

# 基于混合深度神经网络的燃料电池混合动力汽车 能量管理优化研究

何宋杰, 吕学勤

(上海电力大学 自动化工程学院, 上海 200090)

**摘要:** 为提升燃料电池混合动力汽车在短程驾驶过程中的燃油经济性, 文章构建了一种基于混合深度神经网络的车速预测模型 VBS-Net。该模型不仅进一步改良了基于 VGG-Net 结构的卷积网络, 还引入了双向长短期记忆神经网络, 对整个车速预测序列的时空依赖关系进行有效学习。同时考虑预测时域和输入序列长度对短程车速预测精度的影响, 利用贝叶斯优化超参数进一步提升 VBS-Net 的预测精度。为解决能量管理策略的在线优化和计算效率问题, 设计了一种基于多目标优化的模型预测控制(MPC)能量管理策略。该策略可以实现对氢气消耗、锂电池充电状态(SOC)维持、燃料电池使用效率三者的平衡优化。最后在3种实车工况下, 将所提策略与基于规则的策略相比, 燃油经济性分别提升了7.25%, 9.94%和19.23%, 且有更好的SOC维持特性。

**关键词:** 深度学习; 贝叶斯优化; 能量管理策略; 速度预测

**中图分类号:** TK01; TM911 **文献标志码:** A **文章编号:** 1671-5292(2024)08-1127-10

## 0 引言

全球范围内的能源危机与环境污染问题不断加剧, 促使现代汽车行业在能源结构调整和环境保护背景下寻求变革<sup>[1]</sup>。而燃料电池混合动力汽车(FCHEV)目前被认为是最具发展前景的新能源汽车形态, 但续航性能差、能耗高等问题限制了其在工商业领域的应用和覆盖<sup>[2,3]</sup>。能量管理策略(EMS)作为提升混合动力系统能量利用率、延长续航里程的有效解决途径, 可以通过合理分配不同动力源的功率需求提升整车性能<sup>[4]</sup>。速度预测作为车辆需求功率预测中的重要环节, 其准确性将直接影响EMS的优化效果。

近年来, 随着机器学习和人工智能算法研究的不断深入, 人工神经网络、深度强化学习、支持向量机等学习型EMS迅速发展。通过对驾驶工况的特征提取和数据的训练学习, 学习型EMS不仅在优化性方面可以得到全局最优, 而且在实时性方面的表现也得到了显著提升<sup>[5]</sup>。速度预测作为学习型EMS中不可或缺的组成部分, 可以提供实时准确的驾驶员行为预测, 实现更好的燃料经济性和能量利用效率。Francesc C L<sup>[6]</sup>选取西班牙马德里的两类交通数据进行分析, 通过建立车速与能量消耗、停车率百分比等

交通控制因素的数学关系构建多元线性回归模型, 最终有效提升了汽车的能量利用率。Quan S<sup>[7]</sup>将指数平滑和马尔可夫修正相结合进行速度预测, 以此获得更准确的功率需求信息, 结果表明, 该策略可以有效提升预测精度。但这两类方法多用于处理简单驾驶环境下的车速预测, 无法有效捕捉历史车速和未来车速的长期依赖关系, 且对复杂驾驶环境下的高度非线性关系的拟合效果还有很大提升空间, 鲁棒性较差。

基于机器学习的速度预测方法可以有效解决上述方法存在的不足, 并且随着深度强化学习在多领域取得的突破性进展, 将深度强化学习用于车速预测逐渐成为研究热点。深度强化学习不仅可以通过深度神经网络有效提取数据特征进行预测输出, 还可以利用强化学习框架进行决策优化, 从而提高燃料电池混合动力汽车EMS的能量利用效率<sup>[8]</sup>。然而随着输入车速数据数量的增加和控制因素带来的维度上升, 基于机器学习的速度预测方法同样会陷入预测精度下降的难题。对于燃料电池混合动力系统能量管理优化需要高预测精度的问题, 单神经网络存在因数据处理和特征提取能力不足、高度非线性条件下预测精度低以

收稿日期: 2024-02-23。

基金项目: 国家自然科学基金(52075316); 上海市地方院校能力建设项目(23010501400)。

通信作者: 吕学勤(1974-), 女, 博士, 教授, 主要从事燃料电池汽车混合动力系统能量管理、多传感器信息融合与路径规划和电动汽车制动能回收的研究。E-mail: lvxueqin@shiep.edu.cn

及泛化能力有限而导致过拟合现象<sup>[9]</sup>。

本文利用一维卷积神经网络(CNN)和双向长短时记忆(BILSTM)神经网络搭建混合神经网络的结构。CNN 特有的局部感受野和权值共享的特性可有效减少参数训练量,池化层的引入可以降低特征维度、提高计算效率,同时避免过拟合现象。对于具有很强时序特征和复杂依赖关系的时间序列,BILSTM 神经网络可以同时基于历史和未来信息进行学习,增加模型深度和提高适应性的同时,更有效地捕捉输入数据的多重依赖关系。此外,针对基于优化的控制策略存在的计算量和实时性缺陷,本文设计了一种基于多目标优化的模型预测控制(MPC)-EMS,并在 MPC 的滚动优化环节中加入动态规划算法(DP)优化计算成本,以达到更好的能量利用效果。

### 1 燃料电池混合动力汽车系统建模

混合动力系统拓扑结构的设计和选择对不同动力源输出功率的分配方式和整车性能参数有直接影响。本文选取的 FCHEV 的拓扑结构如图 1 所示,其中质子交换膜燃料电池(PEMFC)作为主动力输出源提供持续稳定的低频输出功率,锂电池作为辅助动力源提供高频瞬时输出功率和回收部分制动能量。两者分别通过单向 DC/DC 变换器和双向 DC/DC 变换器将功率传输到直流母线上,再经由 DC/AC 变换器向驱动电机供电。整个能量传输过程中,PEMFC 始终保持向直流母线充电,锂电池基于实时状态对母线进行充放电。当混合动力汽车处于启停、加减速等瞬时功率需求大的路况时,锂电池对瞬态变化的高响应反馈可以有效弥补燃料电池在瞬时高功率环境下动态特性差的不足,从而保证燃料电池始终工作在高效运行区间。而当混合动力汽车处于平稳路况时,燃料电池可以持续不断地提供稳定输出功率,锂电池




图 1 燃料电池混合动力汽车拓扑结构  
Fig.1 The topology of fuel cell hybrid electric vehicle

则是进入充电状态。能量管理系统通过将控制量输入 DC/DC 变换器实现对子系统的控制,具有协调各控制模块间的协同性、改善电力系统负荷影响、优化各功率输出源比例分配的作用。

综合上述分析,这种间接型拓扑结构不仅具有高系统兼容性,还可以抑制 PEMFC 的输出电压波动。此外,该结构中通过控制 DC/DC 变换器可以使燃料电池输出电压波动较小,从而有效提高系统的能量利用率<sup>[10]</sup>。

#### 1.1 燃料电池效率模型

构建燃料电池效率模型可准确分析其输出功率和最佳工作效率区间,并使氢气利用率最大化。该模型的理论效率定义为燃料电池反应过程中产生的理论热能和供给氢气反应产生的能量之比。

$$\eta_{fc} = \frac{V_{fc} i_{fc}}{-2\Delta H_{LHV} F i_{fc}} \quad (1)$$

式中: $\eta_{fc}$  为燃料电池理论效率; $V_{fc}$  和  $i_{fc}$  分别为燃料电池对应的电压和电流; $F$  为法拉第常数; $\Delta H_{LHV}$  为氢气热值。

#### 1.2 锂电池模型

锂电池作为混合动力汽车的辅助能源,其荷电状态将直接影响驱动控制策略。本文在 Rint 等效电路模型的基础上,考虑电压极化效应,构建锂电池等效极化模型。当锂电池处于辅助供电状态时,结合驱动电机的功率,计算总线电流  $I$ 。其充电状态的 SOC 计算表达式如下:

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

式中: $U_o$  为开路电压; $R_i$  为内阻; $\eta$  为驱动电机机电转换效率; $\omega_m, T_m$  分别为电机对应状态下的瞬时转速、瞬时转矩; $Q$  为电池容量。

### 2 车速预测

利用该 FCHEV 在标准工况下行驶的历史车速数据作为输入,对未来短程时间段的车速进行预测。利用周期分解算法(STL)对车速数据序列进行分解,将所得特征分量输入 CNN 进行特征提取,再将所得结果输入 BILSTM 神经网络,对数据的时空依赖关系进行学习,最后输出未来短程车速预测结果。

2.1 STL 法

历史车速数据序列作为一种典型的时间序列数据,在驾驶行程中通常会因交通流量的变化而产生周期性波动、噪声增加、趋势变化等问题<sup>[11]</sup>。而时序 STL 基于数据特征对周期项和趋势项进行有效分离,使数据输入神经网络后可以集中处理剩余项,即实现数据聚焦。此外,在分离后将噪声部分并入剩余项可以减少噪声带来的干扰,提高预测精度。总的来说,STL 的基本思想是先采用局部回归方法对时间序列进行平滑处理,以此捕捉趋势和季节性信息,再将其从原始序列中移除。

STL 在  $t$  时刻的分解表达式如下:

$$Y_t = T_t + S_t + R_t \quad t=1, 2, \dots, N \quad (3)$$

式中:  $T_t$  为趋势项;  $S_t$  为周期项;  $R_t$  为剩余项;  $N$  为时间序列数据的样本数。

该算法通过采用内外循环的方式,利用 LOESS (一种用于对局部估计的散点图进行平滑处理的技术方法) 和中位数展开技术对趋势和周期性分量进行迭代拟合和平滑处理,以最小化噪声和异常数据的影响,提高时序分解的稳定性和精度。

2.2 混合深度学习网络的构建

BP 神经网络、RBF 径向基神经网络、LSTM 神经网络等常见的神经网络,在车速预测方面也有不错的表现,但随着数据维度和体量的上升以及时序数据的复杂化,单一神经网络存在数据提取不充分、模型过拟合和梯度爆炸等问题,从而影响预测精度<sup>[12,13]</sup>。

本文利用 CNN 和 BiLSTM 神经网络进行混合神经网络结构的搭建。对于车速预测问题,1D-CNN 在特征提取过程中涉及到的参数量较少,数据维度匹配,进一步降低了计算成本。整个过程主要是输入数据经过多层卷积操作后生成对应的特征图,然后利用激活函数层提取非线性关系,再通过池化层降低特征维度,最后经扁平层重组数据形状,为后续输入 BiLSTM 神经网络做准备。

BiLSTM 神经网络结构所独有的门控机制和记忆单元能捕捉时序数据的长期依赖关系,对应计算模块的计算过程如下:

$$f_t = \sigma(W_f \cdot [C_{t-1}, h_{t-1}, x_t] + b_f) \quad (4)$$

$$i_t = \sigma(W_i \cdot [C_{t-1}, h_{t-1}, x_t] + b_i) \quad (5)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (7)$$

$$o_t = \sigma(W_o \cdot [C_t, h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (9)$$

式中:  $f_t$  为遗忘门,判断先前的输入信息是否需要遗忘;  $i_t$  为输入门,判断筛选传递和更新的信息;  $\tilde{C}_t$  为候选细胞状态;  $C_t$  为细胞状态,用于存储、传递各类信息;  $o_t$  为输出门,决定输出的信息。

基于上述分析,本文构建了 VBS-Net 模型用于 FCHEV 的短程车速预测,如图 2 所示。将历史车速作为输入数据输入一维卷积层进行特征提取后,再通过两次二维卷积层进一步全面捕捉空间和通道上的特征。在每个卷积层中均引入最大池化层、Relu 函数激活层和批量归一化层进行数据处理,最后经过平滑处理输入 BiLSTM 神经网络。

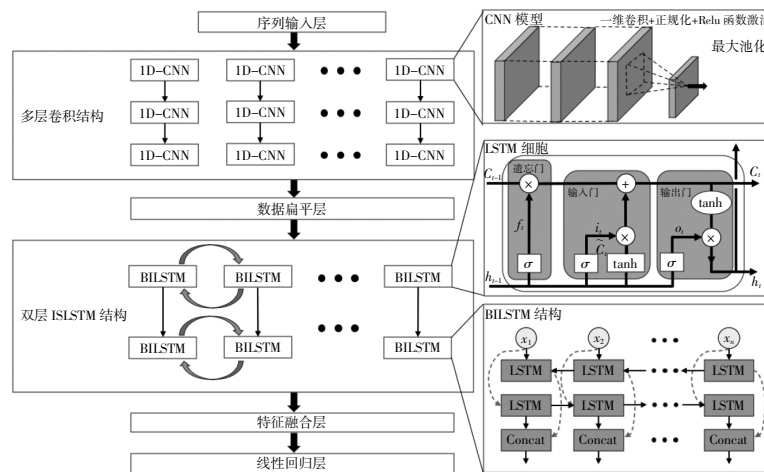


图 2 VBS-Net 结构

Fig.2 The structure of VBS-Net

而两层 BILSTM 神经网络对数据进行时空依赖关系的学习, 经由丢失层提高泛化性能后输入全连接层, 完成车速预测。

### 2.3 贝叶斯优化超参数

混合神经网络拥有复杂结构的网络模型, 其超参数的设置对于最后的预测精度有直接的影响。目前用于 FCHEV 车速预测问题的超参数优化方法有网格搜索、粒子群优化算法、随机搜索、贝叶斯(Bayes)优化等<sup>[4]</sup>。其中: 对于具有高参数维度的情况, 网格搜索和随机搜索的计算成本太高; 遗传算法和粒子群优化算法虽然计算效率高, 但存在调参困难等问题。

贝叶斯优化算法可以通过已有的评价结果逐步寻找最优的参数组合。该方法以贝叶斯公式为基础, 通过选取最优点, 更新参数空间, 并使用高斯过程回归模型将样本点转化为输出概率分布, 然后根据超参数的输出概率在样本点中选取合适的点。其中全局最优值和目标函数值之间的关系表达式如下:

$$x^* = \operatorname{argmax}_{x \in U} f(x) \quad (10)$$

式中:  $x$  为待优化的超参数组合;  $U$  为搜索空间;  $f(x)$  为反映准确度关系的高度非线性黑盒函数。

### 2.4 评价指标

本文选取平均绝对百分比误差 (MAPE)、均方根误差 (RMSE) 和决定系数 ( $R^2$ ) 3 个指标, 综合评价所提混合神经网络预测模型的精度。其中: MAPE 和 RMSE 作为在预测建模领域被广泛使用的评价指标, 可以从两个不同角度直观地评估预测精度, MAPE 和 RMSE 的值越小, 说明模型的预测精度越高; 而  $R^2$  则是衡量模型拟合程度的重要指标,  $R^2$  的值越接近于 1, 说明模型的拟合效果越好。同时评估上述 3 个指标可以有效达成指标间的互补, 从而对预测模型有一个全面的评估结果。具体表达式如下:

$$\text{MAPE} = \frac{100\%}{N} \sum_{i=1}^N \frac{|v_i - \hat{v}_i|}{v_i} \quad (11)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (v_i - \hat{v}_i)^2} \quad (12)$$

$$R^2 = \frac{\sum_{i=1}^N \left( \hat{v}_i - \frac{1}{N} \sum_{i=1}^N v_i \right)^2}{\sum_{i=1}^N \left( v_i - \frac{1}{N} \sum_{i=1}^N v_i \right)^2} \quad (13)$$

式中:  $v$  为实际车速值,  $v = \{v_1, v_2, \dots, v_n\}$ ;  $\hat{v}$  为预测车速值,  $\hat{v} = \{\hat{v}_1, \hat{v}_2, \dots, \hat{v}_n\}$ ;  $N$  为样本数。

### 3 基于模型预测控制的能量管理策略

MPC 作为最优控制的一个重要分支, 适用于具有约束和不确定性的非线性系统。MPC 算法的本质是通过构建预测模型获得系统未来一段时间的状态信息, 设计目标函数和约束条件, 通过求解获得目标函数的最优解并应用于系统, 最后基于系统实时反馈的状态信息对系统模型进行更新, 实现控制策略的动态调整和优化。

在混合动力系统的 EMS 研究中, MPC 算法具有在线求解多输入多输出系统 (MIMO) 的特点, 通过计算若干子问题的局部最优解, 获得整体控制策略的全局最优解。此外, 对于控制策略的多约束性问题, MPC 算法基于算法结构特点, 能在确保满足多个参数约束的前提下实现最优解。

在实际的混合动力汽车能量管理系统中, 还应考虑电池的 SOC 规划, 确保电池电量保持在合理的水平。合理规划 SOC 轨迹相当于确定每次的功率分配趋势, 在保证动态响应能力的同时, 提高了 FCHEV 运行的经济性, 这是 EMS 能否接近全局最优的决定性因素。MPC-EMS 的整体结构如图 3 所示, 其主要控制过程分为参数预测、SOC 轨迹规划与系统约束、滚动优化、反馈修正 4 个部分。

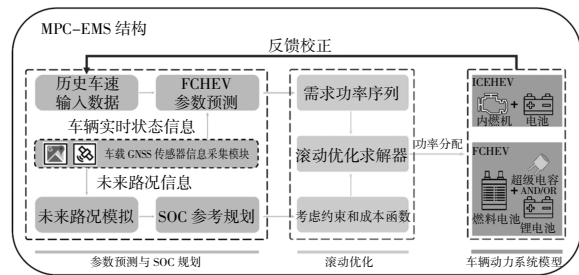


图 3 MPC-EMS 整体结构

Fig.3 The whole structure of MPC-EMS

首先根据历史运行信息构建预测模型, 将历史数据与当前状态相结合, 预测未来有限域中的状态变化; 其次定义系统优化对象, 考虑电池特性和系统约束, 根据当前状态预测未来 SOC 变化, 并根据具体优化算法规划最优轨迹; 再次利用求解算法在预测时域内寻找最优的功率分配组合; 最后将滚动优化过程中获得的状态信息应用到系

统中,更新 FCHEV 状态并进行再次预测。根据新的预测信息,计算并优化功率分配,实现反馈校正。上文已经通过搭建 VBS-Net 预测模型完成对系统速度状态的预测演化,故本节的重点是设计目标函数及优化求解算法。

FCHEV 的能量管理策略通常涉及大量性能指标和约束条件,性能指标之间又互相存在大量关联性。为平衡不同性能指标在系统中的权重,实现整体性能的最优化,本文从燃料电池效率、锂电池 SOC 和氢气消耗 3 方面对 FCHEV 进行多目标优化设计。整个目标函数由三大部分组成,分别对应 FCHEV 系统的三维输出向量。

①燃料电池输出效率代价函数

对于燃料电池混合动力系统来说,维持燃料电池工作在高效率区间有助于提高能量利用率。代价函数设计如下:

$$J_{fc}(t) = -\|y_1(t)\|_2^2 \quad (14)$$

式中: $J_{fc}(t)$ 为  $t$  时刻的燃料电池输出效率代价函数; $y_1(t)$ 为燃料电池输出效率的一维列向量表达式。

②锂电池 SOC 维持代价函数

锂电池 SOC 的维持对燃料电池混合动力系统的稳定性及电池自身寿命都有至关重要的作用,其代价函数设计如下:

$$J_{bat}(t) = \|y_2(t) - Bat_{soc}(t)\|_2^2 \quad (15)$$

式中: $J_{bat}(t)$ 为  $t$  时刻锂电池 SOC 维持代价函数; $y_2(t)$ 为锂电池 SOC 的一维列向量表达式; $Bat_{soc}(t)$ 为  $t$  时刻锂电池 SOC 值。

③氢气消耗成本代价函数

降低 FCHEV 的氢气消耗量可以有效提升系统的整体经济性,其相应的代价函数设计如下:

$$J_{H_2}(t) = \|y_3(t+T)\|_2^2 \quad (16)$$

式中: $J_{H_2}(t)$ 为一个周期内的最小氢气消耗量; $y_3(t)$ 为氢气消耗量的一维列向量表达式。

综合上述分析,本文的总目标函数和最优控制问题的表达式分别为

$$J(t) = \sum_{j=0}^{N-1} [\zeta_1 J_{fc}(t+j) + \zeta_2 J_{bat}(t+j) + \zeta_3 J_{H_2}(t+j)] \quad (17)$$

$$J_{min}[x(t)] = \min J(t) \quad (18)$$

对应的约束条件为

$$\begin{cases} P_{fc\_min} < P_{fc}(t) < P_{fc\_max} \\ \Delta P_{fc\_min} < \Delta P_{fc}(t) < \Delta P_{fc\_max} \\ SOC_{min} < SOC(t) < SOC_{max} \\ P_{fc}(t) + P_{bat}(t) = P_v(t) \end{cases} \quad (19)$$

式中: $P_{fc\_max}$ 和  $P_{fc\_min}$ 分别为燃料电池输出功率的上、下限; $\Delta P_{fc\_max}$ 和  $\Delta P_{fc\_min}$ 分别为燃料电池输出变化率的上、下限; $SOC_{max}$ 和  $SOC_{min}$ 分别为锂电池 SOC 的上、下限; $P_v(t)$ 为整车需求功率。

4 仿真与结果

4.1 VBS-Net 的预测精度分析

本文以一辆 24 V 燃料电池混合动力小车作为实验对象,车辆的具体参数如表 1 所示。

表 1 车辆主要部件参数

Table1 The parameters of main vehicle components

主要部件	参数	数值
整车	整车质量/kg	30
	电机额定转速/r·min <sup>-1</sup>	3 000
	驱动轮半径/mm	200
	转动惯量/kg·mm <sup>2</sup>	2.6
燃料电池	额定功率/W	600
	额定效率/%	42
锂离子电池	额定容量/Ah	5.87
	最大容量/Ah	6.5
	最大放电电流/A	2.6
	完全充电电压/V	25

本文选取轻型汽车全覆盖测试工况(WLTP)、市郊循环测试工况(EUDC)、城市道路循环测试工况(UDDS)、新标欧洲循环测试工况(NEDC)4种标准工况构建循环工况库,用于训练 VBS-Net 模型的预测性能,其车速曲线如图 4 所示。该工况样本包含了城市、高速公路和乡村等多种路况条件,且同时涵盖了频繁启停、高低速切换等模式下的样本数据,这些信息可以提供给 VBS-Net 大量的训练参考数据。




图 4 循环工况组合车速曲线

Fig.4 The combined vehicle speed curve under cycle conditions

4.1.1 不同神经网络预测结果分析

基于短程车速预测 EMS 的功率需求及综合考虑车速预测的实时性, 本文选取 5, 10, 15, 20 s 4 组不同预测时域对速度进行预测, 预测效果如

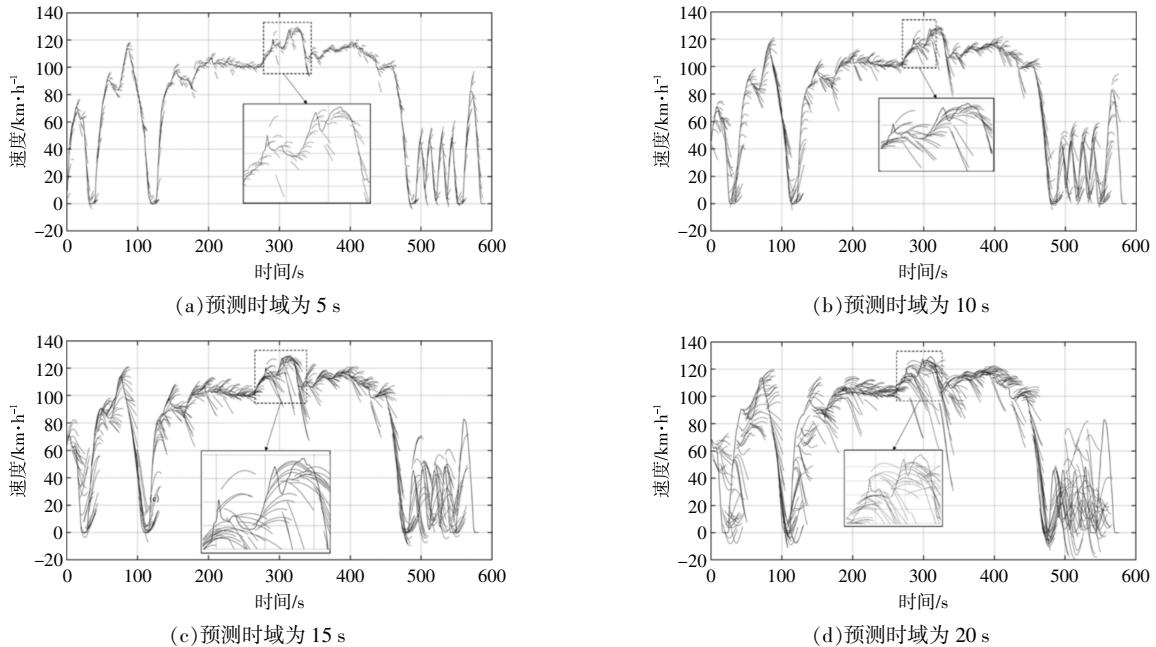


图 5 不同预测时域效果对比

Fig.5 The comparison of different prediction time domain effects

考虑车速预测的实时性问题, 利用实验平台中的深度学习网络设计器搭建 VBS-Net 预测模型。卷积层主要由一维卷积层、批量归一化层、Relu 函数激活层和最大池化层构成。BILSTM 神经网络层主要由输入层、两层隐藏层、丢失层和输出层构成。

选择 US06 工况作为测试工况, 将所提出的 VBS-Net 与 CNN, LSTM, RBF 以及 CNN-LSTM 进行对比研究, 预测结果如图 6 和表 2 所示。从表 2 中的数据分析可以看出, RBF 神经网络虽然预测用时很短, 但对于速度变化较为剧烈的区间, 无法




图 6 US06 工况下不同网络预测精度效果

Fig.6 The prediction accuracy effect of different networks under US06 working condition

图 5 所示。随着预测时域的不断增加, 模型的预测精度下降。为保证实验的准确性, 本文选择将历史输入序列长度和预测时域长度同时设置为 5 s 进行后续实验。

表 2 US06 工况下模型预测精度对比

Table 2 The comparison of model prediction accuracy under US06 working condition

	US06 working condition				km/h
误差指标	RBF	CNN	LSTM	CNN-LSTM	VBS-Net
RMSE	7.213	4.124	2.357	1.639	1.405 14
MAPE	0.081 3	0.048 8	0.050 5	0.032 9	0.031 5

做到快速响应, 且预测精度远不如深度神经网络。对于其他 4 种深度神经网络结构来说, CNN-LSTM 和 VBS-Net 的预测效果比单一的 CNN 和 LSTM 要好, 其中本文所提出的 VBS-Net 预测模型的预测精度最高, 与其他 4 种预测模型相比, 其误差评价指标 RMSE 分别降低了 80.57%, 66.71%, 40.54%, 14.51%, MAPE 分别降低了 61.25%, 35.45%, 37.22%, 4.26%。

4.1.2 超参数优化算法的对比分析

从图 6 中可以看出, VBS-Net 和 CNN-LSTM 这类混合神经网络在部分区间的表现有时不如单一深度神经网络。这是因为混合神经网络虽然结合了两种或多种网络的优点, 但也导致了其高度复杂的网络结构以及对于不同网络之间的协调

匹配能力的高要求。故对基于时序预测的混合神经网络进行超参数优化是非常重要的一个步骤,超参数组合的优劣直接影响预测模型的性能。

选取卷积核个数、步长、隐含层单元数、丢失率、正规化系数、初始学习率及最大训练批次 7 个超参数进行优化组合,对比结果如表 3 所示。本文将使用贝叶斯优化 VBS-Net 的超参数,并与粒子群优化(PSO)、网格搜索(GS)两种超参数优化算法在相同工况下进行对比实验,结果如图 7 所示。

对于越是复杂的深度神经网络结构,须要考虑的超参数优化个数就越多。由表 3 可以看出,平时常用的 GS 和 PSO 超参数优化算法在处理 VBS-Net 复杂网络结构时,不仅计算成本随超参数个数的增加而成指数上升,且优化效果并不明

表 3 US06 工况下超参数优化对比

Table 3 The comparison of super parameter optimization under US06 working condition

神经网络	寻优参数	GS-VBS-	PSO-VBS-	Bayes-VBS-
		Net	Net	Net
CNN	卷积核个数	86	37	200
	步长	1	2	1
	最大训练批次	250	438	497
LSTM	隐含层单元数 1	131	118	48
	隐含层单元数 2	115	150	60
	学习率	0.004 9	0.008 2	0.011 8
	丢失率	0.273 14	0.380 33	0.213 75
	正规化系数	$2.741 \times 10^{-10}$	$6.982 \times 10^{-9}$	$1.911 4 \times 10^{-6}$
RMSE		1.382 4	1.305 2	1.198 3
$R^2$		0.978	0.966	0.992




图 7 3 种超参数优化结果

Fig.7 The optimization results of three super parameters

显。而贝叶斯优化算法的误差指标 RMSE 与优化前相比降低了 14.72%,与其他两个优化算法相比分别降低了 13.32%,8.2%, $R^2$  也更接近于 1。由图 7 可以看出,整条预测曲线在测试区间上没有出现偏移较大的情况,能够很好地贴合实际曲线且计算效率高。

#### 4.2 不同控制策略优化结果分析

通过搭建仿真平台,对本文所提出的基于 VBS-Net 速度预测的 MPC-DP 在混合动力系统中的性能效果进行验证。针对 FCHEV 在行驶过程中锂电池充放电可能存在的状态,设置不同的初始 SOC 数值来研究混合动力系统的功率曲线。

选取 24 V 燃料电池混合动力小车的实车工况速度数据集(2 000 s),输入调试好的 VBS-Net 速度预测器,并结合 MPC-DP 控制策略对在初始 SOC 值为 0.45,0.60,0.75 3 种情况下的需求功率进行最优功率分配求解,得到的功率分配曲线及对应 SOC 曲线分别如图 8 和图 9 所示。




图 8 系统功率变化曲线

Fig.8 The system power variation curve




图9 锂电池 SOC 曲线

Fig.9 The SOC curve of lithium battery

设置 FCHEV 的初始 SOC 值为 0.50~0.70, 以确保有足够的充电容量空间, 保证锂电池的输出性能和寿命。当初始 SOC 值设定为 0.45 和 0.60 时, 燃料电池的整体输出功率较为平稳, 维持在 500 W 附近, 锂电池 SOC 波动也较小并最终趋向于 50% 左右。当初始 SOC 设定为 0.75 时, 从功率曲线可以看出, 所提出的 EMS 依旧可以很好地平衡不同动力源之间的功率需求。从 1 000 s 开始, 锂电池 SOC 曲线下降幅度明显趋于平稳, 最终停留在 65% 附近。

考虑本文中 FCHEV 的主要应用场景, 选择工业上广泛使用的电量消耗-电量保持 (CD-CS) 规则型 EMS 进行对比实验。CD-CS 策略通过对锂电池 SOC 设定相应的阈值实现控制系统的功

率分配, 其凭借可靠性、易维护、操作简单等特点适用于工业实际应用。本文通过与这种基于规则的控制策略进行对比实验, 验证了所提控制策略不仅优化效果更好, 且能满足实际应用需求。本文选取欧洲汽车油耗测试工况 (ECE)、城市循环测试工况 (UDDS) 和城市汽车高速测试工况 (HWEFT) 3 种标准工况作为 FCHEV 在城市道路、乡村道路和高速公路环境下的模拟环境工况, 图 10 给出了本文所提控制策略与基于规则的控制策略在 3 种工况下的优化效果。在 ECE 工况下, 两种控制策略的 SOC 曲线整体变化较为平缓, 维持在 5% 以内。当车辆在急加速状态下, 锂电池与燃料电池共同供电来满足驱动电机增大的功率需求, 此时锂电池处于放电状态, SOC 曲线在这段时间内应处于下降阶段。从图 10 中可以看出, 本文所提出的 MPC 策略的 SOC 曲线有明显的下降趋势, 而基于规则的能量管理策略 (RB) 则没有, 说明 MPC 策略可以有效弥补燃料电池的输出功率。在 UDDS 工况下, MPC 的 SOC 波动明显高于 ECE 工况, 但最终变化率仍能维持在 5% 附近。这是因为 UDDS 工况车速通常较快, 使得需求功率进一步增大且存在怠速阶段, 此时仅考虑 SOC 变化容易陷入局部最优, 故在该工况下还须

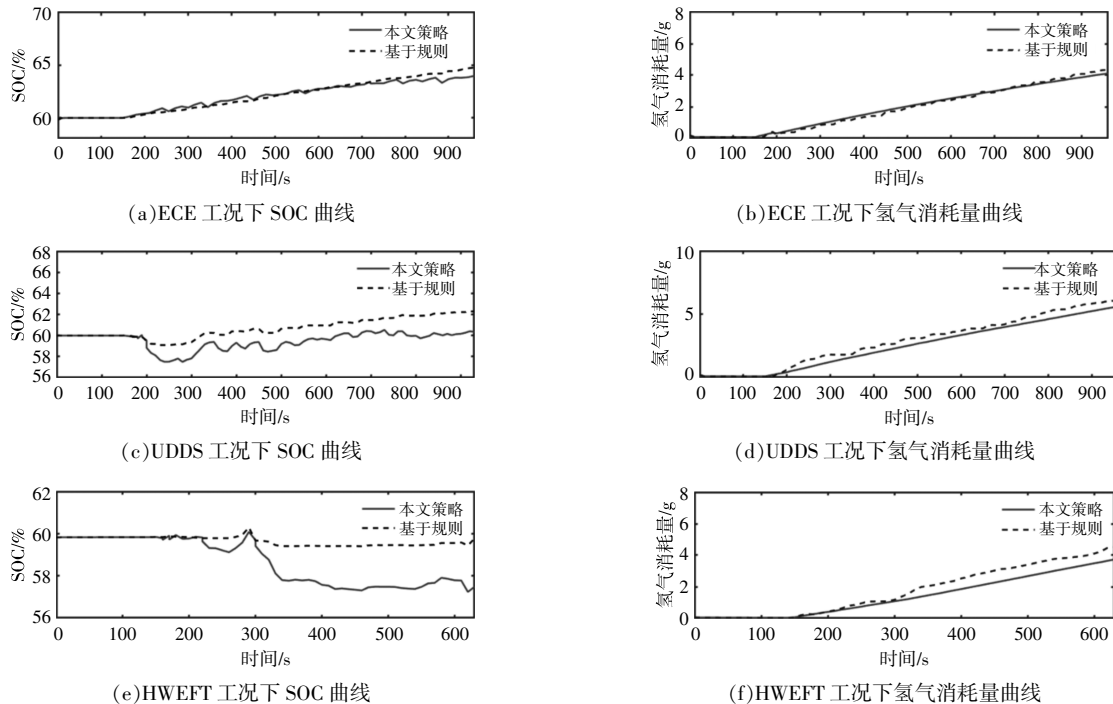


图 10 不同工况下控制策略优化效果

Fig.10 The optimization effect of control strategy under different working conditions

考虑等效氢气消耗指标。

表4为不同工况下控制策略的性能参数。由表4可以看出:UDDS工况下,与基于规则的控制策略相比,MPC策略的氢气消耗减少了9.94%。综合SOC曲线波动和氢气消耗量可以看出,MPC策略整体优化效果优于基于规则的控制策略。在HWEFT工况下,SOC曲线波动明显增大,但能维持在58%附近。这是因为HWEFT工况属于高速工况,没有启停阶段且全程车速平稳,这使得锂电池提供更多的电量来满足功率增加的需求。因此,本文所提控制策略与传统基于规则的控制策略相比,经济性更好,在3种不同工况下氢气减少量分别达到了7.25%,9.94%和19.23%。

表4 不同工况下控制策略性能参数

Table 4 The performance parameters of control strategies under different working conditions

控制策略	驾驶工况	SOC 终值 %	SOC 变化	等效氢耗 g	减少量 %
RB	ECE	64.24	4.24	5.24	
	UDDS	62.32	3.32	6.54	
	HWEFT	59.96	2.83	4.73	
MPC	ECE	63.07	3.07	4.86	7.25
	UDDS	60.14	5.14	5.89	9.94
	HWEFT	57.87	4.13	3.82	19.23

## 5 结论

针对FCHEV需求功率预测的不准确性带来的能量利用效率低下的问题,本文研究了基于混合神经网络的速度预测方法和基于多目标优化的模型预测控制能量管理策略。在速度预测方法中,为提升速度预测模型的预测精度,设计了混合深度神经网络结构速度预测模型VBS-Net,该预测模型不仅可以有效提取时序数据的局部特征域,还能掌握数据之间的长期依赖关系。在此基础上,利用贝叶斯优化算法对该网络模型的最优超参数组合进行搜索。实验结果表明,该方法可以提升预测模型的预测精度。在能量管理策略方面,为实现FCHEV能量利用率的最大化,设计了基于多目标优化的模型预测控制算法。通过与基于规则的控制策略进行对比实验,验证了本文所提策略在不同工况下的能量利用率更高,且有更好的锂电池SOC维持特性。

## 参考文献:

- [1] Song Z, Pan Y, Chen HC, et al. Effects of temperature on the performance of fuel cell hybrid electric vehicles: a Review[J]. Applied Energy, 2021, 302: 117572.
- [2] 黄春辉,朱自伟,裘昕月,等.偏差考核下售电公司的电动汽车电价策略研究[J].可再生能源,2020,38(9): 1258-1265.
- [3] Zhu L, Tao F, Fu Z, et al. Multi-objective optimization of safety, comfort, fuel economy, and power sources durability for fchev in car-following scenarios[J]. IEEE Transactions on Transportation Electrification, 2023, 9(1): 1797-1808.
- [4] Lü X, Wang P, Meng L, et al. Energy optimization of logistics transport vehicle driven by fuel cell hybrid power system [J]. Energy Conversion and Management, 2019, 199: 111887.
- [5] Yan F, Wang J, Du C, et al. Multi-objective energy management strategy for hybrid electric vehicles based on TD3 with non-parametric reward function [J]. Energies, 2023, 16(1): 74.
- [6] Francesc C L, Roberto úF. Predictive model for energy consumption of battery electric vehicle with consideration of self-uncertainty route factors[J]. Journal of Cleaner Production, 2020, 276: 124188.
- [7] Quan S, Wang Y, Xiao X, et al. Real-time energy management for fuel cell electric vehicle using speed prediction-based model predictive control considering performance degradation[J]. Applied Energy, 2021, 304: 117845.
- [8] He H, Jia C, Li J. A new cost-minimizing power-allocating strategy for the hybrid electric bus with fuel cell/battery health-aware control [J]. International Journal of Hydrogen Energy, 2022, 47 (52): 22147 - 22164.
- [9] Cheng Z, Lu J, Zhou H, et al. Short-term traffic flow prediction: an integrated method of econometrics and hybrid deep learning [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23 (6): 5231-5244.
- [10] 王超,郑炼,刘聚良,等.新能源电动汽车模块化电池包并联控制策略[J].可再生能源,2023,41(11): 1520-1527.
- [11] Liu C, Murphey Y. Optimal power management based on Q-learning and neuro-dynamic programming for

- plug-in hybrid electric vehicles [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(6): 1942–1954.
- [12] 潘诗媛, 华志广, 王光伟, 等. 基于级联回声状态网络的氢燃料电池剩余使用寿命预测[J/OL]. 中国电机工程学报, 1–11 [2024–02–23]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20240125.1004.006.html>.
- [13] Tang X, Chen J, Pu H, 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.
- [14] Ma X, Tao Z, Wang Y, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data [J]. Transportation Research Part C: Emerging Technologies, 2015, 54: 187–197.

## Energy management optimization of fuel cell hybrid electric vehicles based on hybrid deep neural networks

He Songjie, Lü Xueqin

(School of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

**Abstract:** In order to improve the fuel economy of fuel cell hybrid electric vehicles during short range driving, a vehicle speed prediction model structure VBS-net based on hybrid deep neural network was constructed. This structure not only further improves the convolutional network based on the VGG-Net structure, but also introduces a bidirectional long short-term memory neural network to effectively learn the spatiotemporal dependencies of the entire vehicle speed prediction sequence. Simultaneously considering the influence of prediction time domain and input sequence length on the prediction accuracy of short-range vehicle speed problems, Bayesian optimization hyperparameters are used to further improve the prediction accuracy of VBS-Net. To address the online optimization and computational efficiency issues of energy management strategies, a multi-objective optimization based on model predictive control (MPC) energy management strategy was designed. This strategy can achieve a balance and optimization of hydrogen consumption, lithium battery state of charge (SOC) maintenance, and fuel cell utilization efficiency. Finally, under actual vehicle conditions, the proposed strategy was compared with rule-based strategies, resulting in fuel economy improvements of 7.25%, 9.94% and 19.23%, and better SOC maintenance characteristics.

**Keywords:** deep learning; bayesian optimization; energy management strategy; speed prediction