

doi: 10.19562/j.chinasae.qcgc.2025.04.004

融合机器视觉的插电式混合动力汽车预测型 能量管理策略*

王 姝, 韩 琪, 赵 轩, 谢鹏辉
(长安大学汽车学院, 西安 710000)

[摘要] 针对传统模型预测控制下车速预测不准确和SOC适应性差的问题,以插电式混合动力汽车(PHEV)为研究对象,将基于机器视觉的车速预测模型与深度确定性策略梯度算法(DDPG)相结合,实现PHEV的实时SOC参考轨迹规划和最优动力分配控制。构建基于改进深度确定性策略梯度算法的SOC参考轨迹规划模型,并构建基于机器视觉的级联式长短时间记忆网络车速预测模型,在此基础上使用基于模型预测控制的最优控制器,实现SOC参考轨迹精确跟踪及功率优化。结果表明,相较于传统的DDPG,本文提出的策略使得整车经济性提高了5.66%,达到了全局最优算法的97.93%。同时较不使用机器视觉的能量管理策略提高了2.92%的整车经济性。

关键词: 插电式混合动力; 能量管理策略; 机器视觉; 车速预测; 参考轨迹

Predictive Energy Management Strategy of Plug-in Hybrid Electric Vehicle with Computer Vision

Wang Shu, Han Qi, Zhao Xuan & Xie Penghui
School of Automobile, Chang'an University, Xi'an 710000

[Abstract] For the problems of inaccurate speed prediction and poor SOC adaptability under the traditional model predictive control, the plug-in hybrid electric vehicle (PHEV) is taken as the research object, and the speed prediction model based on computer vision is combined with the deep deterministic policy gradient (DDPG) algorithm to achieve the real-time state of charge (SOC) reference trajectory planning and optimal power allocation control of PHEV. A SOC reference trajectory planning model based on the enhanced DDPG is constructed, and a speed prediction model based on computer vision with cascaded long short-term memory network is constructed, based on which the optimal controller based on the model predictive control is used to achieve the accurate tracking of the SOC reference trajectory and power optimization. The results show that compared to the traditional DDPG, the strategy proposed in this paper increases the overall vehicle economy by 5.66%, reaching 97.93% of the global optimal algorithm. It also improves the overall vehicle economy by 2.92% compared to the energy management strategy without computer vision.

Keywords: plug-in hybrid electric vehicle; energy management strategy; computer vision; speed prediction; reference trajectory

* 国家自然科学基金(52472397, 52172362)、陕西省重点研发计划项目(2024GX-YBXM-260)和陕西省科技成果转化计划项目(2024CG-CGZH-19)资助。

原稿收到日期为2024年10月16日,修改稿收到日期为2024年12月15日。

通信作者: 韩琪, 博士, E-mail: hanqi_0612@163.com。

前言

发展新能源汽车技术是当前汽车技术研究的热点,同时也是我国战略性新兴产业^[1]。其中,插电式混合动力汽车(plug-in hybrid electric vehicle, PHEV)因其具有较长的续驶里程,可利用电力成本提高整车经济性,可通过削峰填谷改善电网使用结构等多项优点,进而成为国内外整车企业和研究机构的研究热点。针对PHEV整车的多动力源协同优化管理,开展能量管理策略研究对提升混合动力关键技术的核心竞争力具有重要的意义^[2-3]。

基于规则的能量管理策略虽然逻辑简单,有利于实时控制,但对专家和工程经验依赖性比较强,在日趋复杂的道路交通环境下难以达到最优的能量分配^[4]。基于全局优化算法可以从理论上获得最优解,如动态规划(dynamic programming, DP)算法,但是全局优化须提前预知整个行驶工况信息,且计算量大,计算效率低,难以在线实时应用,故通常被视为基准算法^[5-7]。等效燃油消耗最小化策略(equivalent consumption minimization strategy, ECMS)和基于模型预测控制(model predictive control, MPC)的能量管理策略是目前最为常见的基于瞬时优化的控制策略^[8-12]。ECMS虽可以实现实时最优控制,但等效因子的选取会影响整个策略的控制效果。而MPC将全局最优问题转化为预测时域内的局部优化问题,利用滚动优化算法不断更新未来时域内汽车行驶状态获得优化结果,从而实现预测控制在能量管理策略中的应用。

基于机器学习的智能能量管理策略,因其具有自学习探索的能力,更有利于克服由车辆行驶工况和道路交通环境多变所导致的能量管理策略适用性差、控制性能次优等问题^[13-14]。目前常用于PHEV能量管理策略中的深度强化学习(deep reinforcement learning, DRL)算法,将深度学习的感知能力和强化学习的决策能力相结合,实现从高维状态感知输入到最优动作输出的端到端控制,在PHEV的能量管理方面表现出优异的控制性能和出色的适应性^[15-18]。但是目前基于DRL的能量管理策略研究大多忽略了未来驾驶周期的不确定性,从而损害了能量管理策略的经济性能。因此,在上述所有能量管理策略中只有基于MPC的能量管理策略可以通过预测未来短时域内车辆需求功率来主动调整功率流在多个动力源之间的分配。但基于MPC的能量管

理策略虽然能够借助预测模型,将未来短时域内的行驶工况纳入到预测控制中,但是其模型内部的控制参数不能做到自适应调整。未来时域内汽车行驶状态准确可靠的预测和高效、高精度和强适应性的电池荷电状态(state of charge, SOC)参考轨迹对MPC的控制效果和鲁棒性有着极其重要的作用。

对车辆未来短时域内行驶状态的预测通常是指对其未来短时域内的车速序列进行预测,目前常用的车速预测方法有基于指数函数的预测方法、基于马尔科夫链模型的预测方法、基于确定型参数模型的预测方法和基于神经网络的预测方法^[19-20]。同时现阶段对车辆行驶过程中电池全局SOC参考轨迹的研究主要有3种。第1种是根据动态规划算法的SOC轨迹,并将其近似制定成线性下降的轨迹。Xie等^[21]将SOC参考轨迹制定成随时间线性下降的轨迹,并将其应用于MPC中。第2种是基于行驶时间或行驶里程制定的线性下降的SOC参考轨迹^[22-24]。Tang等^[25]分别制定了随行驶时间和行驶里程的SOC参考轨迹以指导MPC的滚动优化过程。第3种是通过对未来工况进行预测,然后利用全局优化算法在预测时域内提前规划SOC参考轨迹。He等^[26]利用动态规划算法进行SOC参考轨迹快速规划,并将其运用到基于MPC中。然而,采用全局优化算法对SOC参考轨迹进行离线计算,需要经过极长的迭代时间,且如果行驶周期变化较大,则须重新计算,不能保证SOC参考轨迹的自适应性。

因此,为了弥补上述研究的不足,本文提出一种融合机器视觉的预测型PHEV智能能量管理策略。将能够对预测时域提前主动调整的MPC能量管理策略与具有强鲁棒性和自适应性的DDPG算法相结合。通过DDPG算法规划出合适的SOC参考轨迹以指导MPC控制器优化转矩分配,同时将控制结果反馈给DDPG参考轨迹规划模型,实现了两者之间的优势互补;同时,将基于机器视觉的车速预测模型作为MPC的预测器,采用考虑外部交通环境信息的级联式长短时间记忆网络(long short-term memory, LSTM)神经网络模型实现对未来时域内车速的精准、全面预测,进一步提升能量管理策略控制效果。

1 混合动力系统建模

1.1 混合动力构型

本文以并联式插电式混合动力汽车为研究对象,其整车动力系统如图1所示。电驱动系统由电

机和机械自动变速器组成。发动机与电机之间通过离合器的分离与接合实现并联运行模式下的转矩耦合,并通过同一输出轴将两种动力源所产生的转矩传递给车轮。整车及各主要总成部件参数如表1所示。




图1 混合动力构型

表1 整车关键参数

参数	数值
整车整备质量/kg	1 680
滚动半径/m	0.352
迎风面积/m ²	2.26
风阻系数	0.371
滚动阻力系数	0.012
传动系效率	0.90
旋转质量换算系数	1.07
主减速器速比	6.328

1.2 关键部件建模

发动机的燃油消耗及电机效率 Map 图如图2和图3所示。同时采用等效电路 Rint 模型对电池进行建模,电池输出功率和 SOC 可由下式描述:

$$P_b = U_0 - I_b = U_{oc} \cdot I_b - I_b^2 \cdot R_i \quad (1)$$

$$I_b = \left(U_{oc} - \sqrt{U_{oc}^2 - 4P_b R_i} \right) / 2R_i \quad (2)$$

$$SOC(t) = SOC_0 - \frac{\int_0^t \left(U_{oc} - \sqrt{U_{oc}^2 - 4R_i P_b(t)} \right) dt}{2R_i Q_0} \quad (3)$$




图2 发动机燃油消耗 Map 图




图3 电机效率 Map 图

式中: $SOC(t)$ 为当前时刻的 SOC; SOC_0 为动力电池 SOC 的初始值; Q_0 为电池的最大容量。

2 基于机器视觉的车速预测模型

2.1 基于 DDPG 算法的 SOC 参考轨迹规划模型

深度确定性策略梯度 (deep deterministic policy gradient, DDPG) 算法通过 Actor-Critic 结构,为解决连续动作空间上的动作输出提供方法。Actor 网络根据状态输出连续控制动作, Critic 网络对状态和输出动作的值函数进行估计,提供梯度信息,以指导 Actor 网络更新。DDPG 算法采用 Actor 网络和 Critic 网络来对策略函数 $\mu(s|\theta^\mu)$ 和价值函数 $Q(s,a|\theta^Q)$ 进行拟合, θ^Q 和 θ^μ 分别是 Actor 网络和 Critic 网络的参数。同时每个 Actor 网络和 Critic 网络都存在相应的目标神经网络。

在训练过程中为了提升智能体对最优策略的探索能力,在 DDPG 算法中使用奥恩斯坦-乌伦贝格 (Ornstein-Uhlenbeck, OU) 随机过程作为随机噪声 ϑ 。加入随机噪声 ϑ 后 Actor 网络 μ 的输出动作为

$$a = \mu(s|\theta^\mu) + \vartheta \quad (4)$$

$\mu(s)$ 的训练是探索具有最高累积奖励行动序列的过程,这种长期奖励由 Critic 网络评估,并由著名的 Bellman 方程以递归方式更新,表示为

$$Q^\mu(s,a) = E[r(s,a) + \gamma Q^\mu(s',\mu(s'))] \quad (5)$$

式中: $r(s,a)$ 为状态 s 下采用动作 a 的即时奖励; s' 为下一时刻状态值。为实现上述过程, Critic 网络采用时序差分误差的均方差来表现评价的准确性,并用随机梯度的方法进行参数更新,表示为

$$\frac{\partial L(\theta^Q)}{\partial \theta^Q} = E_{s,a,r,s'} \left[y_t - Q(s,a|\theta^Q) \frac{\partial Q(s,a|\theta^Q)}{\partial \theta^Q} \right] \quad (6)$$

$$y_t = r_{t+1} + \gamma Q^Q(s',\mu(s'|\theta^\mu)|\theta^Q) \quad (7)$$

Actor 网络基于策略梯度法进行自我更新,记为

$$\frac{\partial J(\theta^\mu)}{\partial \theta^\mu} = E_s \left[\frac{\partial Q(s, a | \theta^\mu)}{\partial a} \frac{\partial \mu(s | \theta^\mu)}{\partial \theta^\mu} \right] \quad (8)$$

目标 Actor 网络和目标 Critic 网络的参数 θ^μ 和 θ^v , 以逼近系数 τ 沿着梯度上升的方向进行参数更新, 分别表示为

$$\theta^\mu \leftarrow \tau \theta^\mu + (1 - \tau) \theta^{\mu'} \quad (9)$$

$$\theta^v \leftarrow \tau \theta^v + (1 - \tau) \theta^{v'} \quad (10)$$

所建立的基于 DDPG 算法的 PHEV 能量管理策略目的是为了实现在整车驾驶成本的最小化, 其中包括动力电池电量消耗量和发动机燃油消耗量。同时为保证提出的 SOC 参考轨迹规划模型对电量下降的平稳有效规划, 故在奖励函数中增加了单位时间内 SOC 下降平衡因子。因此本文提出的基于改进深度确定性策略梯度算法 (enhanced-DDPG, E-DDPG) 的动作空间、状态空间及奖励函数可表示为

$$\begin{cases} A = \{n_e, T_e\} \\ S = \{T_{\text{req}}, SOC, V, a\} \\ R = -(Q_f \cdot \psi_f + Q_b \cdot \psi_b + \xi_1 \Delta SOC + \xi_2 (SOC(t) - SOC_{\text{tar}})) \end{cases} \quad (11)$$

式中: T_{req} 、 V 和 a 分别为车辆行驶时的总需求转矩、自车车速和自车加速度; Q_f 和 Q_b 分别表示燃油和电量的消耗量; ψ_f 和 ψ_b 分别表示燃油价格和电力价格; ΔSOC 表示单位时间内 SOC 的变化量; SOC_{tar} 为 SOC 目标值; ξ_1 和 ξ_2 是约束 SOC 变化的权重因子。

2.2 融合机器视觉的交通感知车速预测模型

速度预测可表述为一个监督回归问题, 以当前车辆前一时间窗口内的速度序列以及实时交通信息作为输入, 以当前车辆在未来时刻的实际速度序列作为标签。给定由多个时间速度轨迹组成的数据集:

$$\mathcal{D}: \{T_1, T_2, \dots, T_N\}, |T_i| = L_i \quad (12)$$

$$T_i = \{(\mathcal{X}_{i,t}^w, \mathcal{Y}_{i,t}^h) | t \in \{1, 2, \dots, L_i\}\} \quad (13)$$

式中: T 为预测水平为 L_i 的预测速度序列; \mathcal{X}^w 是步长为 w 的输入变量; \mathcal{Y}^h 是预测步长为 h 的预测车速序列; t 是轨迹上第 t 个时间步长。因此, 一个样本可以表示为

$$\mathcal{X}^w = [x_1, x_2, \dots, x_w] \quad (14)$$

式中 \mathcal{X} 表示每个时间步长内的工况特征。本研究使用的特征包括目标车辆前方特定区域内的外部交通信息 (车辆数目、道路交通速度以及与正前方车辆车距) 和自车行驶信息 (自车车速及纵向加速度) 两部分, 表示为 $\mathcal{X}^w = [N_i, V, D_i, V_0, a_0]$ 。具体来说:

$$V(t) = \frac{\sum_{i=1}^{N_i} V_i(t)}{N_i(t)} \quad (15)$$

式中: $N_i(t)$ 表示 t 时刻目标车辆前方一定区域内的车辆数目; V_i 表示 t 时刻第 i 辆车的车速。当前车辆前方宽 5 m、长 60 m 的区域为摄像最大捕捉技术区域, 任何超出此范围的车辆将被排除在外。回归学习问题是基于输入 \mathcal{X}^w 生成预测的未来速度序列:

$$\mathcal{Y}^h = \mathcal{M}_p(\mathcal{Y}_{i,t}^h, \mathcal{X}^w; \theta^{M_p}) \quad (16)$$

式中: \mathcal{M}_p 在本研究中为级联式 LSTM 预测模型; θ^{M_p} 为网络参数。

为获取交通信息, 本文使用第 3 代“你只看一次” (You only look once version 3, YOLOv3) 探测器对车辆进行计数, 该系统在目标检测方面具有准确和快速的特点。并采用基于深度学习的在线和实时跟踪 (deep simple online and real time tracking, DeepSORT) 算法对目标车辆前方特定区域车辆进行跟踪。

通过摄像头获取原始图像后, 使用透视变换得到鸟瞰图, 转换效果如图 4 所示。而后使用鸟瞰图中被检测目标像素点的信息变化情况对距离和车速进行计算:

$$D = \frac{F_{\text{camera}} \times W_{\text{real}}}{P_{\text{width}}} \quad (17)$$

$$V_{\text{det.cet}} = \frac{\sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \times W_{\text{real}}}{P_{\text{width}} \times T_p} \times 3.6 \quad (18)$$

式中: F_{camera} 为车载摄像头的相机焦距; W_{real} 为被检测目标真实宽度; P_{width} 为被检测目标在图像中所占像素宽度; (x_1, y_1) 和 (x_2, y_2) 分别为前一帧和当前帧被检测目标的中心坐标; T_p 为两帧之间的时间差; $V_{\text{det.cet}}$ 为相对车速。跟踪及检测效果如图 5 所示。




图4 逆透视变换效果图

为解决输入信息维度增加导致预测模型的预测精度变差这一问题, 本研究以 LSTM 网络作为单体, 将 3 个结构相同的 LSTM_1、LSTM_2 和 LSTM_3 网络




图5 特定区域的多目标检测及追踪效果图

进行链式递归构建了级联式 LSTM 神经网络车速预测模型,预测模型结构如图 6 所示。当车辆处于某交通场景时,目标车辆前方特定区域内车辆数目 (N_f)、车速 (V_f) 是对该时刻前方道路交通速度的体现,其会影响目标车辆与正前方车辆的车距 (D_f)、自车行驶车速 (V_0) 和自车加速度 (a_0)。故将 N_f 和 V_f 作为 LSTM_1 的输入,并将 LSTM_1 输出的信息与 D_f 作为 LSTM_2 的输入信息,再将 LSTM_2 的输出信息与 V_0 、 a_0 作为 LSTM_3 的输入信息,并最终得到目标车辆短时域内的车速预测信息 V_{pre} 。由于能量管理策略的优化性能受到预测水平和预测精度的综合影响,根据前人的相关研究,为兼顾速度预测精度和计算成本,本研究使用历史 6 s 内的行驶状态信息来预测未来 3 s 内的行驶状态信息。






图6 级联式车速预测模型结构

本研究采用实际情况下的道路行驶数据 Comma. ai 数据集作为仿真分析基础。Comma. ai 数据集是在美国高速公路驾驶环境下采集的真实驾驶数据,它由 11 个视频片段组成,其中一个车载摄像头安装在捕获屏幕的中间。该数据集包含了车载传感器所记录的自车行驶车速、纵向加速度等自车行驶数据以及车载摄像头拍摄的外部交通环境的图像视频数据。本研究采用基于时间戳的方法将原始 20 Hz 的图像数据与 100 Hz 的传感器数据进行对齐,并转化为 1 Hz 的统一时间基频率数据,以满足交通感知模型的实时性要求。进一步将视频片段进行组合并划分为训练集和测试集,分别命名为 com_01to05 和 com_06to11,其对应的速度轨迹如图 7 所示。图 8 显示了级联式预测器在测试集内的预测性能。为了进一步说明所提出的速度预测器的优越

性,将其与另外两种基准方法进行了比较,分别是径向基函数(radial basis function, RBF)神经网络和基于多特征输入的单层 LSTM 神经网络。为了表征速度预测的准确性,选择均方根误差(root mean square error, RMSE)、平均绝对误差(mean absolute error, MAE)和平方相关系数(squared correlation coefficient, SCC)作为评价指标。3 种预测方法在不同预测水平下的对比结果如表 2 所示。本文所构建的基于机器视觉的级联式 LSTM 车速预测模型与基于 RBF 的车速预测模型和基于多特征输入的单层 LSTM 车速预测模型训练及误差分析如表 2 所示。从表中可以看出相较于其它两种车速预测模型,本文所提出的基于机器视觉的级联式 LSTM 神经网络车速预测模型预测结果的 RMSE 和 MAE 值仅为 2.096 和 1.511 km/h,明显小于其他两种模型的预测误差。同时可以明显看出,通过对输入特征信息进行分层输入之后,整体预测模型的精度得到了极大幅度的提升,SCC 值从 79.95% 增至 99.85%。



(a) 训练工况



(b) 测试工况

图7 训练和测试样本车速数据




图8 车速预测值与实际值对比

表2 3种预测模型的结果

预测模型类型	RMSE/(km·h ⁻¹)	MAE/(km·h ⁻¹)	SCC/%
RBF神经网络	2.873	1.968	99.77
单层LSTM	10.570	8.610	79.95
级联式LSTM	2.096	1.511	99.85

2.3 MPC优化控制器

本研究采用基于模型预测控制对预测区间内控制序列进行优化求解,选取的求解算法为DP算法,其代价函数可表示为

$$\begin{cases} J_k = \int_{k\Delta t}^{(k+N_p)\Delta t} [\beta_1 Q_{\text{fuel}}(t) + \beta_2 Q_{\text{elec}}(t) + \psi(SOC(t))] dt \\ \psi(SOC(t)) = \varpi_1 |SOC(t) - SOC_{\text{ref}}(k + N_p)| \end{cases} \quad (19)$$

式中: J_k 为优化算法的优化目标函数,其中 $Q_{\text{fuel}}(t)$ 和 $Q_{\text{elec}}(t)$ 为当前时刻的燃油消耗量和电量消耗量, β_1 和 β_2 为与其对应的权重系数; ψ 为SOC跟踪约束函数, $SOC_{\text{ref}}(k + N_p)$ 为预测时域内最后时刻的SOC的参考值, ϖ_1 为SOC跟踪惩罚因子。单位时间步长下SOC值的变化相对比较小,为确保在滚动优化过程中良好的跟随效果,应选取较大的惩罚因子,本研究中选取 ϖ_1 为1000。

同时,因为基于E-DDPG算法的SOC轨迹规划

模型所得到的SOC轨迹整体变化比较稳定平滑,所以通过加入松弛因子来实现对SOC参考轨迹稳定平滑的追踪,具体表示为

$$\begin{aligned} (SOC_{\text{ref}}(k + N_p) - s_1) &\leq SOC(k + N_p) \leq \\ &(SOC_{\text{ref}}(k + N_p) + s_1) \end{aligned} \quad (20)$$

式中 s_1 为松弛因子,本研究将松弛因子设置为0.01,以获得优异的SOC跟踪性能。此外,基于被控对象PHEV动力系统的总体特征,整个优化问题受到一定的系统约束:

$$\begin{cases} T_{e_min} \leq T_e(k) \leq T_{e_max} \\ n_{e_min} \leq n_e(k) \leq n_{e_max} \\ T_{m_min} \leq T_m(k) \leq T_{m_max} \\ n_{m_min} \leq n_m(k) \leq n_{m_max} \\ SOC_{min} \leq SOC(k) \leq SOC_{max} \\ I_{batt_min} \leq I(k) \leq I_{batt_max} \\ P_{batt_min} \leq P(k) \leq P_{batt_max} \end{cases} \quad (21)$$

式中下标max和min为与之相对应物理量的最大值和最小值。

2.4 能量管理框架

根据以上内容,本研究提出的能量管理控制框架如图9所示,其主要由数据预处理层、行驶工况预测层、SOC参考轨迹规划层和MPC滚动优化控制层

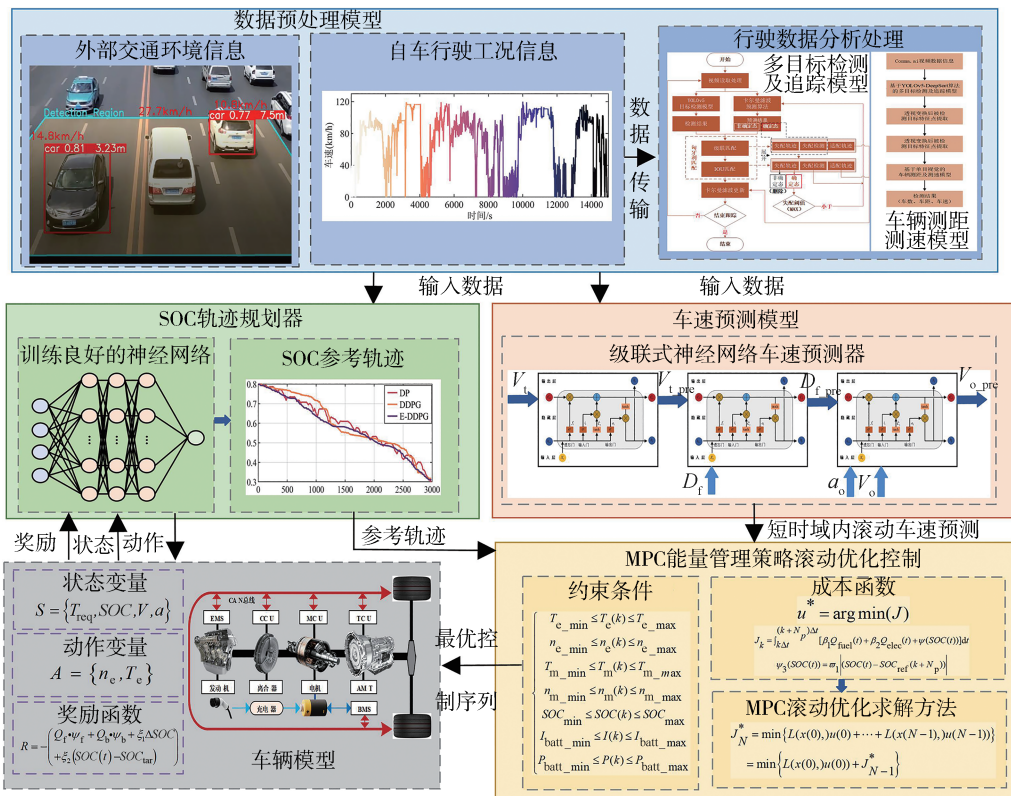


图9 能量管理控制框架

4部分组成。首先使用基于机器视觉的车速预测模型对未来车速序列进行预测,并使用SOC参考轨迹规划模型对未来车速序列进行轨迹规划,并将未来车速序列和SOC参考轨迹作为配备最优求解器的MPC控制模型的输入。MPC控制模型计算得到预测区间内的最优化控制序列,并将控制序列的第一个动作传输给被控系统进行更新,依次循环直至工况结束。

3 仿真测试及结果分析

3.1 SOC轨迹规划及适应性分析


本节首先对基于E-DDPG的SOC参考轨迹模型有效性和适应性进行验证,所有仿真均基于Python平台的TensorFlow框架进行,仿真平台为配备GHzAMD Ryzen 7 4800H处理器及16 GB内存的笔记本电脑。首先对比在静态全局工况下SOC轨迹的生成效果,图10对比了采用DP、DDPG和E-DDPG在com_06to11测试工况下的SOC轨迹曲线,以及两种强化学习算法与DP策略SOC轨迹曲线的绝对误差。从图10可以看出,3条轨迹曲线的整体变化情形相似,终止SOC均接近设定值0.3。但E-DDPG的SOC轨迹曲线下降趋势更加平稳,参考轨迹的最大绝对值误差为0.0285,较DDPG降低了0.0768,且误差曲线整体变化平稳,波动幅值小。表3对比了在com_06to11测试工况下SOC曲线各误差评价指标的具体数值,由表可知,E-DDPG生成的SOC参考轨迹更为精确,根据SCC值可以看出加入平衡因子优化后的轨迹与最优轨迹曲线相似度高达98.903%。

为验证所提出的基于E-DDPG的SOC规划模型泛化性能,在组合标准工况NEDC-WLTP下对模型进行验证。适应性验证工况信息如图11所示,该组合工况的最高车速为131 km/h,平均车速为41.23 km/h。而com_06to11测试工况最高车速为119.91 km/h,平均车速为70.78 km/h,两者在工况特性方面存在显著差异,满足泛化性验证需求。


如图12所示,在该验证工况下,E-DDPG算法仍具有良好的SOC规划能力,其有效地将终值SOC控制在0.3附近,且相较于DDPG算法曲线下降更为平缓。

3.2 SOC轨迹跟踪有效性验证

进一步对比了模型预测控制框架下不同SOC轨



(a) 电池SOC轨迹



(b) SOC轨迹绝对误差

图10 不同SOC轨迹规划模型的参考轨迹结果对比

表3 不同控制策略下的SOC曲线误差

策略	MAE	RMSE	SCC/%
DDPG	0.04135	0.04819	96.735
E-DDPG	0.01513	0.02133	98.903




图11 算法适应性验证工况




图12 验证工况下SOC轨迹规划情况

迹对能量管理策略的影响。要说明的是,基于E-DDPG、DQN、DP参考轨迹预测型能量管理策略下文简称为E-DDPG-SOC、DQN-SOC和DP-SOC。同时与一种广泛应用于能量管理领域的时间线性模型进

行对比,线性参考模型可表示为

$$SOC_{ref_time}(t+n) = SOC_{init} - \frac{t+n}{T}(SOC_{init} - SOC_{end}) \quad (22)$$

式中: SOC_{ref_time} 为时间线性模型规划的SOC参考轨迹值; SOC_{init} 和 SOC_{end} 表示动力电池组初始SOC和终止SOC; T 表示整个工况的总时间。

图13对比了DQN-SOC和Time-SOC的实际SOC变化曲线及相对应的参考曲线和跟踪误差。从图13可以看出模型预测控制框架的预测性和滚动时域优化性使得各种策略均具有良好的参考曲线跟踪能力。DQN-SOC和Time-SOC对参考曲线跟踪的最大绝对误差值分别为0.099和0.035,Time-SOC的跟踪能力比DQN-SOC要好,这是因为DQN-SOC的参考曲线在局部存在大幅度突变的情况,使得其跟踪性能有所下降。虽然Time-SOC的跟踪能力较好,但在真实行驶工况中车辆动力电池SOC值一定不是呈现出完全线性下降的趋势,且线性参考轨迹的设定依赖于经验,故适应性较差。E-DDPG-SOC和DP-SOC的实际SOC变化曲线及对相应参考曲线及跟踪误差,如图14所示。E-DDPG-SOC和DP-SOC的跟踪能力明显增强,两种方法对参考曲线跟踪的最大绝对误差值均低于DQN-SOC和Time-SOC的最大值,仅为0.0209和0.0247,且E-DDPG-SOC的跟踪误差整体小于DP-SOC。E-DDPG-SOC对SOC参考曲线的跟踪能力优于DP-SOC,这是因为相比于DP的被动计算,DDPG算法利用其强大的学习探索能力和泛化能力将实际行驶工况的非线性特性和混合动力汽车动力系统特性进行了综合考虑。

表4对比了各策略下实际SOC变化轨迹对与其相对应的SOC参考轨迹跟踪性能的评价指标。由表可见,E-DDPG-SOC的所有误差指标值明显小于DQN-SOC和Time-SOC,略小于DP-SOC,且E-DDPG-SOC的SCC值达到了99.86%。

3.3 节能效果及计算效率验证

图15对比了DP、DDPG、DP-SOC及E-DDPG-SOC的累积燃油消耗量曲线和电机转矩曲线。由图可知,DP、DP-SOC及E-DDPG-SOC三者的累积燃油消耗曲线变化趋势相似度比较高,这是因为DP-SOC和DDPG-SOC中MPC过程均采用DP算法进行求解。基于DP和基于DDPG的能量管理策略的累积燃油消耗分别为15.37和16.90 L,DP-SOC和E-DDPG-SOC分别为16.20和15.79 L。如图所示E-





图13 DQN-SOC和Time-SOC的SOC跟踪表现






图14 DP-SOC和E-DDPG-SOC的SOC跟踪表现


表4 不同控制策略下的SOC跟踪误差

策略	MAE	RMSE	SCC/%
DP-SOC	0.004 0	0.006 4	99.83
DQN-SOC	0.026 2	0.036 3	97.80
Time-SOC	0.005 5	0.009 7	99.63
E-DDPG-SOC	0.003 6	0.005 9	99.86

DDPG-SOC 和 DP-SOC 电机转矩变化趋势相似, 输出转矩较为平滑, 减少了 DDPG 策略下较多峰值扭矩的情况。



(a) 累计燃油消耗量



(b) 电机转矩

图 15 不同控制策略下的仿真结果对比


各能量管理策略经济性评价参数如表 5 所示。其中燃料成本和电力成本是以燃油价格 8 元/L 和充电桩电价 1.7 元/(kW·h) 计算。如表所示, 以全局最优的 DP 能量管理策略经济性为对比分析的参考值, DP-SOC 和 E-DDPG-SOC 由于其参考曲线的高度相关性, 导致其经济性相差仅 2.32%, 且分别达到了 DP 的 95.61% 和 97.93%。然而 DDPG 的经济性仅为 DP 的 92.27%, 较 E-DDPG-SOC 经济性降低了 5.66%, 这是因为 DDPG 算法虽然融合了深度学习的感知能力和强化学习的决策能力, 但是探索学习过程中忽略了车辆未来交通情况的时变性和不确定性。

表 5 不同控制策略下的成本及经济性对比

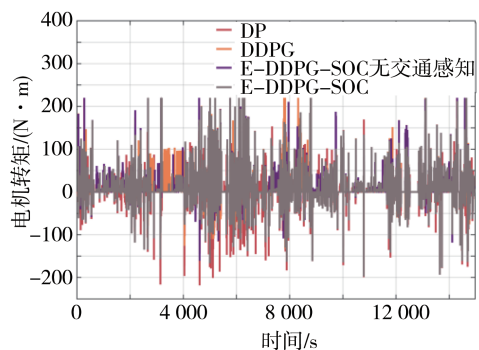
策略	总油耗/L	电力/(kW·h)	总成本/元	经济性/%
DP	15.37	16.43	139.39	100
DDPG	16.90	15.85	151.07	92.27
DP-SOC	16.20	16.16	145.79	95.61
E-DDPG-SOC	15.79	16.04	141.77	97.93

本研究进一步分析了外部交通信息对于 EMS 的影响, 图 16 对比了 DP、DDPG、忽略交通感知的 E-DDPG-SOC 及 E-DDPG-SOC 的累积燃油消耗量曲

线和电机转矩曲线。由图可见, E-DDPG-SOC 将自行车外部的交通信息作为 MPC 预测输入, 从而提升了 MPC 对未来行驶工况的预测精度, 相较其他策略具有最小的累计燃油消耗量。从图可以看出 E-DDPG-SOC 的电机转矩分配情况比忽略交通感知的 E-DDPG-SOC 更加接近 DP, 但转矩分配相差不大, 所以 E-DDPG-SOC 的电力成本并没有明显的降低。E-DDPG-SOC 和 DDPG-SOC 的经济性评价如表 6 所示, 从表中可以更为直观地印证上述关于两类能量管理策略的分析, E-DDPG-SOC 的累积燃油消耗较忽略交通感知的 E-DDPG-SOC 节省了 0.56 L, E-DDPG-SOC 的经济性比忽略交通感知的 E-DDPG-SOC 提升了 2.92%, 达到了 DP 的 97.93%。这也进一步表明交通感知对于对未来短时段内车速预测精度的提升, 从而进一步提升能量管理策略的性能。



(a) 累计燃油消耗量



(b) 电机转矩

图 16 不同交通感知模型下的仿真结果对比

表 6 交通感知模型成本及经济性对比

策略	总油耗/L	电力/(kW·h)	总成本/元	经济性/%
DP	15.37	16.43	139.39	100
E-DDPG-SOC 无交通感知	16.35	15.93	146.71	95.01
E-DDPG-SOC	15.79	16.04	141.77	97.93

进一步对本研究所提出策略的实时性进行分析。从计算时间的角度对所提出策略的实时性进行验证, 计算时间包括 SOC 参考规划时间和 MPC 控制

器计算时间。SOC参考规划时间仅对E-DDPG-SOC和DP-SOC进行比较。MPC控制器计算时间为预测时域3 s内各控制步长的平均计算时间。各策略的计算时间比较如表7所示,可以看出,DP-SOC方法的SOC参考规划时间大于24 min,这对于实时应用来说是不切实际的,而E-DDPG-SOC方法的规划时间仅为11.64 s。此外,MPC控制器的计算时间也非常接近。对于E-DDPG-SOC,一个控制步长的总计算时间仅为0.214 s,小于1 s的控制步长要求,满足了基于MPC的EMS在线应用的要求,证明MPC框架下的有效性,表明所提出的策略具有极大的在线应用潜力。

表7 不同控制策略下的计算时间对比

策略	计算时间/s	
	SOC规划	MPC控制器计算
E-DDPG-SOC	11.64	0.214
DP-SOC	1496.24	0.237

4 结论

本文以插电式混合动力汽车为研究对象,提出了一种将基于机器视觉的级联式LSTM车速预测模型、基于E-DDPG算法的SOC参考轨迹规划模型与MPC框架相结合的预测型能量管理策略。主要总结如下:

(1)构建融合机器视觉的交通感知车速预测模型,采用级联式LSTM结构建立了满足预测精度要求的预测模型,车速预测的平均绝对误差MAE仅为1.511 km/h,且与实际车速的平方相关系数SCC为99.85%。

(2)将基于DP算法的电池SOC变化轨迹作为对比基准,本文所构建的基于E-DDPG算法的SOC参考轨迹规划模型与DDPG算法相比平均误差降低了0.076 8,且整体SOC轨迹曲线与DP的SOC轨迹曲线的相关系数SCC为98.903%。

(3)本文所构建的E-DDPG-SOC整车经济性可以达到全局最优(基于DP的能量管理策略)的97.93%,且比基于DDPG算法能量管理策略的经济性提高了5.66%,较忽略交通感知的E-DDPG-SOC能量管理策略提高了2.92%。同时E-DDPG-SOC的计算效率满足实时控制要求,表现出极大的在线应用潜力。

参考文献

- [1] 陈轶嵩,兰利波,郝卓,等.面向碳中和的新能源汽车全生命周期评价研究综述及趋势展望[J].汽车工程学报,2022,12(4):360-374.
CHEN Y S, LAN L B, HAO Z, et al. Review and future prospects of life cycle assessment of new energy vehicles towards carbon neutrality [J]. Chinese Journal of Automotive Engineering, 2022, 12(4): 360-374.
- [2] 朱镇,曾令新,林勇刚,等.融合工况预测的混合动力拖拉机自适应能量管理策略[J].西安交通大学学报,2023,57(12):201-210.
ZHU Z, ZENG L X, LIN Y G, et al. Adaptive energy management strategy for hybrid tractors based on condition prediction [J]. Journal of Xi'an Jiaotong University, 2023, 57(12): 201-210.
- [3] 王跃飞,王志,孙睿,等.基于驾驶意图多步预测的智能网联HEV等效排放最小控制策略[J].机械工程学报,2023,59(18):271-282.
WANG Y F, WANG Z, SUN R, et al. Equivalent emission minimization strategy of intelligent connected HEV based on multi-step prediction of driving intention [J]. Journal of Mechanical Engineering, 2023, 59(18): 271-282.
- [4] 黄康,王强,邱明明,等.考虑模式切换频率的多模式混合动力汽车参数优化[J].西安交通大学学报,2019,53(7):99-107.
HUANG K, WANG Q, QIU M M, et al. Parameter optimization of multi-mode hybrid vehicle considering mode switching frequency [J]. Journal of Xi'an Jiaotong University, 2019, 53(7): 99-107.
- [5] 施德华,袁超,汪少华,等.考虑驾驶风格的混合动力汽车强化学习能量管理策略[J].西安交通大学学报,2024,58(10):51-62.
SHI D H, YUAN C, WANG S H, et al. Reinforcement learning energy management strategy for hybrid electric vehicle considering driving style [J]. Journal of Xi'an Jiaotong University, 2024, 58(10): 51-62.
- [6] TRAN D, VAFAEIPOUR M, BAGHDADI M, et al. Thorough state-of-the-art analysis of electric and hybrid vehicle powertrains: topologies and integrated energy management strategies [J]. Renewable and Sustainable Energy Reviews, 2020, 119: 109596.
- [7] YANG C, DU X L, WANG W D, et al. Variable optimization domain-based cooperative energy management strategy for connected plug-in hybrid electric vehicles [J]. Energy, 2024, 290: 130206.
- [8] 施德华,容香伟,汪少华,等.基于功率比的混合动力汽车模糊自适应等效燃油消耗最小策略研究[J].西安交通大学学报,2022,56(1):12-21.
SHI D H, RONG X W, WANG S W, et al. Fuzzy adaptive equivalent consumption minimization strategy for hybrid electric vehicle based on power ratio [J]. Journal of Xi'an Jiaotong University,

- ty, 2022, 56(1): 12–21.
- [9] LIU X D, DU J, MA J, et al. An adaptive co-state design method for PMP-based energy management of plug-in hybrid electric vehicles based on fuzzy logical control [J]. *Journal of Energy Storage*, 2024, 102: 114118.
- [10] CHAI H, ZHAO X, YU Q, et al. Adaptive equivalent consumption minimization strategy based on road grade estimation for a plug-in hybrid electric truck [J]. *Journal of Energy Storage*, 2023, 70: 108035.
- [11] JU F, MURGOVSKI N, ZHUANG W C, et al. Predictive energy management with engine switching control for hybrid electric vehicle via ADMM [J]. *Energy*, 2023, 263: 125971.
- [12] LI Y P, WANG F, TANG X L, et al. Convex optimization-based predictive and bi-level energy management for plug-in hybrid electric vehicles [J]. *Energy*, 2022, 257: 124672.
- [13] 齐春阳, 宋传学, 宋世欣, 等. 基于逆强化学习的混合动力汽车能量管理策略研究 [J]. *汽车工程*, 2023, 45(10): 1954–1964, 1974.
- QI C Y, SONG C X, SONG S X, et al. Research on energy management strategy for hybrid electric vehicles based on inverse reinforcement learning [J]. *Automotive Engineering*, 2023, 45(10): 1954–1964, 1974.
- [14] HE H W, MENG X F, WANG Y, et al. Deep reinforcement learning based energy management strategies for electrified vehicles: recent advances and perspectives [J]. *Renewable and Sustainable Energy Reviews*, 2024, 192: 114248.
- [15] DU G D, ZOU Y, ZHANG X D, et al. Deep reinforcement learning based energy management for a hybrid electric vehicle [J]. *Energy*, 2020, 201: 117591.
- [16] TANG X L, CHEN J X, PU H Y, et al. Double deep reinforcement learning-based energy management for a parallel hybrid electric vehicle with engine start-stop strategy [J]. *IEEE Transactions on Transportation Electrification*, 2022, 8(1): 1376–1388.
- [17] ZHANG J, TAO J, HU Y, et al. An energy management strategy based on DDPG with improved exploration for battery/supercapacitor hybrid electric vehicle [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(5): 3999–4008.
- [18] TANG X L, ZHANG J M, PI D W, et al. Battery health-aware and deep reinforcement learning-based energy management for naturalistic data-driven driving scenarios [J]. *IEEE Transactions on Transportation Electrification*, 2022, 8(1): 948–964.
- [19] 袁田, 赵轩, 刘瑞, 等. 考虑交通参与者的城市交叉口车速预测模型 [J]. *东南大学学报(自然科学版)*, 2023, 53(2): 326–333.
- YUAN T, ZHAO X, LIU R, et al. Speed prediction model at urban intersections considering traffic participant [J]. *Journal of Southeast University (Natural Science Edition)*, 2023, 53(2): 326–333.
- [20] HUI L, LI X M, WANG W D, et al. Markov velocity predictor and radial basis function neural network based real-time energy management strategy for plug-in hybrid electric vehicles [J]. *Energy*, 2018, 152: 427–444.
- [21] XIE S, HU S S, TANG X L, et al. Model predictive energy management for plug-in hybrid electric vehicles considering optimal battery depth of discharge [J]. *Energy*, 2019, 173: 667–678.
- [22] LI G P, ZHANG J L, HE H. Battery SOC constraint comparison for predictive energy management of plug-in hybrid electric bus [J]. *Applied Energy*, 2017, 194: 578–587.
- [23] LIU Y G, LI J, CHEN Z, et al. Research on a multi-objective hierarchical prediction energy management strategy for range extended fuel cell vehicles [J]. *Journal of Power Sources*, 2019, 429: 55–66.
- [24] GUO L X, ZHANG X D, 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.
- [25] TANG X L, JIA T, HU X S, et al. Naturalistic data-driven predictive energy management for plug-in hybrid electric vehicles [J]. *IEEE Transactions on Transportation Electrification*, 2020, 7(2): 497–508.
- [26] HE H W, HUANG R C, MENG X F, et al. A novel hierarchical predictive energy management strategy for plug-in hybrid electric bus combined with deep deterministic policy gradient [J]. *Journal of Energy Storage*, 2022, 52: 104787.