

插电式混合动力汽车车速预测及整车控制策略

连 静, 刘 爽, 李琳辉[†], 周雅夫, 杨 帆, 袁鲁山

(大连理工大学 工业装备结构分析国家重点实验室 运载工程与力学学部 汽车工程学院, 大连 辽宁 116024)

摘要: 本文针对插电式混合动力汽车(plug-in hybrid electric vehicle, PHEV)这一典型混杂系统, 提出了一种基于车速预测的混合逻辑动态(mixed logical dynamical, MLD)模型预测控制策略. 首先, 通过对发动机和电动机能量消耗模型进行线性化, 建立双轴并联插电式混合动力城市公交车的动力传动系统数学模型; 其次, 运用模糊推理进行驾驶意图分析, 提出基于驾驶意图识别和历史车速数据相结合的非线性自回归(nonlinear auto-regressive models, NAR)神经网络车速预测方法进行未来行驶工况预测. 然后, 以最小等效燃油消耗为目标建立PHEV的混合逻辑动态模型, 运用预测控制思想对车速预测时域内最优电机转矩控制序列进行求解. 最后, 通过仿真实验验证了本文所提出控制策略在特定的循环工况下与电动助力策略相比, 能够提高燃油经济性.

关键词: 插电式混合动力汽车; 模糊推理; NAR神经网络; 车速预测; 混合逻辑动态模型

中图分类号: U469.72 **文献标识码:** A

Plug-in hybrid electric vehicle speed prediction and control strategy

LIAN Jing, LIU Shuang, LI Lin-hui[†], ZHOU Ya-fu, YANG Fan, YUAN Lu-shan

(School of Automotive Engineering, Faculty of Vehicle Engineering and Mechanics, State Key Laboratory of Structural Analysis for Industrial Equipment, Dalian University of Technology, Dalian Liaoning 116024, China)

Abstract: Focusing on plug-in hybrid electric vehicle (PHEV), a classical hybrid system, a model predictive control (MPC) strategy based on mixed logical dynamical (MLD) model and vehicle speed prediction is proposed. Firstly, the dynamic model of parallel plug-in hybrid electric city bus is established using the linearized energy consumption models of engine and motor. Then, the driving intention is recognized through fuzzy inference, and a vehicle speed prediction method using nonlinear auto-regressive (NAR) models neural network is proposed based on the driving intention and the past vehicle speed data. Next, the MLD model is established with the objective function of minimum equivalent fuel consumption, and the optimal motor torque sequence within the vehicle speed prediction horizon can be solved with the predictive control theory. Finally, the simulation experiment is implemented, and the result shows that the proposed energy control strategy can improve the PHEV fuel economy compared with electric assist strategy under certain driving conditions.

Key words: plug-in hybrid electric vehicle; fuzzy inference; nonlinear auto-regressive neural network; vehicle speed prediction; mixed logical dynamical model

1 引言(Introduction)

插电式混合动力汽车能量管理策略通过合理地分配发动机和电机的功率或转矩来提高车辆的燃油经济性和排放性能, 使其动力系统的综合性能达到最佳状态^[1]. 在目前公开发表的控制策略中, 基于规则的控制策略^[2]最为简单实用, 但其严重依靠经验, 无法适应工况的动态变化, 不能实现动力系统的最佳匹配. 基于优化方法的控制策略^[3-4]包括瞬时优化和全局优化. 其中, 等效燃油最小的瞬时优化控制策略^[5]可保证车辆在当前时刻瞬时最优, 但无法保证在整个工况

性能最优, 而全局优化^[6-7]是在准确预知整个行驶工况的前提下进行的, 其要求过于苛刻. 所以, 如果能够较准确预测车辆在未来尽量长时间内的行驶工况, 即可在该段时间内进行全局寻优, 弥补全局优化算法在实用性上的不足, 为基于模型预测控制的插电式混合动力汽车(plug-in hybrid electric vehicle, PHEV)控制策略研究奠定基础.

车速轨迹预测受人、车、环境多种因素共同影响, 具有高度的时变性和非线性, 如何在尽量长的预测时间内保证良好的预测精度有着重要的意义. 车速预测

收稿日期: 2016-08-22; 录用日期: 2017-03-02.

[†]通信作者. E-mail: dlutlilinhui@126.com; Tel.: +86 15524706097.

本文责任编辑: 陈虹.

国家自然科学基金项目(61473057, 61203171), 中央高校基本科研业务费专项基金项目(DUT17LAB11, DUT15LK13)资助.

Supported by National Natural Science Foundation of China (61473057, 61203171) and China Fundamental Research Funds for Central Universities (DUT17LAB11, DUT15LK13).

的方法总体上可分为基于数据的方法和基于模型的方法^[8], 基于数据的方法主要包括神经网络^[9]、卡尔曼滤波^[10]及隐马尔可夫模型^[11]等. 其中动态神经网络由于具有显著的自学习能力, 非线性映射能力及并行计算能力, 非常适合处理车速预测这类具有高度时变性和非线性的问题^[12]. 本文选用非线性自回归神经网络^[13]进行车速预测, 其在解决时间序列上的非线性问题具有显著的优越性. 在基于数据的方法进行车速预测的文献中, 大多数学者在通过车载全球定位系统(global position system, GPS)采集车速数据的基础上对汽车驾驶循环数据进行统计分析^[14-16], 或直接基于车速传感器数据进行在线预测, 而往往忽略能够反映未来车速变化的驾驶员操作. 驾驶员的操作主要表现在其对加速踏板和制动踏板的控制上, 从而影响车速的变化趋势. 本文充分考虑驾驶员操作对车速变化趋势的影响, 运用模糊推理对驾驶员的踏板操作进行分析, 识别驾驶意图, 并将其做为非线性自回归(non-linear auto-regressive models, NAR)神经网络的一个重要输入, 提出基于驾驶意图分析的NAR神经网络车速预测方法.

基于上述分析, 针对PHEV这一典型混杂系统^[17], 本文建立了其动力传动系统的混合逻辑动态模型^[18], 从而进行模型预测控制方法的研究. 首先以双轴并联插电式混合动力汽车为研究对象, 建立其动力传动系统的数学模型; 其次, 研究运用模糊推理进行驾驶意图分析, 提出基于驾驶意图识别的非线性自回归神经网络车速预测方法预测未来行驶工况并进行需求转矩的转化; 然后, 建立PHEV动力传动系统的混合逻辑动态模型, 运用混合整数线性规划算法, 以最小等效燃油消耗为目标, 结合基于驾驶意图模糊推理分析的预测车速, 提出基于车速预测的插电式混合动力公交车混合逻辑动态模型预测控制策略; 最后, 通过仿真平台验证该策略的有效性.

2 动力传动系统建模(Modeling of powertrain system)

本文以并联插电式混合动力公交车为原型车, 其选用的双轴并联动力传动系统^[19]如图1所示. 图1中, 车轮转矩和转速的动力学模型如下:

$$\begin{cases} T_w = r_w(\frac{\rho_a}{2} A_f C_d v^2 + f_r mg \cos \alpha + mg \sin \alpha) + \frac{J}{r_w} \frac{dv}{dt}, \\ \omega_w = \frac{v}{r_w}, \end{cases} \quad (1)$$

式中: v 为车速, m/s; ρ_a 为空气密度, kg/m³; r_w 为车轮半径, m; ω_w 为车轮转速, rad/s; T_w 为车轮转矩, N·m; A_f 为迎风面积, m²; C_d 为风阻系数; f_r 为轮胎滚动阻力系数; m 为汽车质量, kg; J 为汽车总的转动惯量, kg·m²; α 为车辆行驶的道路坡度, rad; $\frac{dv}{dt}$ 为汽车的

加速度, m/s². 变速器转矩和转速的动力学模型为式(2), 式中: ω_{in} 为变速器输入端的需求转速, rad/s; i_0 为变速器处于某档时车辆总的传动比; T_{in} 为变速器输入端的需求转矩, N·m; η 为变速器处于某档时从变速器输入端到车轮总的传动效率. 定义发动机燃油消耗率的数学模型, 如式(3)所示:

$$T_{in} = \begin{cases} \frac{T_w}{i_0 \eta}, & T_w \geq 0, \\ \frac{T_w}{i_0} \eta, & T_w < 0, \end{cases} \quad (2)$$

$$\dot{m}_f = f_{mf}(\omega_e, T_e), \quad (3)$$

其中: \dot{m}_f 为发动机的燃油消耗率, g/s, 它是转矩 T_e 和转速 ω_e 的函数. 根据发动机燃油效率数据, 将不同转速下发动机燃油消耗率 \dot{m}_f 随转矩的变化关系用最小二乘法拟合为一次函数如图2所示.




图1 并联PHEV动力传动系统

Fig. 1 Parallel PHEV powertrain and transmission system




图2 燃油消耗率 \dot{m}_f 与转矩线性拟合曲线

Fig. 2 Linear fitting curve of engine fuel consumption rate \dot{m}_f and torque

其表达式如式(4), 其中 a_1 和 a_0 分别为拟合直线表达式中一次项系数和常数项:

$$\dot{m}_f = a_1(\omega_e)T_e + a_0(\omega_e), \quad (4)$$

$$\dot{m}_m = \begin{cases} \frac{\lambda U_0 I(\omega_m, T_m)}{R}, & T_m > 0, \\ 0, & T_m = 0, \\ \lambda U_0 I(\omega_m, T_m)R, & T_m < 0, \end{cases} \quad (5)$$

$$\lambda = \frac{(n \cdot \sum Q_i C_i / D_i^2 - \sum(Q_i / D_i) \cdot \sum(C_i / D_i))}{(n \cdot \sum(Q_i / D_i)^2 - (\sum Q_i / D_i)^2)}$$

$$R \cdot \frac{\rho}{Q_{\max} \cdot U_0} \quad (6)$$

式(5)为电机等效燃油消耗率的数学模型, 其中: m_m 为电机的用电量的消耗等效的燃油消耗率, g/s; ω_m 为电机转速, rad/s; T_m 为电机转矩, N·m; R 为柴油质量热值常数(取43000 kJ/kg); I 为电池输出电流, A; U_0 为电池的开路电压, V; λ 表示电机作为电动机消耗电池能量和作为发电机给电池充电时的电池能量等效燃油因子, 为准确反映油电转换的关系, 本文参照 GB/T19753-2005^[20] 中燃料消耗量修正系数的统计计算方法, 进行多次仿真实验统计, 计算等效燃油因子, 如式(6)所示, 其中: n 为实验总次数; Q_i 为第 i 次实验测得的荷电状态(state of charge, SOC)变化量; C_i 为第 i 次实验测得的燃料消耗量, L; D_i 为第 i 次实验的车辆行驶里程, km; ρ 为燃料密度, g/L. 根据电池输出电流的数学模型, 如式(7), 绘出一定转速下电池荷电状态变化率随转矩的拟合曲线(见图3). 用最小二乘法拟合为一次函数如式(8), b_1 和 b_0 分别为拟合直线表达式中一次项系数和常数项, R_i 为电池等效内阻, Ω ; Q_{\max} 为电池容量, C.

$$I = \begin{cases} \frac{U_0 - \sqrt{U_0^2 - 4R_i \omega_m T_m / \eta}}{2R_i}, & T_m > 0, \\ 0, & T_m = 0, \\ \frac{U_0 - \sqrt{U_0^2 - 4R_i \omega_m T_m \cdot \eta}}{2R_i}, & T_m < 0, \end{cases} \quad (7)$$

$$\dot{x} = -\frac{I}{Q_{\max}} = b_1(\omega_m)T_m + b_0(\omega_m). \quad (8)$$




图3 电池荷电状态变化率与转矩线性拟合曲线

Fig. 3 Linear fitting curve of motor torque and SOC change

3 基于驾驶意图分析的车速预测(Vehicle speed prediction based on driving intention analysis)

3.1 驾驶意图的模糊识别(Fuzzy recognition of driving intention)

驾驶员的驾驶意图受行车环境、车辆运行状态和

驾驶员的驾驶习惯等多种因素影响, 具有一定的模糊性, 是一种典型的经验型模型. 而模糊理论采用模糊数学的知识模仿人脑的思维方式, 对模糊现象进行识别和判决, 其在处理经验型模型上有明显优势^[21]. 因此本文选用模糊推理方法来识别驾驶员的驾驶意图. 将驾驶意图总体上分为加速意图、匀速意图和制动意图, 本文重点关注加速和制动两种动态情况. 制动意图按有无对制动踏板的操作分为常规制动和滑行制动, 驾驶意图具体分类如图4所示.

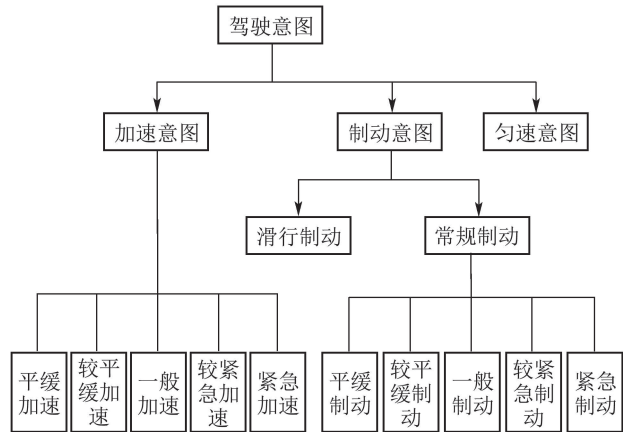



图4 驾驶意图分类


Fig. 4 Driving intention classification

在车辆行驶过程中, 驾驶员根据行车环境及车辆运行状态, 直接对加速踏板、制动踏板及方向盘进行操作来实现其驾驶意图, 因此加速踏板和制动踏板的踏板开度是进行意图识别的主要参数. 但仅靠踏板开度不足以充分反映其加速或是制动的紧急程度, 这里在踏板开度的基础上, 分别引入加速踏板开度变化率和制动踏板开度变化率来识别其加速和制动意图的紧急程度.


加速意图的识别参数确定为加速踏板开度和加速踏板开度变化率, 运用模糊推理进行驾驶意图识别, 其隶属度函数曲线分别如图5(a)和图5(b)所示. 输出的加速意图隶属度函数曲线如图5(c)所示. 加速意图识别的模糊规则如表1.




(a) 加速踏板开度隶属度函数




(b) 加速踏板开度变化率隶属度函数



(b) 制动踏板开度变化率隶属度函数



(c) 加速意图隶属度函数



(c) 制动意图隶属度函数

图 5 加速意图识别隶属度函数曲线

图 6 制动意图识别隶属度函数曲线

Fig. 5 Membership functions of acceleration intention

Fig. 6 Membership functions of braking intention

表 1 加速意图识别模糊规则表

Table 1 The fuzzy rules for the acceleration intention recognition


踏板开度	踏板开度变化率				
	负大	负小	小	中	大
小	平缓	平缓	较平缓	较平缓	一般
较小	平缓	较平缓	较平缓	一般	较紧急
中	较平缓	一般	一般	较紧急	紧急
较大	较平缓	一般	较紧急	较紧急	紧急
大	一般	一般	较紧急	紧急	紧急

表 2 制动意图识别模糊规则表

Table 2 The fuzzy rules for the braking intention recognition

踏板开度	踏板开度变化率				
	负大	负小	小	中	大
小	平缓	平缓	较平缓	较平缓	一般
较小	平缓	较平缓	较平缓	一般	一般
中	较平缓	较平缓	一般	一般	较紧急
较大	较平缓	一般	较紧急	较紧急	紧急
大	一般	一般	较紧急	紧急	紧急

制动意图的识别参数确定为制动踏板开度和制动踏板开度变化率, 运用模糊推理进行驾驶意图识别, 其隶属度函数曲线分别如图6(a)和图6(b)所示. 输出的制动意图隶属度函数曲线如图6(c)所示. 制动意图识别的模糊规则如表2所示.



(a) 制动踏板开度隶属度函数

以伦敦市公交线路经典行驶工况为例, 对该工况进行驾驶意图识别. 加速意图识别结果范围在(0, 1)内, 其值越接近1代表其加速意图越强烈, 制动意图识别结果范围在(-1, 0)内, 其值越接近-1代表其制动意图越强烈. 加速踏板和制动踏板均无操作时, 默认为滑行制动, 其意图识别结果为0. 这样取值可保证其驾驶意图与车速轨迹一致, 是在时间上连续的序列, 且能区别每一时刻是加速意图还是制动意图以及其意图的紧急程度, 以方便作为NAR神经网络的输入. 并以加速度衡量驾驶意图强度, 将根据车速求得的加速度按不同的意图分类归一化至(-1, 1)区间, 以验证意图识别的准确性. 图7为该工况局部车速片段, 图8为其模糊识别的驾驶意图与驾驶意图强度对比图, 可见一致的变化趋势, 能够有效识别驾驶员的驾驶意图.




图7 伦敦公交工况运行片段

Fig. 7 The speed segment of UKBUS driving cycle




图8 驾驶意图识别结果对比

Fig. 8 The driving intention recognition result comparison

3.2 NAR神经网络车速预测(Vehicle speed prediction using NAR neural network)

基于车速轨迹本身具有的复杂非线性及时间序列特征, 本文采用NAR动态神经网络用于车速预测, 并充分考虑驾驶员操作的影响, 引入基于模糊推理识别的驾驶意图时间序列这一能够反映车速未来变化趋势的因素与车速共同作为输入.

NAR预测模型如式(9)所示:

$$y(t+1) = f(y(t), y(t-1), \dots, y(t-d_y+1)), \quad (9)$$

式中 $y(t) = \begin{bmatrix} v(t) \\ h(t) \end{bmatrix}$, 其中: $v(t)$ 和 $h(t)$ 分别为 t 时刻的车速和驾驶意图, f 是网络非线性函数, d_y 为网络输出延迟时长. 下一时刻的预测输出 $y(t+1)$ 取决于前 d_y 个时刻的输出. 对于 t 时刻的车速预测, 首先通过当前时刻 t 及前 d_y-1 个时刻的车速及驾驶意图识别结果作为网络输入, 求出 $t+1$ 时刻的预测车速及驾驶意图 $y(t+1)$. 然后, NAR神经网络预测模型将预测输出反馈作为输入, 即将预测得到的 $y(t+1)$ 反馈到输入端与 $y(t), y(t-1), \dots, y(t-d_y+2)$ 共同作为预测模型输入, 通过式(9)再求出 $y(t+2)$, 从而可实现多步滚动预测, 直至求出预测时域 N 内的所有输出 $y(t+1), \dots, y(t+N)$.

本文采用的NAR神经网络结构如图9所示. 包括一个隐含层, 一个输出层和一个输出反馈, 从而使神经网络闭合, 形成一个周期性循环的动态网络. 其中

隐含层神经元个数为15个, 输出层神经元个数为1个, 输出反馈时延阶数为5.




图9 NAR神经网络结构图

Fig. 9 NAR neural network structure

本文采用贝叶斯归一化法对网络进行训练, 使网络具有较强的泛化能力. 隐含层激活函数选择双曲正切函数, 输出层选择purelin线性函数.

以伦敦市公交线路经典行驶工况为例, 使用前述驾驶意图识别方法得到与该工况相对应的驾驶意图时间序列. 共3288组车速-意图数据, 每组时间间隔为1 s, 选取前2788组车速-意图数据作为网络训练样本数据, 剩余500组数据用于网络检验分析.

本文采用网络的预测值与真实值的均方根误差 (root mean square error, RMSE)来表征网络预测的准确性, RMSE的值越小, 预测准确性越高. 图10为选用的500组车速预测数据的预测值与实际值的对比图及误差分析图, 可以看出误差均分布在 $[-2.5, 2.5]$ km/h区间内, 单步预测效果良好. 在此基础上, 将预测时长逐步提高至50 s, 表3给出了预测的500组数据在1 s~50 s不同预测时长的RMSE的值, 从中可以看出, 随着预测时长的提高, 预测误差逐渐加大.




图10 单步预测误差图

Fig. 10 Error of single-step prediction

表3 不同预测时长的车速均方根误差

Table 3 RMSE results of vehicle speed under different prediction horizon

预测时长/s	1	2	5	10
RMSE	0.6416	1.126	2.8917	5.631
预测时长/s	20	30	40	50
RMSE	9.0878	10.9024	12.0005	12.6537

4 混合逻辑动态模型预测控制策略 (Mixed logical dynamical model predictive control (MLD-MPC) strategy)

4.1 混合逻辑动态模型预测控制建模 (Modeling of MLD-MPC)

通过前一节所述的方法预测当前时刻之后一段时间内的车速, 可计算车辆相应时刻的总体需求转矩, 则在该预测时域内的转矩分配问题即可描述成为以电机转矩为控制变量, 时域内等效燃油消耗最小为目标的模型预测控制优化问题. 本文基于MLD标准模型^[22], 建立插电式混合动力公交车控制策略的状态转移方程和评价指标方程, 如式(10)所示:

$$\begin{cases} x(k+1) = x(k) + \mathbf{B}_1 \boldsymbol{\delta}(k) + \mathbf{B}_2 \mathbf{z}(k), \\ y(k) = \mathbf{D}_1 \boldsymbol{\delta}(k) + \mathbf{D}_2 \mathbf{z}(k), \end{cases} \quad (10)$$

式中:

$$\begin{aligned} \mathbf{B}_1 &= [b_0(k), 0, b_0(k), b_0(k), b_0(k), 0], \\ \mathbf{B}_2 &= [b_1(k), 0, b_1(k), b_1(k), b_1(k), 0], \\ \mathbf{D}_1 &= [-\lambda U_0 b_0(k) \frac{Q_{\max}}{R}, a_0(k) + a_1(k) T_{\text{in}}(k), \\ &\quad -\lambda U_0 b_0(k) \frac{Q_{\max}}{R} + a_0(k) + a_1(k) T_{\text{in}}(k), \\ &\quad -\lambda U_0 b_0(k) \frac{Q_{\max}}{R} + a_0(k) + a_1(k) T_{\text{in}}(k), 0, 0], \\ \mathbf{D}_2 &= [-\lambda U_1 b_0(k) \frac{Q_{\max}}{R}, 0, -\lambda U_0 b_1(k) \frac{Q_{\max}}{R} - \\ &\quad i_t a_1(k), -\lambda U_0 b_1(k) \frac{Q_{\max}}{R} - i_t a_1(k), \\ &\quad -\lambda U_0 b_1(k) \frac{Q_{\max}}{R}, 0], \end{aligned}$$

其中: $x(k)$ 为 k 时刻电池的荷电状态SOC的值; $y(k)$ 为 k 时刻等效燃油消耗率; $\boldsymbol{\delta}(k)$ 为 k 时刻的工作模式矩阵, 是一个 6×1 的矩阵逻辑变量, 每个分量只能取0或1且分量和为1; $\mathbf{z}(k)$ 为辅助变量, 定义 $\mathbf{z}(k) = \boldsymbol{\delta}(k) \cdot u(k)$, 其中 $u(k)$ 为控制变量, 文中为电机转矩, 将其转化为如式(11)中线性不等式约束的形式, a_0, a_1, b_0, b_1 同式(4)和式(8), i_t 为发动机和电机间连接的转矩耦合器的传动比.

$$\begin{cases} -T_M \boldsymbol{\delta}(k) + \mathbf{z}(k) \leq 0, \\ -T_M \boldsymbol{\delta}(k) - \mathbf{z}(k) \leq 0, \\ T_M \boldsymbol{\delta}(k) + \mathbf{z}(k) - u(k) \leq T_M, \\ T_M \boldsymbol{\delta}(k) - \mathbf{z}(k) + u(k) \leq T_M. \end{cases} \quad (11)$$

建立城市公交车的6种工作模式的约束方程, 包括: 1) 纯电动模式:

$$\begin{aligned} T_{\max} \delta_1 &\leq T_{\max} + T_{\text{in}} - \varepsilon, \\ T_{\max} \delta_1 &\leq T_{\max} - T_{\text{in}} + i_t T_{\text{m.max}}, \\ -T_{\text{in}} \delta_1 + i_t z_1 &\leq 0, T_{\text{in}} \delta_1 - i_t z_1 \leq 0; \end{aligned}$$

2) 油动模式:

$$\begin{aligned} T_{\max} \delta_2 &\leq T_{\max} + T_{\text{in}} - \varepsilon, z_2 \leq 0, \\ T_{\max} \delta_2 &\leq T_{\max} - T_{\text{in}} + T_{\text{e.max}}, -z_2 \leq 0; \end{aligned}$$

3) 油电混动模式:

$$\begin{aligned} T_{\max} \delta_3 &\leq -i_t u + T_{\max} + T_{\text{in}} - \varepsilon, \\ T_{\max} \delta_3 &\leq i_t u + T_{\max} - T_{\text{in}} + T_{\text{e.max}}, \\ T_M \delta_3 &\leq -u + T_M + T_{\text{m.max}}, \\ T_M \delta_3 &\leq -u + T_M - \varepsilon; \end{aligned}$$

4) 行车充电模式:

$$\begin{aligned} T_{\max} \delta_4 &\leq -i_t u + T_{\max} + T_{\text{in}} - \varepsilon, \\ T_{\max} \delta_4 &\leq i_t u + T_{\max} - T_{\text{in}} + T_{\text{e.max}}, \\ T_M \delta_4 &\leq u + T_M + T_{\text{m.max}}, \\ T_M \delta_4 &\leq -u + T_M - \varepsilon; \end{aligned}$$

5) 制动回收模式:

$$\begin{aligned} T_{\max} \delta_5 &\leq T_{\max} - T_{\text{in}} - \varepsilon, \\ -T_{\text{dec.max}} \delta_5 + z_5 &\leq 0, T_{\text{dec.max}} \delta_5 - z_5 \leq 0; \end{aligned}$$

6) 停车模式:

$$T_{\text{in}} \delta_6 \leq 0, -T_{\text{in}} \delta_6 \leq 0, z_6 \leq 0, -z_6 \leq 0.$$

其中: T_M 为电动机转矩最大值, T_{\max} 为最大需求转矩, $T_{\text{e.max}}$ 为当前时刻发动机最大转矩, $T_{\text{m.max}}$ 为当前时刻电动机最大转矩, $T_{\text{dec.max}}$ 为当前最大制动转矩, 其值为 $\max(T_{\text{in}}/i_t, -T_{\text{m.max}})$, ε 为机器精度, 选取 $\varepsilon = 0.0001$, T_{in} 为当前时刻的需求转矩(其通过将第3章中神经网络的预测车速, 代入车辆动力学公式(1)-(2)中计算获得), δ_i 当前第 i 个工作模式的选取(激活)状态, 其值为1表示激活, 其值为0表示未激活.

将式(11)所示辅助变量及以上6种工作模式不等式约束引入时间序列 k , 统一为矩阵不等式:

$$\mathbf{E}_1 \boldsymbol{\delta}(k) + \mathbf{E}_2 \mathbf{z}(k) \leq \mathbf{E}_3 u(k) + \mathbf{E}_4. \quad (12)$$

将基于滚动优化的预测控制理论应用于该MLD模型, 建立优化模型如式(13)-(14)所示:

$$\begin{aligned} \min_{\{u_k^k, u_k^{k+1}, u_k^{k+2}, \dots, u_k^{k+N}\}} J &= \sum_{i=0}^N y(k+i), \quad (13) \\ \text{s.t.} \begin{cases} x_{\min}(k) \leq x(k) \leq x_{\max}(k), \\ x(k+1) = x(k) + \mathbf{B}_1 \boldsymbol{\delta}(k) + \mathbf{B}_2 \mathbf{z}(k), \\ y(k) = \mathbf{D}_1 \boldsymbol{\delta}(k) + \mathbf{D}_2 \mathbf{z}(k), \\ \mathbf{E}_1 \boldsymbol{\delta}(k) + \mathbf{E}_2 \mathbf{z}(k) \leq \mathbf{E}_3 u(k) + \mathbf{E}_4, \end{cases} \quad (14) \end{aligned}$$

其中: N 为预测时域长度; $\mathbf{E}_1, \mathbf{E}_2, \mathbf{E}_3, \mathbf{E}_4$ 如下式所示, $x_{\min}(k)$ 和 $x_{\max}(k)$ 分别为 k 时刻SOC可达域的上、下限. 在每一采样时刻 k , 代入矩阵 $\mathbf{B}_1, \mathbf{B}_2, \mathbf{D}_1, \mathbf{D}_2, \mathbf{E}_1, \mathbf{E}_2, \mathbf{E}_3$ 和 \mathbf{E}_4 的值, 基于最小等效燃油消耗目标函数, 式(13)-(14)即转化为混合整数线性规划(mixed integer linear programming, MILP)^[23]问题.

$$\mathbf{E}_1 = \begin{bmatrix} T_{\max} & 0 & 0 & 0 & 0 & 0 \\ T_{\max} & 0 & 0 & 0 & 0 & 0 \\ -T_{\text{in}} & 0 & 0 & 0 & 0 & 0 \\ T_{\text{in}} & 0 & 0 & 0 & 0 & 0 \\ 0 & T_{\max} & 0 & 0 & 0 & 0 \\ 0 & T_{\max} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & T_{\max} & 0 & 0 & 0 \\ 0 & 0 & T_{\max} & 0 & 0 & 0 \\ 0 & 0 & T_{\text{M}} & 0 & 0 & 0 \\ 0 & 0 & T_{\text{M}} & 0 & 0 & 0 \\ 0 & 0 & 0 & T_{\max} & 0 & 0 \\ 0 & 0 & 0 & T_{\max} & 0 & 0 \\ 0 & 0 & 0 & T_{\text{M}} & 0 & 0 \\ 0 & 0 & 0 & T_{\text{M}} & 0 & 0 \\ 0 & 0 & 0 & 0 & T_{\max} & 0 \\ 0 & 0 & 0 & 0 & -T_{\text{dec.max}} & 0 \\ 0 & 0 & 0 & 0 & T_{\text{dec.max}} & 0 \\ 0 & 0 & 0 & 0 & 0 & T_{\text{in}} \\ 0 & 0 & 0 & 0 & 0 & -T_{\text{in}} \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ -T_{\text{M}} & -T_{\text{M}} & -T_{\text{M}} & -T_{\text{M}} & -T_{\text{M}} & -T_{\text{M}} \\ -T_{\text{M}} & -T_{\text{M}} & -T_{\text{M}} & -T_{\text{M}} & -T_{\text{M}} & -T_{\text{M}} \\ T_{\text{M}} & T_{\text{M}} & T_{\text{M}} & T_{\text{M}} & T_{\text{M}} & T_{\text{M}} \\ T_{\text{M}} & T_{\text{M}} & T_{\text{M}} & T_{\text{M}} & T_{\text{M}} & T_{\text{M}} \end{bmatrix}, \mathbf{E}_3 = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ -i_t \\ i_t \\ 1 \\ -1 \\ -i_t \\ i_t \\ 1 \\ -1 \\ 0 \\ 1 \\ -1 \end{bmatrix}, \quad (15)$$

$$\mathbf{E}_2 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ i_t & 0 & 0 & 0 & 0 & 0 \\ -i_t & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & -1 \\ 1 & 1 & 1 & 1 & 1 & 1 \\ -1 & -1 & -1 & -1 & -1 & -1 \\ 1 & 1 & 1 & 1 & 1 & 1 \\ -1 & -1 & -1 & -1 & -1 & -1 \end{bmatrix}, \mathbf{E}_4 = \begin{bmatrix} T_{\max} + T_{\text{in}} - \varepsilon \\ T_{\max} - T_{\text{in}} + i_t T_{\text{m.max}} \\ 0 \\ 0 \\ T_{\max} + T_{\text{in}} - \varepsilon \\ T_{\max} - T_{\text{in}} + T_{\text{e.max}} \\ 0 \\ 0 \\ T_{\max} + T_{\text{in}} - \varepsilon \\ T_{\max} - T_{\text{in}} + T_{\text{e.max}} \\ T_{\text{M}} - \varepsilon \\ T_{\text{M}} + T_{\text{m.max}} \\ T_{\max} + T_{\text{in}} - \varepsilon \\ T_{\max} - T_{\text{in}} + T_{\text{e.max}} \\ T_{\text{M}} + T_{\text{m.max}} \\ T_{\text{M}} - \varepsilon \\ T_{\max} - T_{\text{in}} - \varepsilon \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ T_{\text{M}} \\ T_{\text{M}} \end{bmatrix}. \quad (16)$$

4.2 MILP问题求解(Solution of MILP)

上述MILP问题采用MATLAB平台下YALMIP工具箱进行建模并用Gurobi优化器求解,进而计算出未来一段控制时域内的控制输入(电机转矩)序列,并将该控制输入序列的首值施加至被控对象;在 $k+1$ 时刻,使用新的车速预测轨迹和SOC状态在下一控制时域内重复上述优化步骤,便可实现基于滚动优化思想的PHEV模型预测控制.其中对于模型状态变量电池SOC的更新过程中,采用式(7)所示简化前的原始非线性模型代替MILP中的线性等式约束模型,将当前时刻计算的电机转矩输入至该模型,估计出在控制作用结束时的SOC终值,并以此作为下一滚动优化的初始状态值,从而实现预测控制的反馈校正功能.

由于本文选用的PHEV共有6种工作模式,需要求解带有6个逻辑变量的辅助变量 $z(k)$,其组成了共27个不等式约束,计算量较大,且容易导致部分计算不收敛,影响控制策略的实时性.同时,考虑到城市公交车的运行工况中部分工作模式切换较为明显,模式切换及转矩分配的定性知识和专家经验将能够良好的发挥作用.因此,本文引入启发式算法,缩小辅助变量及控制变量的搜索范围,从而优化MILP的求解速度.

启发式算法的逻辑规则如下:

$$\begin{cases} T_{in} = 0, & \delta_6 = 1, u = 0, \\ T_{in} < 0, & \delta_5 = 1, u = \frac{T_{in}}{i_t}, \\ x < x_{min}, & \delta_4 = 1, u = \frac{T_{in} - T_{e,max}}{i_t}, \\ T_{in} > T_{e,max}, & \delta_3 = 1, u > 0, \\ & 0 < T_{in} - i_t u < T_{e,max}, \end{cases} \quad (17)$$

否则

$$\begin{cases} \delta_1 = 1, u = \frac{T_{in}}{i_t}, \\ \delta_2 = 1, u = 0, \\ \delta_3 = 1, u > 0, 0 < T_{in} - i_t u < T_{e,max}, \\ \delta_4 = 1, u < 0, 0 < T_{in} - i_t u < T_{e,max}. \end{cases} \quad (18)$$

当车辆处于停车和制动状态时,可通过总需求转矩是否小于或等于零进行判断,并直接进入停车和再生制动模式,对应的控制变量值亦可直接确定.当车辆紧急加速或高速行驶时,总需求转矩较大,当其超过发动机当前转速下的最大转矩时,可直接进入油电混动模式;当车辆处于平缓加速和巡航行驶

时,总转矩需求处于中小水平,控制策略应将车辆控制在纯电动模式、油动模式、油电混动模式和行车充电模式4种状态下切换,其中纯电动模式和油电混动模式下的控制变量解可直接求出,油电混动和行车充电模式下可通过优化目标函数,选择预测时域内最优的控制变量序列.这些启发规则,可显著缩小MILP的求解搜索空间,进而提高算法效率.

与传统HEV不同,PHEV通常存在CD(能量消耗)和CS(能量维持)两种阶段,CD阶段不需要对电池SOC进行电量平衡维持,因此在MLD-MPC控制策略中通过设置SOC的下限让电池自由地充放电,而在CS阶段,需要将SOC维持在下限最低值附近,此时,MLD-MPC策略中在不修改目标函数的前提下,一旦出现需求扭矩较大,超过发动机的最大扭矩时,必须用电机电动助力,SOC即会越界,此时的MILP问题约束被破坏,会出现无解的情况.因此,在SOC下限值附近,首先通过对发动机进行最大扭矩输出,估算预测窗口内每一秒的最高SOC可达值,当SOC可达值大于SOC下限,不会发生越界时,施加当前时刻的SOC约束,否则去除该项约束以进行求解.当电池SOC低于SOC下限时,停止MILP问题求解,直接进入启发模式,计算发动机最大扭矩输出情况下,电机的最大充电转矩(或最小放电转矩),直至SOC上升到比下限值的高处一定值后,重新进入MILP问题求解.

4.3 预测时长对MLD-MPC策略的影响分析(Influence of prediction horizon for MLD-MPC strategy)

本文基于MLD的模型预测控制策略中,包含以下两个关键步骤:基于驾驶意图分析的NAR神经网络车速预测和基于最小燃油消耗目标函数的MLD模型预测控制.前者随着预测时长的增加,预测结果相对于真实车速数据的准确性随之降低,继而影响后者求解的准确性,使最终的燃油经济性变差;而后者运用有限时域的在线滚动优化,随着优化时域的增加,其优化性能指标即目标函数最优解的效果随之更优.此外,预测时长对模型单步计算时间也有较大影响.因此,需要权衡燃油经济性与计算时间,确定合适的预测时长.

以NEDC工况为例,研究预测时长对目标等效燃油消耗的影响.由于当电池SOC值未下降至最低值的情况下,预测窗口内各秒间的状态关联SOC约束起不到作用,相当于各秒独立求解,无法体现预测窗口的作用.因此选用SOC初始值为0.7的情况下,设置SOC下限值为0.67,模拟CS-CD切换阶段,SOC越界后进入启发模式将电池充电至0.68后重新进入MILP求解模式.

不同预测时长对应的电池SOC变化曲线如图11所示,其对应的SOC触底时间如表4,可以看出随着预测时长的增加, SOC触底的时间得到延迟,说明MILP在优化求解过程中,随着预测窗口的增加,能够提前预知到SOC即将到达下界,进入能量消耗较高的CS电量维持阶段,从而提前合理保存电量,提高燃油经济性,对应的不同预测时长求解的等效百公里油耗如图12所示。




图 11 不同预测时长的电池SOC变化曲线

Fig. 11 Battery SOC curve under different prediction horizon

表4 不同预测时长SOC触底时间

Table 4 SOC bottoming time under different prediction horizon

SOC触底时间 预测窗口/s	SOC触底时间	
	第1次	第2次
1	643	847
5	643	849
10	650	851
15	650	976
20	651	976
25	651	976
30	675	1040




图 12 等效燃油消耗与预测时长的变化关系

Fig. 12 Equivalent oil consumption under different prediction horizon

从图12可知,随着预测时长的增加,MLD-MPC控制策略的等效燃油消耗不断降低,预测时长在

10 s~15 s时,油耗降低最为明显,15 s后增加至30 s油耗提升不明显.而另一方面,车速预测均方根误差(RMSE)随着预测时长的变化关系如图13所示,可以看出,车速预测均方根误差随着预测时长的增加持续升高,这也将对控制策略的效果产生影响,导致15 s预测时长后节油效果提升并不明显.在基于普通计算机的MATLAB仿真环境下,算法单步计算时间与预测时长的变化关系如图14所示.本文的车速采样步长为1 s,车速预测及模型预测控制的计算步长也为1 s,单步计算时间随着预测时长增长较快,在15 s内的预测时长内单步计算时间均在0.5 s以内,能够满足控制需求.综合考虑预测时长变化时对燃油消耗、车速预测误差和单步计算时间的影响,认为预测时长在10 s~15 s内较为合理,可根据实车及行驶工况进一步调整,本文在仿真实验中选择了15 s的预测时长。




图 13 车速预测均方根误差与预测时长的变化关系

Fig. 13 RMSE under different prediction horizon




图 14 单步计算时间与预测时长的变化关系

Fig. 14 Single step calculation time under different prediction horizon

5 仿真试验(Simulation experiments)

本文选用的PHEV主要参数为:整车整备质量10636 kg,满载质量13485 kg,轴距6.85 m,迎风面积7.24 m²,滚阻系数0.0094,车轮半径0.5 m,主减速比1,空气阻力系数0.79.在动力传动系统方面,发动机为柴油发动机,排量7.3 L,峰值功率177 kW,最

高转速2300 r/min. 电机为交流感应电机, 峰值功率124 kW, 最高转速10000 r/min. 动力电池为锂电池, 额定容量90A·h. 发动机和电机转动惯量之和 $I_f = 2.2511$, 全部车轮的转动惯量 $I_w = 20.5215$.

为了便于分析车速预测精度和对比衡量本文提出的控制策略, 选用ADVISOR下伦敦公交工况UKBUS(图15)作为计算工况, 其为模态工况, 但在MLD-MPC控制策略中, 在当前时刻 t_0 仿真计算时仅使用 t_0 及 t_0 以前的车速数据用于车速预测, 通过神经网络预测当前时刻之后一段预测时域内的车速序列, 并转换为总转矩需求序列, 用于当前时刻 t_0 的模型预测控制. 蓄电池SOC初始值为0.7, SOC上限为0.8, 下限为0.15, 燃油等效因子为1.629, 选取预测时长为15 s进行仿真. 图16为MLD-MPC策略求解的各种工作模式时间占比图, 从图中可以看出电机的电动模式(纯电动、油电混动)工作状态相比纯发动机模式和发电模式(行车充电、制动回收)较多, 且发电模式主要以制动能量回收为主, 这是由于初始SOC处于高水平状态, 系统处于电量消耗阶段, 电池有良好的放电时机, 电动模式较多, 仅在功率需求较大时才启动发动机, 以使电池电能被充分利用, 提升燃油经济性.




图 15 伦敦公交循环工况
Fig. 15 UKBUS driving cycle






图 16 工作模式时间占比图
Fig. 16 Time proportion of each operation mode

图17(a)为MLD-MPC策略与电动助力控制策略^[24]的电池SOC变化对比曲线, 图17(b)为燃油消耗量的对比曲线, 直至整个循环工况结束MLD-MPC控制策略下PHEV的油耗为1.9467 L, SOC最

终值为0.5164, 而电动助力控制策略的最终油耗为2.404 L, SOC最终值为0.5145, 将电量消耗折算为等效燃油消耗后求得MLD-MPC策略的燃油消耗率降低了9.45%, 在该行驶工况下MLD-MPC控制策略下的PHEV在节省燃油消耗的同时又维持了较高水平的电池电量, 具有更高的燃油经济性. 此外, 本文还分别在Orange County公交工况OCC和新欧洲工况NEDC下分别对MLD-MPC策略进行仿真, 其结果对比如表5所示, 可见其均有效提升了PHEV的燃油经济性.



(a) 电池SOC曲线对比



(b) 燃料消耗曲线对比

图 17 两种控制策略仿真结果对比

Fig. 17 Simulation results comparison of two strategies

表 5 两种控制策略下的等效燃油消耗量对比
Table 5 Equivalent fuel consumption comparison under two control strategies

行驶工况	MLD-MPC/L	电动助力/L	等效燃油消耗降低/%
UKBUS	4.65	5.14	9.45
8 × OCC	24.14	27.38	11.82
8 × NEDC	20.01	22.65	11.66

6 结论(Conclusions)

本文针对PHEV, 建立了一种基于车速预测的混合逻辑动态模型预测控制策略. 首先, 对发动机和电动机能量消耗模型进行线性化, 建立了PHEV的能量消耗计算数学模型. 其次, 充分考虑驾驶员对车速变化趋势的影响, 提出基于驾驶员意图模糊分析和历史车速数据相结合的非线性自回归神经网络车

速预测方法进行未来行驶工况预测并进行需求转矩的转化。然后,以等效燃油消耗为目标函数,综合考虑系统的状态变量连续约束和各工作模式下变量范围约束,建立了PHEV的MLD模型。结合预测控制滚动优化的思想,将转矩分配转化为混合整数线性规划问题,并通过引入启发式算法提高了运算效率,求解获得了关于各时刻工作模式选择和电机转矩大小的最优解,并分析了预测时长的选取对控制策略的影响。最后,在3种工况下进行仿真实验,实验结果验证了本文中提出的方法在特定的循环工况下与电动助力策略相比,能够提升燃油经济性。

参考文献(References):

- [1] WIRASINGHA S G, EMADI A. Classification and Review of Control strategies for plug-in hybrid electric vehicles [J]. *IEEE Transactions on Vehicular Technology*, 2011, 60(1): 111 – 122.
- [2] PADMARAJAN B, MCGORDON A, JENNINGS P. Blended rule based energy management for PHEV: system structure and strategy [J]. *IEEE Transactions on Vehicular Technology*, 2016, 65(10): 8757 – 8762.
- [3] WU L, WANG Y, YUAN X, et al. Multiobjective optimization of HEV fuel economy and emissions using the self-adaptive differential evolution algorithm [J]. *IEEE Transactions on Vehicular Technology*, 2011, 60(6): 2458 – 2470.
- [4] XIA Chaoying, ZHANG Cong. Real-time optimization control for hybrid electric vehicles based on quadratic performance index [J]. *Control Theory & Applications*, 2014, 31(5): 601 – 606.
(夏超英, 张聪. 基于二次型性能指标的混合动力汽车实时优化控制 [J]. *控制理论与应用*, 2014, 31(5): 601 – 606.)
- [5] SIVERTSSON M. Adaptive control using map-based ECMS for a PHEV [J]. *IFAC Proceedings Volumes*, 2012, 45(30): 357 – 362.
- [6] OVERINGTON S, RAJAKARUNA S. Review of PHEV and HEV operation and control research for future direction [C] // *The 2012 3rd IEEE International Symposium on Power Electronics for Distributed Generation Systems (PEDG)*. Aalborg: IEEE, 2012: 385 – 392.
- [7] SHEN Caiying, XIA Chaoying. Control strategy of series hybrid electric vehicle based on improved dynamic programming [J]. *Control Theory & Applications*, 2010, 28(3): 427 – 432.
(申彩英, 夏超英. 基于改进型动态规划算法的串联混合动力汽车控制策略 [J]. *控制理论与应用*, 2010, 28(3): 427 – 432.)
- [8] LEFEVRE S, SUN C, BAJCSY R, et al. Comparison of parametric and non-parametric approaches for vehicle speed prediction [C] // *2014 American Control Conference*. Portland: IEEE, 2014: 3494 – 3499.
- [9] CHAN K Y, DILLON T S, JAIPAL S, et al. Neural-network-based models for short-term traffic flow forecasting using a hybrid exponential smoothing and levenberg — marquardt algorithm [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2012, 13(2): 644 – 654.
- [10] HODGSON D, MECROW B C, GADOUE S M, et al. Effect of vehicle mass changes on the accuracy of Kalman filter estimation of electric vehicle speed [J]. *Let Electrical Systems in Transportation*, 2013, 3(3): 67 – 78.
- [11] WU J, CUI Z M, ZHAO P P, et al. Traffic vehicle behavior prediction using hidden markov models [C] // *Proceedings of International Conference on Artificial Intelligence and Computational Intelligence*. Berlin: Springer, 2010: 383 – 390.
- [12] LIN H. An artificial neural network model for data prediction [J]. *Advanced Materials Research*, 2014, 971(973): 1521 – 1524.
- [13] BENMOUIZA K, CHEKNANE A. Forecasting hourly global solar radiation using hybrid k-means and nonlinear auto regressive neural network models [J]. *Energy Conversion and Management*, 2013, 75(5): 561 – 569.
- [14] PARK J, LI D, MURPHEY Y L, et al. Real time vehicle speed prediction using a neural network traffic model [C] // *International Joint Conference on Neural Networks*. California: IEEE, 2011: 2991 – 2996.
- [15] RASYIDI M A, RYU K R. Short-term speed prediction on urban highways by ensemble learning with feature subset selection [C] // *International Conference on Database Systems for Advanced Applications*. Berlin: Springer, 2014: 46 – 60.
- [16] PARK S, YU Y, MOON S, et al. A short-Term vehicle speed prediction using bayesian network based selective data learning [J]. *Journal of the Korea Institute of Information and Communication Engineering*, 2015, 19(12): 2779 – 2784.
- [17] GOEBEL R, SANFELICE R G, TEEL A. Hybrid dynamical systems [J]. *IEEE Control Systems*, 2009, 29(2): 28 – 93.
- [18] NANDOLA N N, RIVERA D E. An improved formulation of hybrid model predictive control with application to production-inventory systems [J]. *IEEE Transactions on Control Systems Technology*, 2013, 21(1): 121 – 135.
- [19] WANG Y, SUN Z. Dynamic analysis and multivariable transient control of the power-split hybrid powertrain [J]. *IEEE/ASME Transactions on Mechatronics*, 2015, 20(6): 3085 – 3097.
- [20] GB/T19753–2005. Test methods for energy consumption of light-duty hybrid electric vehicles [S]. Beijing: Standards Press of China, 2005.
(GB/T19753–2005. 轻型混合动力电动汽车能量消耗量试验方法 [S]. 北京: 中国标准出版社, 2005.)
- [21] BOVA S, CODARA P, MACCARI D, et al. A logical analysis of mamdani-type fuzzy inference, I theoretical bases [C] // *2010 IEEE International Conference on Fuzzy Systems*. Barcelona: IEEE, 2010: 1 – 8.
- [22] REN H P, ZHENG M M, LI J. A simplified mixed logical dynamic model and model predictive control of boost converter with current reference compensator [C] // *The 24th IEEE International Symposium on Industrial Electronics*. Rio de Janeiro: IEEE, 2015: 61 – 65.
- [23] RUEDA-MEDINA A C, FRANCO J F, RIDER M J, et al. A mixed-integer linear programming approach for optimal type, size and allocation of distributed generation in radial distribution systems [J]. *Electric Power Systems Research*, 2013, 97(1): 133 – 143.
- [24] MARKEL T, BROOKER A, HENDRICKS T, et al. Advisor: a systems analysis tool for advanced vehicle modeling [J]. *Journal of Power Sources*, 2002, 110(2): 255 – 266.

作者简介:

连 静 (1980–), 女, 副教授, 硕士生导师, 主要研究方向为汽车电子与控制, E-mail: lianjing80@126.com;

刘 爽 (1992–), 女, 硕士研究生, 主要研究方向为插电式混合动力汽车控制策略, E-mail: liushuangdlut@163.com;

李琳辉 (1981–), 男, 副教授, 硕士生导师, 主要研究方向为汽车电子与控制, E-mail: dlutlilinhui@126.com;

周雅夫 (1962–), 男, 教授, 博士生导师, 主要研究方向为新能源汽车, E-mail: dlzyf62@126.com;

杨 帆 (1992–), 男, 硕士研究生, 主要研究方向为新能源汽车控制策略, E-mail: yangfandlut@126.com;

袁鲁山 (1990–), 男, 硕士研究生, 主要研究方向为智能车辆, E-mail: yuanlushandlut@126.com.