

DOI:10.3969/j.issn.1003-5060.2025.02.005

# 考虑车流密度的混合动力汽车能量管理策略研究

吴迪<sup>1</sup>, 张栋<sup>1</sup>, 郭鸣明<sup>1</sup>, 赵韩<sup>2</sup>, 张冰战<sup>1</sup>, 邱明明<sup>2</sup>

(1. 合肥工业大学汽车与交通工程学院, 安徽合肥 230009; 2. 合肥工业大学机械工程学院, 安徽合肥 230009)

**摘要:**文章考虑车流密度对车速预测的影响, 基于仿真实验平台采集不同车流密度下的行驶数据, 建立考虑车流密度的多马尔可夫矩阵车速预测模型; 以整车燃油经济性和电池荷电状态(state of charge, SOC)平衡为优化目标, 提出基于模型预测控制(model predictive control, MPC)的混合动力汽车能量管理策略, 并在 MATLAB/Simulink 中搭建控制策略模型; 基于 CRUISE 软件搭建整车动力学仿真模型, 并与 MATLAB/Simulink 进行联合仿真。结果表明, 考虑车流密度的 MPC 能量管理策略使得整车燃油经济性有明显提高, 相较于不考虑车流密度的能量管理策略提高 6.33%。该方法对于其他混合动力汽车的能量管理策略设计有一定的参考意义。

**关键词:**车流密度; 马尔可夫模型; 工况识别; 能量管理; 模型预测控制(MPC)

**中图分类号:**U469.722 **文献标志码:**A **文章编号:**1003-5060(2025)02-0170-09

## Research on energy management strategy of hybrid electric vehicle considering traffic density

WU Di<sup>1</sup>, ZHANG Dong<sup>1</sup>, GUO Mingming<sup>1</sup>, ZHAO Han<sup>2</sup>, ZHANG Bingzhan<sup>1</sup>, QIU Mingming<sup>2</sup>

(1. School of Automobile and Traffic Engineering, Hefei University of Technology, Hefei 230009, China; 2. School of Mechanical Engineering, Hefei University of Technology, Hefei 230009, China)

**Abstract:** In this paper, the influence of traffic density on vehicle speed prediction was considered. Based on the simulation experimental platform, the driving data under different traffic densities were collected and a multi-Markov matrix vehicle speed prediction model considering the traffic density was established. The vehicle fuel economy and the state of charge(SOC) balance of the battery were taken into account as the optimization object. A hybrid electric vehicle energy management strategy based on model predictive control(MPC) was proposed, and the control strategy model was built in MATLAB/Simulink. The vehicle dynamics simulation model was built based on CRUISE software, and the co-simulation with MATLAB/Simulink was carried out. The results show that the MPC-based energy management strategy considering the traffic density improves the fuel economy significantly, which is 6.33% higher than that under the energy management strategy without considering the traffic density. This method has certain reference significance for the energy management strategy design of other hybrid electric vehicles.

**Key words:** traffic density; Markov model; driving cycle identification; energy management; model predictive control(MPC)

混合动力车辆是目前解决车辆能源消耗过度和空气污染的有效途径之一<sup>[1]</sup>, 能量管理策略是

混合动力汽车的核心技术, 通过制定科学合理的能量管理策略, 可极大程度上提高整车的燃油经

收稿日期: 2023-02-20; 修回日期: 2023-05-05

基金项目: 安徽省中央引导地方科技扶贫示范专项资助项目(JZ2022AKKZ0409); 中央高校基本科研业务费专项资金资助项目(PA2021GDSK0075)

作者简介: 吴迪(1987—), 男, 安徽六安人, 博士, 合肥工业大学讲师, 硕士生导师, 通信作者, E-mail: wu85@hfut.edu.cn;  
赵韩(1957—), 男, 安徽滁州人, 博士, 合肥工业大学教授, 博士生导师。

济性。为了更好地对混合动力汽车进行能量管理,不少学者采用模型预测控制(model predictive control, MPC)方法对一定时域的车辆状态进行预测,利用预测信息对转矩或功率分配进行优化,从而提升整车燃油经济性。

在 MPC 的优化方面,文献[1]将非线性的能量管理问题转化为线性二次优化问题,建立了以预测域内能量消耗最小为目标的随机模型预测控制(stochastic model predictive control, SMPC)策略,通过简化模型来提高求解的速度;文献[2]使用 Q-Learning 算法作为 MPC 能量管理策略的优化求解方法,提高了混合动力汽车能量管理策略的全局最优性和运算实时性;文献[3]综合考虑燃油消耗和排放问题,建立了融合燃油消耗和排放的多目标价值函数,从而建立多目标随机 MPC 策略;文献[4]提出一种基于分布估计算法(estimation of distribution algorithm, EDA)的 MPC 方法,用于优化插电式混合动力公交车的能量流,以提高燃油经济性;文献[5]提出一种基于非线性 MPC 框架的高级动态模型预测控制(AMPC),使用动态权重驱动的多目标成本函数,以提高燃料电池混合动力汽车的能源性能,同时延长其部件寿命;文献[6]针对双电机并联式混合动力汽车出现电机频繁使用导致的过热问题,引入多级控制结构来明确 2 个电机上的最大温度边界,提出了一种包括 MPC 的多级控制器。

在车速预测方面,文献[7]为提高车速预测精度,将马尔可夫链与 BP 神经网络进行组合,利用两者优点提高预测模型的性能;文献[8]利用地图信息,如限速、道路曲率、交通和道路标志,提出一种基于长期车速预测的在线方法;文献[9]考虑道路类型信息对车速预测的影响,提出一种结合道路信息的马尔可夫链综合速度预测器,优化了不同道路类型对车速预测的影响;文献[10]针对实际地理特征对车速的影响,建立不同地理特征的车辆行为数据库,并利用马尔可夫链对未来行驶路线已知的汽车行驶工况进行预测;文献[11]研究了人类驾驶行为的时间相关性,提出具有遗忘因子和折扣因子的测量加权函数来提高速度预测的准确性,将加权方法应用于车速预测器和生态自适应巡航控制系统,结果表明,与传统的速度预测器相比,新预测方法将经济性提高了 4.7%;文献[12]引入时间注意力卷积网络(attention-based temporal convolutional network, ATCN)和空间注意力机制提取时间和空间特征,并进行

空间-时间特征融合,提出一种结合注意力与时空特征的交通速度预测方法(ASTCN),实验表明,ASTCN 模型在短期预测中优于现有方法,并提高了中期和长期预测的准确性。

目前的车速预测方法对车流密度信息利用不足,然而不同车流密度下同一预测模型可能会对仿真预测的精度产生一定的影响。为此,本文在实验的基础上,提出一种考虑车流密度的车速预测方法,并进行基于 MPC 的能量管理策略设计,以提高车速预测模型的准确性和能量管理策略的合理性<sup>[13]</sup>。

## 1 并联式混合动力汽车动力学模型

本文以一款并联式混合动力汽车作为研究对象。整车纵向动力学模型为:

$$P_{\text{req}} = \left( \frac{1}{2} \rho_{\text{air}} A C_d v^2 + f m g \cos \theta + m g \sin \theta + \delta m \frac{dv}{dt} + \frac{I_f i_g^2 i_0 \eta_T}{r^2} \frac{di_g}{dt} \right) v / \eta_T \quad (1)$$

其中:  $P_{\text{req}}$  为驾驶员需求功率;  $C_d$  为空气阻力系数;  $A$  为迎风面积;  $v$  为车速;  $m$  为整车质量;  $g$  为重力加速度;  $f$  为滚动阻力系数;  $\theta$  为道路坡度;  $\delta$  为旋转质量换算系数;  $di_g/dt$  为无级变速器传动比的变化率。  $\delta$  的计算公式为:

$$\delta = 1 + \left( \sum I_w + I_f i_g^2 i_0 \eta_T \right) / (m r^2) \quad (2)$$

其中:  $I_f$  为飞轮转动惯量;  $I_w$  为车轮转动惯量。

发动机和电机模型采用实验建模法,发动机热效率曲线、电机效率曲线如图 1 所示。

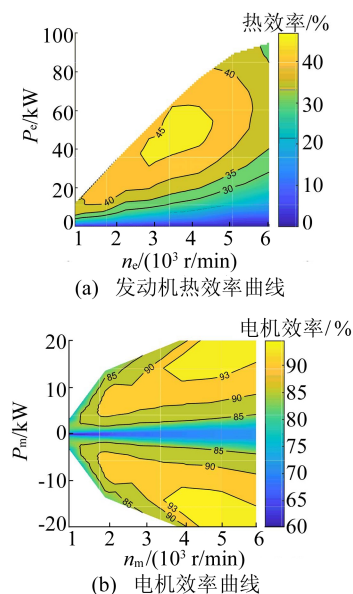


图 1 发动机热效率及电机效率曲线

## 2 考虑车流密度的随机预测模型

在车辆实际行驶过程中,驾驶员通过操纵油门踏板和制动踏板来表达功率需求,其值是不可知的,可将其视为具有马尔可夫性质的随机过程,即下一时刻的需求功率只与这一状态的需求功率有关,与之前的状态无关<sup>[14]</sup>,而需求功率可以通过加速度来反映。

本文将采集到的不同车流密度下的车速数据转化为加速度数据,并通过统计每一工况下的加速度转移概率,得到相应的马尔可夫矩阵,从而建立考虑车流密度的随机预测模型。

### 2.1 多车流密度驾驶工况的采集

为了更准确地进行车速预测,本文通过模拟驾驶平台在线采集不同车流密度下的车速数据<sup>[15]</sup>。模拟驾驶平台车速数据采集流程如图 2 所示。模拟驾驶平台由模拟驾驶设备、模拟驾驶软件、STM32 单片机、上位机和角速度传感器组成。

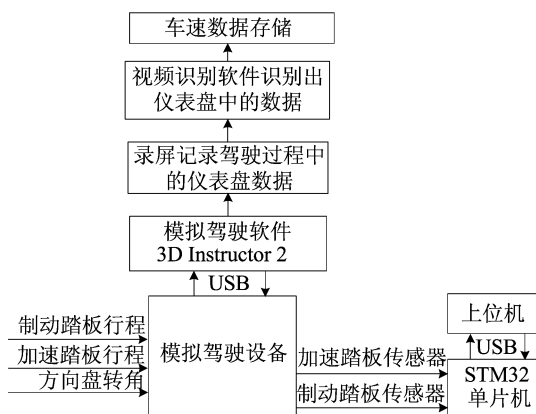


图 2 车速数据采集流程

高速工况车速较为平稳,车流密度对车速影响较小,而城区道路工况车速受车流密度的影响较大,因此本文主要考虑城区道路工况。为充分表征城区道路工况,分别在 3D Instructor 2 软件中设置 10%、40%、70%、100% 这 4 种不同车流密度驾驶工况。其中:10% 表征畅通工况;40% 表征较畅通工况;70% 表征较拥挤工况;100% 表征拥挤工况。下文使用工况序号 1、2、3、4 分别代表上述 4 种工况。通过驾驶员在环实验以 0.1 s 的采样间隔,针对 4 种车流密度分别采集 44 组车速数据,聚类分析找到聚类中心最相近的车速数据作为典型工况。

不同车流密度下的车速曲线如图 3 所示。




图 3 4 种车流密度工况下的车速曲线

### 2.2 随机预测模型的构建

整个驾驶工况的加速度的变化可以看作一个马尔可夫过程,即加速度的变化只与上一时刻的加速度相关。

将加速度离散为有限的状态值,并将离散的数值与矩阵坐标联系起来,便于加速度状态转移次数的统计,即

$$\begin{cases} a_s \in \{a_1, a_2, \dots, a_n\}; \\ i = \text{floor}((a_s(k) + a_{\text{bound}})/s) + 1, \\ j = \text{floor}((a_s(k+1) + a_{\text{bound}})/s) + 1 \end{cases} \quad (3)$$

其中: $a_{\text{bound}}$ 为加速度绝对值的最大值; $i$ 为当前 $k$ 时刻加速度状态对应的空间坐标; $j$ 为 $k+1$ 时刻加速度状态对应的空间坐标; $s$ 为加速度状态分配步长 $0.1 \text{ m/s}^2$ 。

通过统计整个工况下每个加速度状态转移到另一加速度状态的次数以及当前加速度状态总共转移的次数,可以求得每一加速度的状态转移概率,即

$$\begin{cases} F_{i,j} = \sum_{k=1}^l a_i^j(k), \\ F_i = \sum_{j=1}^n F_{i,j}, \\ p_{ij} = \frac{F_{i,j}}{F_i} \end{cases} \quad (4)$$

其中: $F_{i,j}$ 为整个工况下加速度 $a_i$ 转移到 $a_j$ 的次数; $F_i$ 为加速度 $a_i$ 向其他状态转移的总次数; $p_{ij}$ 为加速度 $a_i$ 到 $a_j$ 的状态转移概率。

一阶齐次加速度马尔可夫状态转移概率矩阵可以表示为:

$$\mathbf{P} = \begin{bmatrix} p_{11} & p_{12} & \dots & p_{1n} \\ p_{21} & p_{22} & \dots & p_{2n} \\ \vdots & \vdots & & \vdots \\ p_{n1} & p_{n2} & \dots & p_{nm} \end{bmatrix} \quad (5)$$

式(5)中每一个 $p_{ij}$ 均满足以下条件:

$$\begin{cases} 0 \leq p_{ij} \leq 1, & \sum_{j=1}^n p_{ij} = 1, \\ i, j = 1, 2, \dots, n \end{cases} \quad (6)$$

根据采集的 4 种车流密度的车速数据,建立 4 种加速度状态转移概率矩阵。以  $0.1 \text{ m/s}^2$  为状态划分间隔,共划分为 200 个加速度状态。不同车流密度下的加速度概率转移矩阵如图 4 所示。图 4 中, $S_i$ 、 $S_j$  分别为当前  $k$  时刻和  $k+1$  时刻加速度状态。

多步预测矩阵由单步加速度矩阵生成,即

$$\mathbf{P}(k) = \mathbf{P}^k, \quad k = 1, 2, \dots, p \quad (7)$$

其中: $\mathbf{P}$ 为单步马尔可夫矩阵; $\mathbf{P}(k)$ 为第 $k$ 步马尔可夫矩阵; $p$ 为预测时长值。

加速度的预测公式为:

$$a_k = (S_{k-1} - 1)s - a_{\text{bound}} + \epsilon \quad (8)$$

其中: $a_k$ 为第 $k$ 秒的加速度; $S_{k-1}$ 为第 $k-1$ 秒的加速度状态; $\epsilon$ 为 $0 \sim 1$ 之间的随机数。


结合式(1)即可计算出预测时域内的功率需

求序列。


经过对单步和多步马尔可夫矩阵的求解,车速预测可以表示为:

$$v(k) = v_0 + \sum_{i=1}^k a_i dt \quad (9)$$


其中: $v(k)$ 为 $k$ 时刻车速; $v_0$ 为初始时刻车速; $a_i$ 为第 $i$ 秒的实际加速度。




(a) 10%车流密度



(b) 40%车流密度



(c) 70%车流密度



(d) 100%车流密度

图 4 不同车流密度下的加速度状态转移概率矩阵

### 3 混合动力汽车的 MPC 策略

本文所提出的基于考虑车流密度的 MPC 能

量管理策略由车流密度识别模块、车速预测模块和动态规划滚动求解模块组成,其系统结构及工作流程如图 5 所示。

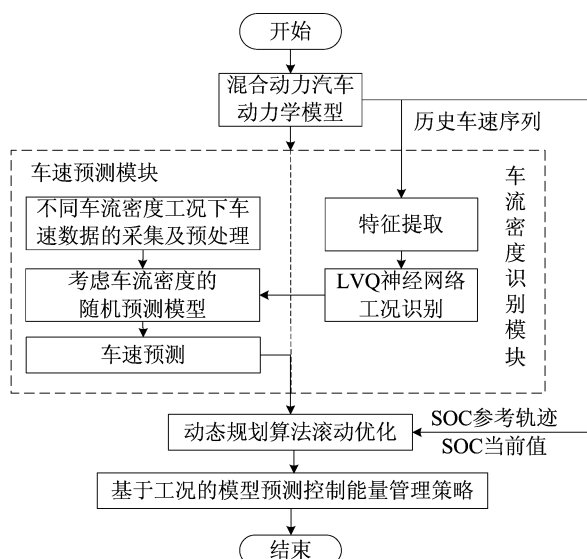


图 5 考虑车流密度的 MPC 能量管理策略系统结构及工作流程

车流密度识别模块基于汽车行驶的历史数据进行识别,并在车速预测模块中选取相应车流密度下的预测模型进行加速度预测,进而获得预测时域内的车速及需求功率,最终通过动态规划求解模块求解预测时域上的控制序列,选取第 1 个控制变量输入到整车模型中,并以此反复滚动向前进行优化求解。

### 3.1 基于 LVQ 神经网络的车流密度识别

对于工况的识别方法主要包括基于聚类理论的识别方法、利用模糊控制器的识别方法和基于神经网络的识别方法<sup>[16]</sup>。基于聚类理论的识别方法速度快,但识别准确率不高;利用模糊识别器的识别方法需要工程经验,同时需要反复调试;而利用神经网络的识别方法有效避免了前 2 种方法的缺陷。因此本文选取学习向量量化(learning vector quantization, LVQ)神经网络来进行车流密度的识别。

LVQ 是一种监督型神经网络,它将竞争学习与监督学习相结合,通过最近邻原则找到获胜神经元后不断修改神经元之间的权向量,从而识别模式类别<sup>[17]</sup>。

LVQ 神经网络的神经元种类固定,由输入层、竞争层和线性输出层 3 层组成<sup>[18]</sup>,其结构如图 6 所示。

竞争层有  $m$  个神经元,输入层有  $n$  个神经元,竞争层通过全连接的方式与输入层相连,连接权

重固定为 1,训练过程中输入层与竞争层之间的权值  $w_i$  逐渐调整为聚类中心。线性输出层有  $l$  个神经元,采用部分连接的方式与竞争层相连,当竞争层的神经元竞争获胜,与其相连的输出层神经元输出 1,而其他神经元输出 0,得到当前输入样本的模式类。




图 6 LVQ 神经网络结构

#### 3.1.1 特征参数及参数提取方式

针对每种车流密度下的工况数据,为了尽可能提取工况的信息,使得识别精度更高,采用滚动时间窗与不等长提取时间结合的方式。以 10% 车流密度的工况为例,设  $T_g$  为滚动时间,  $T_e$  为状态提取时间,以滚动的方式对工况进行特征参数的提取,结果如图 7 所示。

当提取时间到达工况末尾,倍增特征提取时间,继续进行特征的提取,直到特征提取时间为整个工况的时间。




图 7 10% 车流密度车速数据的特征参数提取

为尽可能包含工况信息,不同工况提取的特征参数有明显区别,同时减少神经网络的训练时间,选取  $T_e = 200$  s 为基本特征提取时间,  $T_g = 50$  s,对工况进行特征提取。

经过对提取特征参数进行相关性和主成分分析,选取  $v_{av1}$ 、 $v_{av2}$ 、 $v_{max}$ 、 $a_{min}$ 、 $a_{mean}$ 、 $d_{av}$ 、 $P_j$ 、 $P_{v_1 v_2}$ 、 $P_{v_2 v_3}$ 、 $P_{a_1 a_2}$  10 个能充分表征工况特征的特征参

数,具体含义见表 1 所列。

表 1 特征参数含义

特征参数	特征参数含义
$v_{av1}$	平均车速
$v_{av2}$	平均驾驶车速
$v_{max}$	最高车速
$a_{min}$	最小加速度
$a_{mean}$	平均加速度
$d_{av}$	平均减速度
$P_j$	减速占比
$P_{v_1 v_2}$	车速在 $v_1$ (0 m/s) 与 $v_2$ (最高车速的 1/6) 之间的占比
$P_{v_2 v_3}$	车速在 $v_2$ 与 $v_3$ (最高车速的 1/2) 之间的占比
$P_{a_1 a_2}$	加速度在 $a_1$ (0 m/s <sup>2</sup> ) 与 $a_2$ (最高加速度的 1/2) 之间的占比

将整个工况提取的特征参数存为向量  $V_x = (v_{xy})_{z \times 1}$ 。其中: $z$  为向量的维数; $v_{xy}$  为第  $x$  个车流密度工况对应的第  $y$  个特征参数值; $x=1, 2, 3, 4; y=1, 2, \dots, 10$ 。

### 3.1.2 LVQ 神经网络的训练测试验证

由于采集数据数量较少,为了能够合理地利用采集的数据集进行训练,同时避免训练出的 LVQ 神经网络出现过拟合,采用  $K$ -fold 交叉验证方法对神经网络的超参数进行优化并进行模型的选择。

不同竞争层的神经元数经过交叉验证得到的平均识别正确率见表 2 所列。

由表 2 可知,竞争层神经元个数为 30、40、50 时,识别精度最高,但为减少计算资源,本文选用 30 个神经元数。

表 2 神经元数与平均识别精度

神经元数	10	20	30	40	50
平均识别精度/%	88.72	89.50	92.78	92.78	92.78

神经元数为 30 时交叉验证的识别正确率如图 8 所示。由图 8 可知,训练后的 LVQ 神经网络识别精度可以达到车流密度识别要求。




图 8 交叉验证识别正确率

### 3.1.3 车速预测精度比较

为评估所提预测模型的预测精度,与现有的单一马尔可夫预测模型进行比较。本文采用平均均方根误差 (average root mean square error, ARMSE) 指标,它反映的是整个工况下预测车速与实际车速之间的误差,其数学表达式如下:

$$E_{ARMS} = \frac{1}{L} \sum_{n_{step}=1}^L \sqrt{\frac{1}{p} \sum_{k=1}^p (Y_p^k - Y_d^k)^2} \quad (10)$$

其中: $Y_p^k$  为第  $k$  秒的预测车速; $Y_d^k$  为第  $k$  秒的实际车速; $L$  为整个工况的时间。

单一马尔可夫预测模型和考虑车流密度的马尔可夫预测模型在不同预测时域的预测精度见表 3 所列。

表 3 车速预测指标

预测时域/s	$E_{ARMS}/(m/s)$		提升精度/%
	单一马尔可夫预测	考虑车流密度的马尔可夫预测	
3	0.629	0.552	12.33
6	1.571	1.453	7.51
11	2.886	2.697	6.56

由表 3 可知,考虑车流密度的马尔可夫预测模型相较于单一马尔可夫预测模型在 3 s 的预测时域下的预测精度可提升 12.33%,在 6 s 的预测时域下的预测精度可提升 7.51%,在 11 s 的预测时域下的预测精度可提升 6.56%。

通过以上分析可知,在 3 种预测时域下,考虑车流密度的马尔可夫预测模型均具有更小的平均

均方根误差。因此,在相同预测时域下,考虑车流密度的马尔可夫预测模型具备更高的预测精度。

### 3.2 基于动态规划的滚动优化求解

针对混合动力汽车的 MPC 能量管理策略,本文采用动态规划的滚动优化方法,在预测时域值  $k \sim k+p$  内,求解出损失函数最小的发动机和电机功率分配。

动态规划求解过程如图 9 所示,分为逆向计算和正向寻优 2 个部分。逆向计算是通过将待求问题分解为  $n$  个阶段,从最后一个阶段依次向前迭代计算每个阶段每一状态下的最优目标函数值,从而得到与之相对应的最优控制变量。正向寻优则是基于逆向计算的结果,给定 1 个初始值,通过状态转移方程插值得到预测时域内的最优控制变量序列。




图 9 动态规划算法逆向求解和正向寻优图

本文选取电机功率  $P_m$  为控制变量,电池荷电状态(state of charge, SOC)为状态变量,即

$$\begin{cases} u_k = P_m(k), \\ x_k = SOC(k) \end{cases} \quad (11)$$

系统当前阶段的状态变量由前一阶段的状态变量和控制变量唯一确定,系统的状态转移方程如下:

$$SOC(k+1) = SOC(k) + \Delta SOC(k) \quad (12)$$

$$\Delta SOC(k+1) = -\frac{P_b(k)}{\varepsilon Q_b U_{oc}} \Delta t \quad (13)$$

$$\varepsilon = \begin{cases} \eta_m, & P_b(k) > 0; \\ 1, & P_b(k) = 0; \\ 1/\eta_m, & P_b(k) < 0 \end{cases} \quad (14)$$

其中: $Q_b$  为电池容量; $U_{oc}$  为开路电压; $P_b(k)$  为当前时刻电机发出的功率; $\eta_m$  为电机效率。

综合考虑预测时域  $p$  秒内发动机的燃油消耗和整个工况电池 SOC 的平衡,在任意  $k$  时刻建立如下的目标函数  $J_k$ ,即

$$J_k = m_{fuel}(k) + \alpha [SOC(k) - SOC_{ref}]^2 \quad (15)$$

其中: $m_{fuel}$  为发动机燃油消耗; $\alpha$  为惩罚值,为保证 SOC 值在合理变化范围内,基于 SOC 变化和燃油消耗率的数量级确定为 0.015; $SOC(k)$  为  $k$  时刻 SOC 的状态; $SOC_{ref}$  为 SOC 的参考值,设为定值 0.6。

$J_k^*(SOC_i)$  为逆向求解到  $k$  时刻,最小目标函数值下对应的 SOC 值,即

$$J_k^*(SOC_i) =$$

$$\operatorname{argmin}[J_k(m_{fuel}, SOC_i) + J_{k+1}(SOC_{i+1})] \quad (16)$$

需要满足的约束如下:

$$\begin{cases} SOC_{min} \leq SOC(k) \leq SOC_{max}, \\ P_{e_{min}} \leq P_e(k) \leq P_{e_{max}}, \\ P_{m_{min}} \leq P_m(k) \leq P_{m_{max}}, \\ P_{req}(k) = P_e(k) + P_m(k), \\ n_{e_{min}} \leq n_e(k) \leq n_{e_{max}}, \\ n_{m_{min}} \leq n_m(k) \leq n_{m_{max}}, \\ n_m(k) = n_e(k) \end{cases} \quad (17)$$

其中: $SOC_{min}$  设为 0.3,  $SOC_{max}$  设为 0.9;  $P_e(k)$  为  $k$  时刻发动机功率;  $P_{e_{min}}$ 、 $P_{e_{max}}$  分别为发动机的最小、最大功率;  $P_{req}$  为需求功率;  $n_e(k)$  为  $k$  时刻发动机转速;  $n_{e_{min}}$ 、 $n_{e_{max}}$  分别为电机最小、最大转速;  $n_m(k)$  为  $k$  时刻发动机转速;  $n_{m_{min}}$ 、 $n_{m_{max}}$  分别为电机最小、最大转速。

使用动态规划进行逆向求解,逐步计算出预测时域内的 SOC 变化曲线,在此基础上正向求解得出预测时域内最优电机功率分配序列。

## 4 仿真结果分析

为验证考虑车流密度的 MPC 能量管理策略的有效性,本文通过 CRUISE 软件建立整车动力学模型,通过 CRUISE 软件的 API 接口在 Simulink 中建立数据传输接口,实现 MATLAB/Simulink 与 CRUISE 联合仿真。

### 4.1 仿真工况

本研究将采集到的 4 种车流密度下的工况数据首尾相连组成仿真工况,用于模拟实际车辆行驶的过程,为工况识别和能量管理策略的仿真验证提供条件。

综合工况车速曲线如图 10 所示。




图 10 综合工况车速曲线

### 4.2 混合动力汽车的主要参数

混合动力汽车的整车参数见表 4 所列。

表 4 整车参数

参数	数值
整备质量/kg	1 620
车轮半径/m	0.308
主减速比	5.5
迎风面积/m <sup>2</sup>	2.15
风阻系数	0.3
发动机峰值功率/kW	95.264
电机峰值功率/kW	13.614
电池容量/As	25 000
空气密度/(kg/m <sup>3</sup> )	1.225 8
滚动阻力系数	0.018
重力加速度/(m/s <sup>2</sup> )	9.8
机械效率	0.788
无级变速器传动比	0.500~2.873
飞轮转动惯量/(kg·m <sup>2</sup> )	0.19
车轮转动惯量/(kg·m <sup>2</sup> )	1.1

4.3 仿真结果分析

为分析本文考虑车流密度的 MPC 能量管理策略效果,选取普通不考虑车流密度的 MPC 能量管理策略进行对比,2 种方法均设定预测时域为 10 s,采样时间为 1 s,SOC 初始值为 0.6,控制时域为 1 s。

燃油消耗量的计算利用等效燃油消耗计算,即

$$\dot{V}_{fuel} = V_{fuel} + \frac{(SOC_{end} - SOC_0)Q_b U_{oc}}{Q_{fuel} 1000 \rho_{fuel}} \quad (18)$$

其中:  $Q_{fuel} = 42\ 700\ \text{kJ/kg}$ ,为燃油热值;  $\rho_{fuel} = 0.72\ \text{kg/L}$ ,为燃油密度;  $V_{fuel}$  为实际燃油消耗;  $\dot{V}_{fuel}$  为等效燃油消耗。

考虑车流密度的 MPC 能量管理策略与普通 MPC 能量管理策略下的燃油消耗量如图 11 所示。

2 种 MPC 能量管理策略下电池 SOC 消耗的对比如图 12 所示。

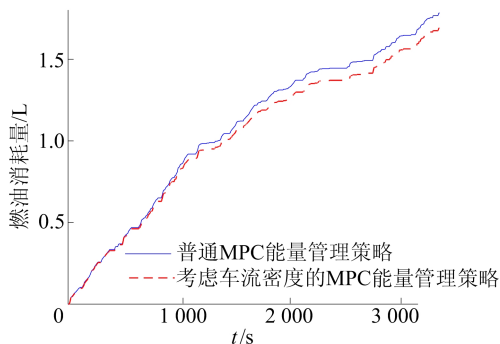


图 11 考虑车流密度的 MPC 与普通 MPC 下的燃油消耗




图 12 2 种 MPC 能量管理策略下的 SOC 消耗图

LVQ 神经网络的车流密度识别结果如图 13 所示。发动机与电机的功率分配如图 14 所示。




图 13 车流密度识别结果




图 14 电机与发动机的功率分配

由图 11、图 12 可知:在循环工况下,该混合动力汽车采用考虑车流密度的 MPC 能量管理策略的燃油消耗共 1.693 L,该循环工况总里程为 19.148 km,工况结束时的 SOC 为 60.09%,由式(15)计算可得等效油耗为 1.692 9 L,故其 100 km 油耗为 8.841 L;而普通 MPC 能量管理策略的燃油消耗为 1.783 L,工况结束时的 SOC 为 46.62%,计算可得等效燃油消耗为 1.783 0 L,故其 100 km 油耗为 9.311 L。

因此,考虑车流密度的 MPC 能量管理策略与普通 MPC 能量管理策略相比,燃油经济性提高了 6.33%,仿真结果表明,基于车流密度的

MPC 能量管理策略能够有效提升混合动力汽车的燃油经济性。

## 5 结 论

1) 本文通过提取工况的特征数据,建立了 LVQ 神经网络进行车流密度识别,并通过  $K$ -fold 交叉验证的方式验证了所建立的神经网络识别方法的识别精度达到要求。

2) 在所建立的车流密度识别方法基础上,提出一种考虑车流密度的车速预测方法,基于实验台架采集多种车流密度下的车速数据,利用统计学方法建立了不同车流密度下的马尔可夫矩阵,提高了车速预测的准确性。

3) 建立了考虑车流密度的混合动力汽车能量管理策略,以经济性为优化目标,基于 MPC 方法实现了滚动优化,并获得了功率分配策略;基于 CRUISE 与 MATLAB/Simulink 进行联合仿真,结果表明,考虑车流密度的 MPC 能量管理策略的燃油经济性有明显提高。后续将在实车上进行试验验证,进一步证明本文所提控制策略的有效性。

## 【参 考 文 献】

- [1] 秦大同,秦岭. 基于显式随机模型预测控制的功率分流式混合动力车辆能量管理策略[J]. 华南理工大学学报(自然科学版), 2019, 47(7): 112-120.
- [2] 尹燕莉,马永娟,周亚伟,等. Markov 链与 Q-Learning 算法的超轻度混动汽车模型预测控制[J]. 汽车安全与节能学报, 2021, 12(4): 557-569.
- [3] 孙蕾,林歆悠,莫李平. 基于随机模型预测控制的插电式混合动力汽车多目标能量管理策略[J]. 控制理论与应用, 2022(12): 2274-2282.
- [4] TIAN X, CAI Y, SUN X, et al. A novel energy management strategy for plug-in hybrid electric buses based on model predictive control and estimation of distribution algorithm [J]. IEEE/ASME Transactions on Mechatronics, 2022, 27(6): 4350-4361.
- [5] ZHOU F L, LI Y Y, WANG W Y, et al. Integrated energy management of a smart community with electric vehicle charging using scenario based stochastic model predictive control[J]. Energy and Buildings, 2022, 260(4): 111916.
- [6] MACHACEK D, BARHOUMI K, RITZMANN J, et al. Multi-level model predictive control for the energy management of hybrid electric vehicles including thermal derating [J]. IEEE Transactions on Vehicular Technology, 2022, 71(10): 10400-10414.
- [7] ZHANG L P, LIU W, QI B N. Combined prediction for vehicle speed with fixed route[J]. Chinese Journal of Mechanical Engineering, 2020, 33(4): 121-133.
- [8] KUCHLY J, NELSON-GRUEL D, CHARLET A, et al. Forecasting ECMS for hybrid electric vehicles[J]. IFAC-PapersOnLine, 2020, 53(2): 14154-14160.
- [9] GUO J H, JIANG Y, LIU C, et al. Integrated multistep Markov-based velocity predictor of energy consumption prediction model for battery electric vehicles[J]. Transportmetrica B(Transport Dynamics), 2021, 9(1): 399-414.
- [10] 曹磊,陈长文,孙强. 基于马尔可夫链的汽车行驶工况预测[J]. 内燃机与动力装置, 2017, 34(3): 13-17, 27.
- [11] HYEON E, KIM Y, ERSAL T, et al. Data-driven forgetting and discount factors for vehicle speed forecasting in ecological adaptive cruise control[J]. Journal of Dynamic Systems, Measurement, and Control, 2022, 144: 011101.
- [12] ZHANG A, LIU Q, ZHANG T. Spatial-temporal attention fusion for traffic speed prediction [J]. Soft Computing, 2022, 26: 695-707.
- [13] 丁峰,王伟达,项昌乐,等. 基于行驶工况分类的混合动力车辆速度预测方法与能量管理策略[J]. 汽车工程, 2017, 39(11): 1223-1231.
- [14] 赵韩,吴迪. 基于随机模型预测控制的并联式混合动力汽车控制策略研究[J]. 汽车工程, 2014, 36(11): 1289-1294.
- [15] 赵韩,刘浩,邱明明,等. 考虑车流密度影响的驾驶风格识别方法研究[J]. 汽车工程, 2020, 42(12): 1718-1727.
- [16] 赵勇,谢金法,时佳威,等. 基于遗传算法优化支持向量机工况识别的燃料电池混合动力汽车能量管理策略[J]. 科学技术与工程, 2020, 20(14): 5820-5827.
- [17] 赵小强,张莺莺. 基于改进 LVQ 神经网络的乳腺肿瘤诊断[J]. 现代电子技术, 2022, 45(1): 77-82.
- [18] 莫浩楠,杨中平,林飞,等. 有轨电车基于工况识别的强化学习能量管理策略[J]. 电工技术学报, 2021, 36(19): 4170-4182.

(责任编辑 胡亚敏)