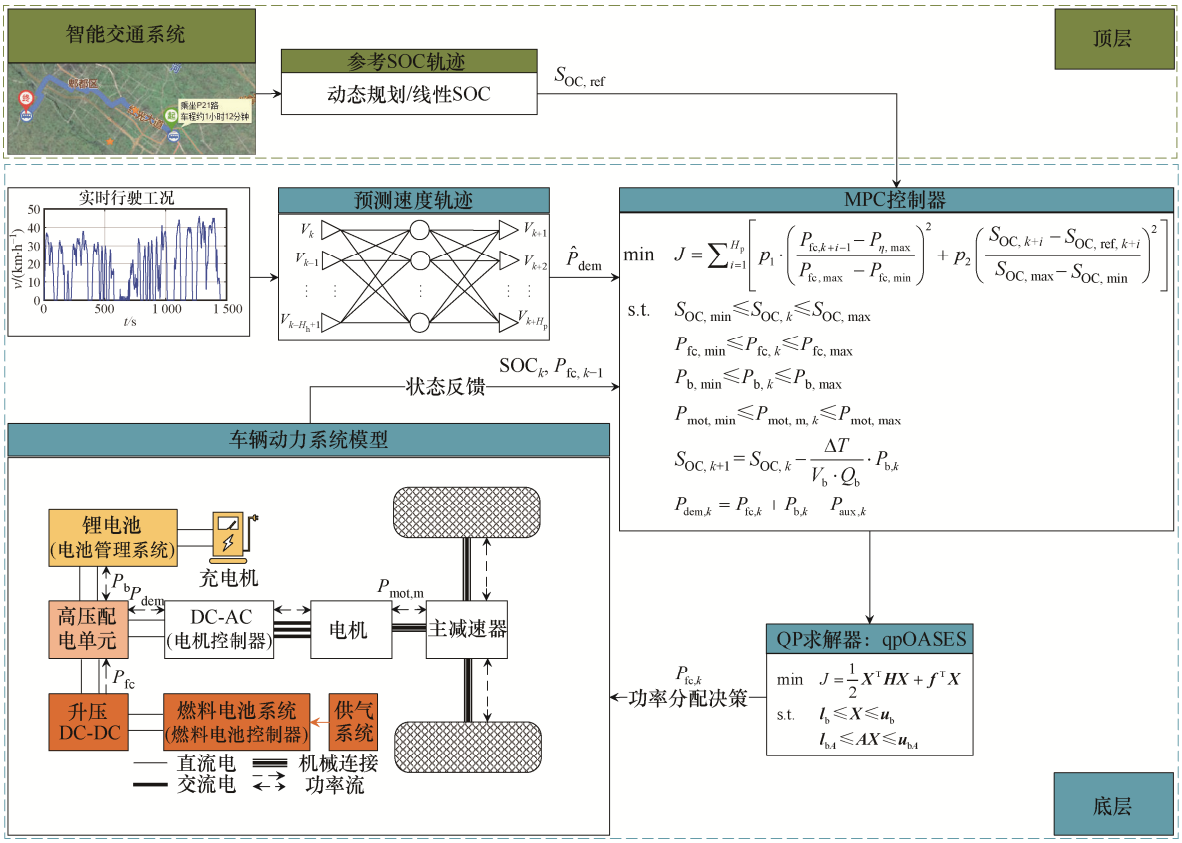


图 2 基于模型预测控制的能量管理策略框架

Fig. 2 MPC-based EMS framework

在底层，针对当前时刻，结合 SOC 参考轨迹、预测车速和当前车辆状态，MPC 通过最小化预测时域内的目标函数得到控制时域内的燃料电池功率最优决策序列，并将其中第 1 个决策值应用于车辆动力系统模型；在下一个采样时刻，重复上述过程，直至工况结束。

2.2.1 基于 RBF-NN 的速度预测模型

MPC 策略是预测时域内的局部优化问题，因此短期工况预测的精度制约着 EMS 的优化效果。在速度预测的各种方法中，基于神经网络的速度预

测模型被证明能够有效提高预测精度，且其中 RBF-NN 的样本训练收敛速度和拟合精度表现良好[21]。车速具有典型的时间序列特征，因此使用 RBF-NN 搭建速度预测模型进行时间序列预测。基于 RBF-NN 的速度预测模型如图 3 所示。RBF-NN 采用 3 层前向网络结构，输入层为由车速传感器采集的历史速度序列，输出层为未来时域的预测速度序列，隐含层的激活函数选择高斯函数，则 RBF-NN 的输出可表示为

$$y_i=\sum_{j=1}^{p}w_{j,i}\exp\left(-\frac{\left\|\boldsymbol{X}_{\mathrm{RBF}}-c_j\right\|^2}{2\sigma_j^2}\right)\qquad i=1,2,\cdots,m \tag{4}$$

式中：$\boldsymbol{X}_{\mathrm{RBF}}=[x_1\ \ x_2\ \ \cdots\ \ x_n]$ 为 n 维输入向量；p、m 分别为隐含层、输出层的神经元个数；c_j、σ_j 分别为激活函数的中心和方差；$w_{j,i}$ 为隐含层与输出层的连接权值。

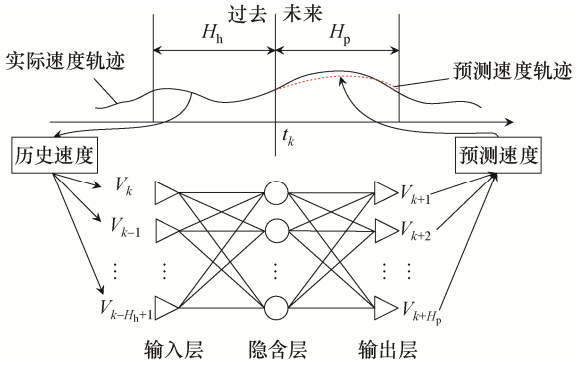


图 3　基于径向基函数神经网络的速度预测模型

Fig. 3 Speed prediction model based on RBF-NN

基于 RBF-NN 的速度预测模型可写成函数 f_{NN} 形式，即

$$[V_{k+1},\cdots,V_{k+H_\mathrm{p}}]=f_{\mathrm{NN}}[V_{k-H_\mathrm{h}+1},\cdots,V_k] \tag{5}$$

式中：H_h、H_p 分别为历史车速序列长度、预测时域；$[V_{k-H_\mathrm{h}+1},\cdots,V_k]$、$[V_{k+1},\cdots,V_{k+H_\mathrm{p}}]$ 分别为历史车速序列、预测车速序列。

2.2.2　车辆状态预测模型与滚动优化

MPC 策略的输入为锂电池 SOC、从基于 DP 的 EMS 获得的参考 SOC 轨迹和预测车速，输出为燃料电池和锂电池的功率分配。与基于 DP 的 EMS 相同，选择锂电池 SOC 作状态变量，燃料电池功率作决策变量，预测车速作扰动变量，时间步长为 1 s。则车辆状态预测模型为

$$\begin{cases}S_{\mathrm{OC},k+1}=S_{\mathrm{OC},k}-\dfrac{\Delta T}{V_\mathrm{b}\cdot Q_\mathrm{b}}\cdot P_{\mathrm{b},k}\\ P_{\mathrm{b},k}=-P_{\mathrm{fc},k-1}+\dfrac{\eta_{\mathrm{mot}}^{-\mathrm{sgn}(P_{\mathrm{mot,m},k})}\cdot v}{\eta_{\mathrm{FD}}}\left(mgf_\mathrm{r}\cos\theta+\right.\\ \qquad\left.\dfrac{1}{2}\rho AC_\mathrm{D}v^2+mg\sin\theta+\sigma m\dfrac{\mathrm{d}v}{\mathrm{d}t}\right)\end{cases} \tag{6}$$

选取二次规划作为 MPC 的求解算法，因此需要在保证控制目标总体不变的同时使得优化问题的形式满足二次规划的要求。本文将控制目标转换成在预测时域内使得燃料电池系统尽可能在最高效工作点附近运行，并跟随 SOC 最优参考轨迹。设置预测时域与控制时域相等，则预测时域内目标函数可以表示为

$$\min J=\sum_{i=1}^{H_\mathrm{p}}\left[p_1\cdot\left(\frac{P_{\mathrm{fc},k+i-1}-P_{\eta,\max}}{P_{\mathrm{fc},\max}-P_{\mathrm{fc},\min}}\right)^2+p_2\cdot\left(\frac{S_{\mathrm{OC},k+i}-S_{\mathrm{OC,ref},k+i}}{S_{\mathrm{OC},\max}-S_{\mathrm{OC},\min}}\right)^2\right] \tag{7}$$

式中：$P_{\eta,\max}$ 为燃料电池最高效率点所对应的功率；p_1 和 p_2 分别为燃料电池功率和锂电池 SOC 跟随效果的惩罚系数。状态变量和决策变量的约束与基于 DP 的 EMS 一致，即式(2)。预测时域内的优化问题，即在约束式(2)条件下最小化式(6)，是二次规划问题。本文选择开源二次规划求解器(qpOASES)内置的活动集算法来求解[22]，设决策向量 $\boldsymbol{X}$ 为

$$\boldsymbol{X}=[P_{\mathrm{fc},k}\ \ S_{\mathrm{OC},k}\ \ 1\ \ \cdots\ \ P_{\mathrm{fc},k+H_\mathrm{p}-1}\ \ S_{\mathrm{OC},k+H_\mathrm{p}-1}\ \ 1]^\mathrm{T} \tag{8}$$

则原优化问题的标准二次规划形式可表示为

$$\begin{cases}\min\quad J=\dfrac{1}{2}\boldsymbol{X}^\mathrm{T}\boldsymbol{H}\boldsymbol{X}+\boldsymbol{f}^\mathrm{T}\boldsymbol{X}\\ \text{s.t.}\quad \boldsymbol{l}_\mathrm{b}\leqslant\boldsymbol{X}\leqslant\boldsymbol{u}_\mathrm{b}\\ \qquad \boldsymbol{l}_{\mathrm{b}\boldsymbol{A}}\leqslant\boldsymbol{A}\boldsymbol{X}\leqslant\boldsymbol{u}_{\mathrm{b}\boldsymbol{A}}\end{cases} \tag{9}$$

式中：$\boldsymbol{H}$ 为海瑟矩阵；$\boldsymbol{f}$ 为梯度向量；$\boldsymbol{l}_\mathrm{b}$、$\boldsymbol{u}_\mathrm{b}$ 为决策向量的上、下限边界向量；$\boldsymbol{A}$ 为约束矩阵；$\boldsymbol{l}_{\mathrm{b}\boldsymbol{A}}$、$\boldsymbol{u}_{\mathrm{b}\boldsymbol{A}}$ 为约束矩阵的上、下限边界向量。

根据 MPC 原理，求解 k 时刻预测时域内的优化问题，得到最优决策向量并将第一个决策变量 $P_{\mathrm{fc},k}^{*}$ 作用于燃料电池客车动力系统模型，在下一个时刻重复以上过程直至得到整个工况的最优控制决策序列。

3 仿真分析

分别对速度预测、SOC 参考轨迹对 MPC 策略的影响及不同 EMS 策略性能表现进行分析，所有仿真均在 1 台配置 Intel Core i5-8300H CPU@2.40GHz 笔记本电脑的 MATLAB R2020b/Simulink 中完成。所研究燃料电池客车主要参数见表 1。选择等效氢耗作为燃料经济性的评价指标，可表示为

$$m_{\mathrm{H_2,equ}}=m_{\mathrm{fc}}+\frac{\Delta S_{\mathrm{OC}}\cdot E_{\mathrm{b}}\cdot 3\ 600}{\eta_{\mathrm{fc,ave}}\cdot L_{\mathrm{H_2}}} \tag{10}$$

式中：m_{fc} 为燃料电池的氢消耗；E_{b} 为锂电池能量容量；$\eta_{\mathrm{fc,ave}}$ 为燃料电池平均效率。

表 1 燃料电池客车主要参数

Tab. 1 Main parameters of fuel cell bus

部件	参数	数值
整车	整车质量/kg	11 800
	迎风面积/m^2	7.13
	风阻系数	0.65
	滚阻系数	0.014
	车轮半径/m	0.479
	主减速器传动比	6.14
电机	最大转速/(r·min^{-1})	3 000
	最大转矩/(N·m)	1 500
燃料电池	额定功率/kW	47
	最大效率	53%
锂电池	额定容量/(A·h)	173
	额定电压/V	521
	SOC	0.6~0.8

3.1 速度预测结果分析

为了验证 RBF-NN 速度预测模型的有效性，选取 2 种典型的神经网络速度预测模型作为对比，分别为反向传播神经网络 BP-NN(back propagation neural network)和分层递归神经网络 LR-NN(layer recurrent neural network)。神经元数目设置相同，网络训练采用 5 种取自 ADVISOR 的标准循环工况(NewYorkBus、INDIA_HW、WVUSUB、NurembergR36、UKBUS6)和中国典型城市公交工况 CCBC(China city bus driving cycle)组成的数据库作为样本，如图 4 所示，其中 85%为训练数据集，15%为测试数据集，包含了城市客车运行的典型城市和郊区驾驶场景，涵盖了城市客车运行的所有车速范围。

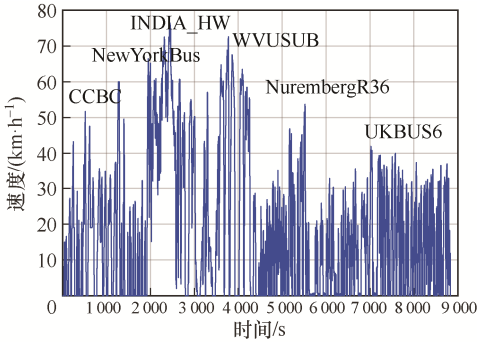


图 4 速度预测模型网络训练数据库

Fig. 4 Speed prediction model network training database

速度预测模型的输入为当前时刻 t_k 前 5 s 的历史车速信息，预测时域 H_{p}。将 CHTC-B 工况用作验证数据集，并选择整个驾驶工况均方根误差 RMSE (root mean square error)的平均值 $\overline{R}_{\mathrm{MSE}}$ 作为速度预测精度的评价指标。不同神经网络速度预测模型的预测结果如图 5 所示，$\overline{R}_{\mathrm{MSE}}$ 数据见表 2。可以看出，在预测精度方面 RBF-NN 和 LR-NN 相比 BP-NN 均有较大改进，但是由于 LR-NN 网络复杂，因此

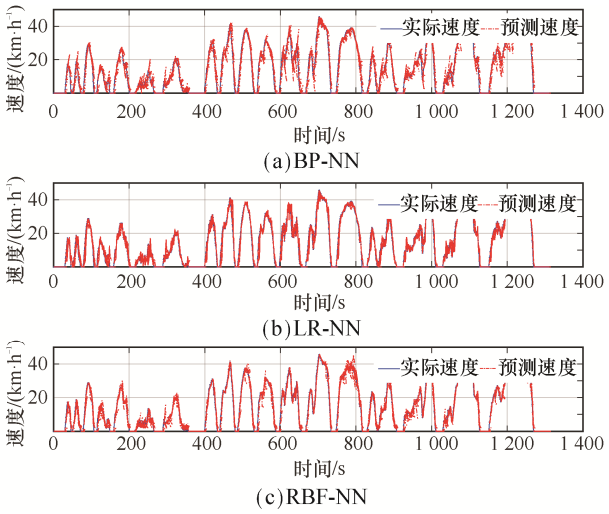


图 5 不同神经网络速度预测模型的预测结果

Fig. 5 Prediction results of different neural network speed prediction models

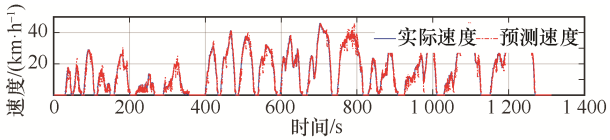
表 2　不同神经网络速度预测模型的平均 RMSE

Tab. 2 Average RMSE of different neural network speed prediction models

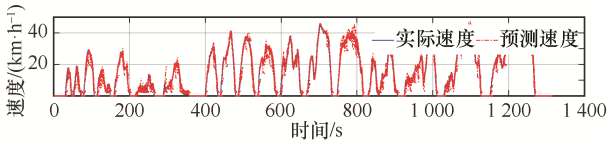
网络类型	$\overline{R}_{\mathrm{MSE}}$/(km·h^{-1})	改进/%	训练时间/s
BP-NN	3.05	—	55
LR-NN	2.70	11.48	503
RBF-NN	2.69	11.80	61

需要更多的训练时间。权衡预测精度和训练时间，RBF-NN 更适合作为所研究对象的速度预测模型。

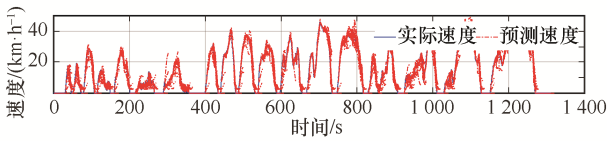
RBF-NN 的速度预测结果如表 6 所示，在不同 H_{P} 下 MPC 策略的性能差异见表 3。可以看出，随着预测时域 H_{P} 的增加，速度预测的 $\overline{R}_{\mathrm{MSE}}$ 逐渐增大，但等效氢耗呈现先减少再增加的趋势。



(a) H_{p}=3



(b) H_{p}=5



(c) H_{p}=10

图 6　RBF-NN 的速度预测结果

Fig. 6 Speed prediction results of RBF-NN

表 3　不同 H_{P} 下 MPC 策略的性能差异

Tab. 3 Performance difference under MPC strategy at different values of H_{P}

H_{P}	$\overline{R}_{\mathrm{MSE}}$/(km·h^{-1})	$S_{\mathrm{OC,0}}$	$S_{\mathrm{OC,N}}$	$m_{\mathrm{H_2,equ}}$/g
3	2.15	0.7	0.699 82	263.10
5	2.69	0.7	0.699 97	259.80
10	4.03	0.7	0.699 85	261.20
15	5.73	0.7	0.699 83	262.68

为了确定最佳预测时域 H_{P}，以仿真步长 1 s 为间隔，研究 H_{P} 处于 1~15 s 范围内 RBF-NN 的速度预测结果和 MPC 策略的性能差异，结果如图 7 所示。当 H_{P}<5 s 时，等效氢耗随着 H_{P} 的增加而减少，在此范围速度预测的 $\overline{R}_{\mathrm{MSE}}$ 略有增加；当 H_{P}>5 s 时，由于速度预测的 $\overline{R}_{\mathrm{MSE}}$ 持续增加，抵消了 H_{P} 增加对等效氢耗减少的积极作用，等效氢耗逐渐增长。当 H_{P}=5 s 时，MPC 策略下等效氢耗最小，为 259.80 g。

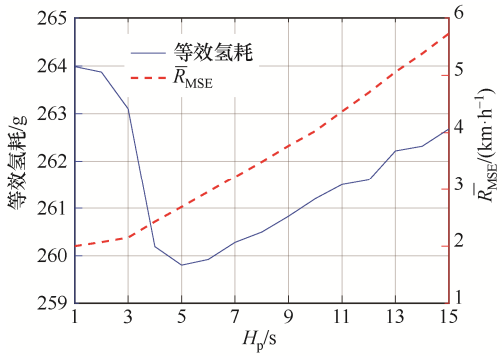
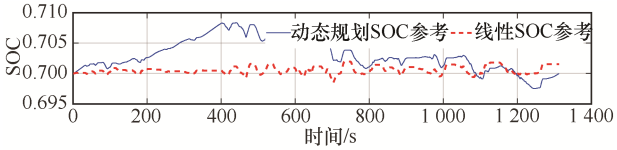


图 7　不同 H_{P} 下 MPC 策略的 $\overline{R}_{\mathrm{MSE}}$ 和等效氢耗

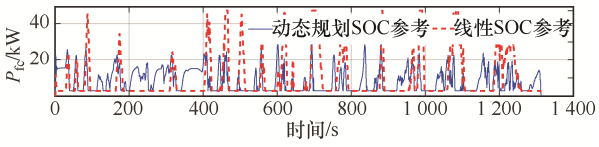
Fig. 7　$\overline{R}_{\mathrm{MSE}}$ and equivalent hydrogen consumption under MPC strategy at different values of H_{P}

3.2　SOC 参考轨迹对 MPC 的影响结果分析

为了验证线性 SOC 参考轨迹替代方案的有效性，考虑最差情况，即工况开始便出现顶层计算速度不够快。不同类型 SOC 参考轨迹下 MPC 策略的仿真结果如图 8 所示，MPC 策略采用线性 SOC 参考轨迹，仍能实现满足整车功率需求的同时维持 SOC 在设定范围。相比采用基于 DP 所求出 SOC 参考轨迹的 MPC 策略，采用线性 SOC 参考轨迹的 MPC 策略燃料电池功率变化更剧烈。不同 SOC 参考轨迹下 MPC 策略的性能差异见表 4，可以看出，采用线性 SOC 参考轨迹的 MPC 策略，相比采用 DP 的 SOC 参考轨迹的 MPC 策略，仍能保持 95.14% 的燃料经济性。



(a) SOC曲线



(b) P_{fc}曲线

图 8　不同类型 SOC 参考轨迹下 MPC 策略的仿真结果

Fig. 8 Simulation results under MPC strategy with different types of SOC reference trajectories

表 4 不同 SOC 参考轨迹下 MPC 策略的性能差异

Tab. 4 Performance differences under MPC strategy with different SOC reference trajectories

SOC 参考轨迹类型	百公里等效氢耗/kg	燃料经济性/%
基于 DP	4.73	100.00
线性	4.96	95.14

3.3 不同 EMS 结果分析

为了验证所提基于分层 MPC 策略的有效性，选择 CHTC-B 和 C-WTVC 两段标准循环工况进行仿真并与理论最优的 DP 策略和 Rule 策略进行对比。初始 SOC 均设为 0.7，2 种工况下燃料电池的功率决策和锂电池 SOC 的变化情况分别如图 9 和图 10 所示。可以看出，2 种工况下 3 种策略均能维持 SOC 在 0.7 附近，避免了锂电池的过度充电和过度放电。SOC 曲线体现了锂电池对功率分配的调节作用，Rule 策略为了维持 SOC 不变，燃料电池功率变化剧烈，而 MPC 策略和 DP 策略合理规划 SOC 变化，燃料电池功率变化相对平缓。在 CHTC-B 工况下，前 400 s 内需求功率较低，MPC 策略的燃料电池在满足需求功率的同时给锂电池充电，后 900 s 内需求功率较高，锂电池有充足的能量容量满足需求功率剧烈波动，使得整个过程 MPC 策略的燃料电池功率稳定在最高效功率点附近。同样的

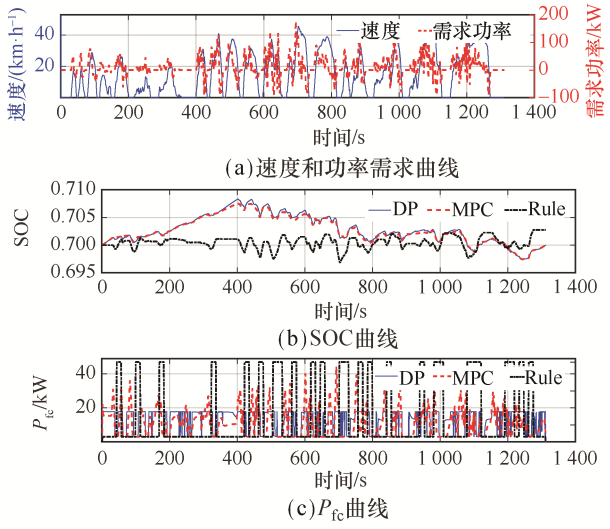


图 9 CHTC-B 工况下 3 种策略的仿真结果

Fig. 9 Simulation results under three strategies in the case of CHTC-B

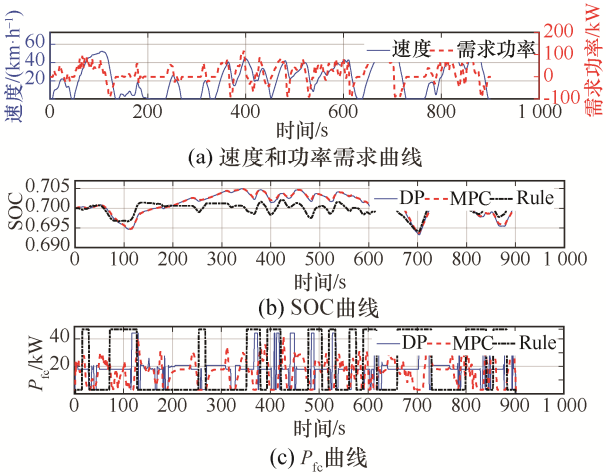


图 10 C-WTVC 工况下 3 种策略的仿真结果

Fig. 10 Simulation results under three strategies in the case of C-WTVC

现象也体现在 C-WTVC 工况中。MPC 策略的 SOC 曲线能很好地跟随 DP 策略的 SOC 曲线，但也存在较小偏差，原因是 DP 是在已知全局工况下做出的最优 EMS，因此可以保证燃料电池功率在整个工况内波动不大且绝大部分处于燃料电池的高效点；而 MPC 则是在预测时域内的局部最优 EMS，同时受到速度预测精度的影响，仅能得到次优的结果。

不同工况下燃料经济性结果见表 5，可以看出，采用相同策略，C-WTVC 比 CHTC-B 得出的等效氢耗偏高，这可以从各自所对应的速度和功率分配曲线得到解释。CHTC-B 工况的平均速度仅为 15.08 km/h，最高速度仅为 45.6 km/h，燃料电池功率曲线几乎都在最高效率点。而 C-WTVC 工况的平均速度为 22.89 km/h，最高速度为 66.2 km/h，整

表 5 不同工况下燃料经济性结果

Tab. 5 Fuel economy results under different operating conditions

工况	策略	$S_{OC,N}$	$m_{H_2,equ}$/g	百公里等效氢耗/kg	燃料经济性/%
CHTC-B	DP	0.700 00	242.68	4.42	100.00
	MPC	0.699 97	259.80	4.73	92.99
	Rule	0.702 76	293.10	5.34	79.19
C-WTVC	DP	0.700 00	267.36	4.67	100.00
	MPC	0.699 88	284.19	4.96	93.79
	Rule	0.701 91	315.89	5.51	82.01

体需求功率比 CHTC-B 高。MPC 策略的燃料电池功率总体上分布在最高效率点，但在工况速度较高时会出现以较高功率输出的情况。在 CHTC-B 工况下，MPC 策略的 SOC 终值为 0.699 97，等效氢耗为 259.80 g，百公里等效氢耗为 4.73 kg，燃料经济性达到 DP 策略结果的 92.99%，与 Rule 策略相比，燃料经济性提高了 13.8%。在 C-WTVC 工况下，MPC 策略达到 DP 策略燃料经济性的 93.79%，与 Rule 策略相比，燃料经济性提高了 11.78%。

为了探究不同初始 SOC 下所提基于分层 MPC 策略的有效性，对策略进行初始 SOC 灵敏度分析。当初始 SOC 为 0.6~0.8 时，DP 策略、MPC 策略和 Rule 策略在 CHTC-B 和 C-WTVC 工况下的百公里等效氢耗见表 6。随着初始 SOC 的增加，3 种策略的等效氢耗均表现出减少的趋势。基于分层 MPC 的策略在初始 SOC 为 0.8 下的等效氢耗相比初始 SOC 为 0.6 下的等效氢耗，在 CHTC-B 和 C-WTVC 工况下分别降低了 5.96%和 5.11%，因此为了获得更好的燃料经济性，应将锂电池初始 SOC 维持在较高水平。在 CHTC-B 工况下，MPC 策略相比 Rule 策略等效氢耗减少了 10.99%~11.95%，在 C-WTVC 工况下，MPC 策略相比 Rule 策略等效氢耗减少了 10.07%~10.39%。所提基于分层 MPC 的策略在初始 SOC 为 0.6~0.8 时，相比 Rule 策略，均能有效提高燃料经济性。

表 6　不同初始 SOC 下的百公里等效氢耗(kg)

Tab. 6 Equivalent hydrogen consumption (kg) per 100 kilometers under different values of initial SOC

工况	CHTC-B			C-WTVC		
$S_{OC,0}$	DP	MPC	Rule	DP	MPC	Rule
0.80	4.25	4.57	5.19	4.56	4.83	5.39
0.75	4.36	4.66	5.29	4.61	4.89	5.45
0.70	4.42	4.73	5.34	4.67	4.96	5.51
0.65	4.49	4.79	5.39	4.72	5.02	5.58
0.60	4.55	4.86	5.46	4.79	5.09	5.66

4　结语

本文针对燃料电池客车，提出了 1 种分层 MPC 的在线 EMS，以满足燃料电池客车功率需求的同时提高燃料经济性。根据 RBF-NN 速度预测结果和 DP 能量管理的 SOC 最佳参考轨迹建立预测时域内以燃料电池功率处于最高效点和锂电池 SOC 跟随最佳参考轨迹为目标的能量管理问题，采用二次规划算法求解得到最优功率分配决策。对速度预测模型和预测时域范围的确定、SOC 参考轨迹对 MPC 的影响以及不同策略下 SOC 变化和燃料经济性进行了仿真分析。结果表明，相比 BP-NN 和 LR-NN，RBF-NN 更适合作为所研究对象的速度预测模型，且预测时域取 5 s 时，所提 MPC 策略燃料经济性最优；顶层算力不足时，基于线性 SOC 参考轨迹，MPC 策略仍然能保持良好的燃料经济性；当初始 SOC 为 0.7 时，在 CHTC-B 和 C-WTVC 工况下，MPC 策略的燃料经济性分别达到了 DP 策略的 92.99%和 93.79%，相比基于规则策略燃料经济性分别提高了 13.8%和 11.78%，且随着初始 SOC 的增加，MPC 策略表现出更好的燃料经济性。验证了所提策略在城市公交领域的应用具有一定的燃料经济性优势。

参考文献：

[1] Abo-Khalil A G, Ali Abdelkareem M, Sayed E T, et al. Electric vehicle impact on energy industry, policy, technical barriers, and power systems [J]. International Journal of Thermofluids, 2022, 13: 100134.

[2] 杨继斌, 张继业, 宋鹏云. 储能式有轨电车能量管理策略多目标优化[J]. 电源学报, 2017, 15(5): 137-143.
Yang Jibin, Zhang Jiye, Song Pengyun. Multi-objective optimization of energy management strategy for a tramway with onboard energy storage system [J]. Journal of Power Supply, 2017, 15(5): 137-143. (in Chinese)

[3] 杨佳珞, 舒俊豪, 徐鑫, 等. 燃料电池汽车生命周期分析综述[J]. 西华大学学报(自然科学版), 2022, 41(6): 105-112.
Yang Jialuo, Shu Junhao, Xu Xin, et al. A review of life cycle assessment on fuel cell vehicles [J]. Journal of Xihua University (Natural Science Edition), 2022, 41(6): 105-112. (in Chinese)

[4] 徐德鸿, 李海津, 李霄, 等. 燃料电池发电系统研究综述[J]. 电源学报, 2012, 10(6): 1-8.
Xu Dehong, Li Haijin, Li Xiao, et al. Review on the fuel cell power system [J]. Journal of Power Supply, 2012, 10(6): 1-8. (in Chinese)

[5] 何洪文, 孟祥飞. 混合动力电动汽车能量管理技术研究综述[J]. 北京理工大学学报, 2022, 42(8): 773-783.
He Hongwen, Meng Xiangfei. A review on energy management technology of hybrid electric vehicles [J]. Transactions of Beijing Institute of Technology, 2022, 42(8): 773-783. (in Chinese)

[6] 高锋阳, 高翾宇, 张浩然, 等. 全局与瞬时特性兼优的燃料电池有轨电车能量管理策略[J]. 电工技术学报, 2023, 38(21): 5923-5938.
Gao Fengyang, Gao Xuanyu, Zhang Haoran, et al. Management strategy for fuel cell trams with both global and transient characteristics [J]. Transactions of China Electrotechnical Society, 2023, 38(21): 5923-5938. (in Chinese)

[7] 邱彬，王雪纯，宋平，等. 基于 DSOGI-PLL 的 VSG 双机并联系统功率分配控制策略[J]. 电源学报，2023, 21(2): 89-99.
Qiu Bin, Wang Xuechun, Song Ping, et al. Power distribution control strategy for VSG dual-machine parallel system based on DSOGI-PLL [J]. Journal of Power Supply, 2023, 21(2): 89-99. (in Chinese)

[8] 舒俊豪, 武小花, 杨佳珞，等. 新能源汽车动力电池安全问题分析及改进趋势综述[J]. 电源学报, 2025, 23(3): 354-362.
Shu Junhao, Wu Xiaohua, Yang Jialuo, et al. Review of analysis and improvement trend of new energy vehicle power battery safety issues [J]. Journal of Power Supply, 2025, 23(3): 354-362. (in Chinese)

[9] 王晖南, 王昱瑾. 基于扰动观测器和鲁棒模型预测的电动汽车集群调频方法研究[J]. 电源学报, 2024, 22 (5): 220-229.
Wang Huinan, Wang Yujin. Frequency regulation method for electric vehicles cluster based on disturbance observer and robust model prediction [J]. Journal of Power Supply, 2024, 22(5): 220-229. (in Chinese)

[10] 刘楠, 于博轩, 郭爱, 等. 燃料电池混合动力的功率跟随管理策略分析[J]. 西南交通大学学报, 2020, 55(6): 1147-1154.
Liu Nan, Yu Boxuan, Guo Ai, et al. Analysis of power tracking management strategy for fuel cell hybrid system [J]. Journal of Southwest Jiaotong University, 2020, 55(6): 1147-1154. (in Chinese)

[11] Singh K V, Bansal H O, Singh D. Fuzzy logic and Elman neural network tuned energy management strategies for a power-split HEVs [J]. Energy, 2021, 225: 120152.

[12] Yu Haifang, Liu Long, Bai Boxu, et al. A dynamic programming-based control strategy with optimum efficiency of hybrid energy storage system for HEV [J]. Advanced Materials Research, 2015, 1092-1093: 165-168.

[13] 吴铁洲, 王越洋, 许玉姗, 等. 基于 PMP 算法的 HEV 能量优化控制策略[J]. 自动化学报, 2018, 44(11): 2092-2102.
Wu Tiezhou, Wang Yueyang, Xu Yushan, et al. Energy optimal control strategy of HEV with PMP algorithm [J]. Acta Automatica Sinica, 2018, 44(11): 2092-2102. (in Chinese)

[14] Zeng Tao, Zhang Caizhi, Zhang Yanyi, et al. Optimization-oriented adaptive equivalent consumption minimization strategy based on short-term demand power prediction for fuel cell hybrid vehicle [J]. Energy, 2021, 227: 120305.

[15] Zhao Yang, Cai Yanguang, Song Qiwen. Energy control of plug-in hybrid electric vehicles using model predictive control with route preview [J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8(12): 1948-4854.

[16] Sun Chao, Hu Xiaosong, Moura S J, et al. Velocity predictors for predictive energy management in hybrid electric vehicles [J]. IEEE Transactions on Control Systems Technology, 2015, 23(3): 1197-1204.

[17] Liu Shiqi, Bin Yang, Li Yaoyu, et al. Hierarchical MPC control scheme for fuel cell hybrid electric vehicles [J]. IFAC-PapersOnLine, 2018, 51(31): 646-652.

[18] Wu Xiaohua, Hu Xiaosong, Yin Xiaofeng, et al. Convex programming improved online power management in a range extended fuel cell electric truck [J]. Journal of Power Sources, 2020, 476: 228642.

[19] 武小花, 余忠伟, 朱张玲, 等. 燃料电池公交车模糊能量管理策略[J]. 吉林大学学报(工学版), 2022, 52(9):

2077-2084.

Wu Xiaohua, Yu Zhongwei, Zhu Zhangling, et al. Fuzzy energy management strategy of fuel cell buses [J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(9): 2077-2084. (in Chinese)

[20] 高新梅, 徐鑫, 余忠伟, 等. 基于车速预测的燃料电池客车能量管理策略[J]. 科学技术与工程, 2022, 22(15): 6325-6330.

Gao Xinmei, Xu Xin, Yu Zhongwei, et al. Energy management strategy of fuel cell bus based on vehicle speed forecast [J]. Science Technology and Engineering, 2022, 22(15): 6325-6330. (in Chinese)

[21] Lin Xinyou, Wu Jiayun, Wei Yimin. An ensemble learning velocity prediction-based energy management strategy for a plug-in hybrid electric vehicle considering driving pattern adaptive reference SOC [J]. Energy, 2021, 234: 121308.

[22] Frison G, Diehl M. HPIPM: A high-performance quadratic programming framework for model predictive control [J]. IFAC-PapersOnLine, 2020, 53(2): 6563-6569.



徐鑫

作者简介：

徐鑫(1995—　)，男，中国电源学会学生会员，硕士研究生。研究方向：燃料电池汽车能量管理策略。E-mail: m18328396506@163.com。

武小花(1984—　)，女，中国电源学会会员，通信作者，博士，教授。研究方向：新能源汽车控制技术。E-mail: xiaohuawu13@163.com。

杨佳珞(1998—　)，男，硕士研究生。研究方向：燃料电池汽车全生命周期建模。E-mail: 799810316@qq.com。

舒俊豪(1998—　)，男，硕士研究生。研究方向：动力电池建模和寿命预测。E-mail: 1356655853@qq.com。

(责任编辑：郭凯凯)