DOI: 10.3901/JME.2020.16.181

基于机器学习速度预测的并联混合动力 车辆能量管理研究*

胡晓松^{1,2} 陈科坪^{1,2} 唐小林^{1,2} 王 斌³

(1. 重庆大学机械传动国家重点实验室 重庆 400044;

2. 重庆大学汽车工程学院 重庆 400044;

3. 北京新能源汽车股份有限公司 北京 100176)

摘要: 针对当前混合动力汽车模型预测控制(Model predict control, MPC)能量管理中预测域速度预测不精准问题, 进行基于机器学习的速度预测研究。首先建立基于无极变速(Continuously variable transmission, CVT)的单轴并联混合动力汽车模型, 其次采用机器学习方法对未来时间窗内的行车速度进行预测, 得到三种不同预测方法下的方均根误差(Root mean squared error, RMSE)精度, 其中长短期记忆(Long short term memory, LSTM)神经网络最佳, 前馈神经网络次之, 支持向量机最差。然后, 利用模型预测控制策略对车辆进行能量流分配, 验证不同预测方法对燃油消耗、SOC 的影响, 且分析对比不同预测时间窗长度下的能量管理性能, 找到不同预测方法下的最小油耗预测域。最后将预测控制与传统动态规划(Dynamic programming, DP)、等效燃油消耗(Equivalent consumption minimization strategy, ECMS)能量管理策略进行性能比较, 发现机器学习预测控制对减少油耗具有良好的潜力, 同时对模型预测控制算法预测域内的扰动量预测具有重要指导意义。

关键词: 并联混合动力汽车; 机器学习; LSTM; 预测能量管理; 模型预测控制

中图分类号: U461

Machine Learning Velocity Prediction-based Energy Management of Parallel Hybrid Electric Vehicle

HU Xiaosong^{1,2} CHEN Keping^{1,2} TANG Xiaolin^{1,2} WANG Bin³

(1. The State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400044;

2. Department of Automotive Engineering, Chongqing University, Chongqing 400044;

3. Beijing New Energy Automobile Co., Ltd., Beijing 100176)

Abstract: To resolve the problem of inaccurate prediction-horizon speeds in model predictive energy management algorithms for hybrid electric vehicles, the speed prediction based on machine learning is examined. First, a single-shaft parallel hybrid electric powertrain model equipped with a continuously variable transmission(CVT) is established. Then, the machine learning algorithms are utilized to predict the vehicle velocity in the future time horizons, and root mean squared error(RMSE) values of three different prediction methods are obtained, where the performance of the LSTM-NN is the best, followed by the feedforward neural network, and the support vector machine is the worst. Model predict control(MPC) is subsequently deployed to manage energy flow distributions. The effects of different prediction methods on fuel consumption and SOC are verified, and the effects of the prediction horizon size on the energy management performance are comparatively analyzed. Consequently, the minimum fuel consumption prediction horizon is determined. Finally, the performance comparisons between the predictive controller and traditional Dynamic programming(DP) and equivalent consumption minimization strategy(ECMS) are made, illustrating that the machine learning driven predictive control is promising for reducing fuel consumption. It also facilitates realizing disturbance quantity prediction in the prediction horizon for model predictive control algorithms.

Key words: parallel hybrid electric vehicles; machine learning; LSTM; predictive energy management; model predictive control

* 国家自然科学基金(51875054, 51705044)和重庆市杰出青年基金(cstc2019jcyj0010)资助项目。20191028 收到初稿, 20200330 收到修改稿

0 前言

混合动力汽车控制策略对提高燃油经济性和降低排放有着举足轻重的作用。许多学者在能量管理策略上做了研究工作^[1-2]。其中模型预测控制算法受到了很大关注^[3-4]。模型预测控制(Model predict control, MPC)能量流分配策略把整个工况内的全局最优控制问题转化为预测域内的优化问题进行滚动优化、反馈矫正,适用于线性、非线性系统,具有较强的鲁棒性^[5]。但 MPC 算法预测域内的扰动量具有不确定性,加大了未来工况扰动对优化性能影响的风险,因此提升扰动量的预测质量是混合动力汽车 MPC 能量管理研究的核心与难点^[4]。

针对未来预测信息的获取,国内外学者进行了大量深入研究。文献[6]提到,给定速度预测域,线性系统利用二次规划方法求解预测域内的控制量大小,非线性系统则采用非线性规划、动态规划策略求解预测域内的控制量。文献[7]采用随机模型预测控制算法求解能量管理问题,首先对需求功率进行预测,针对并联混合动力转矩分配建立了马尔科夫模型,在预测区间内利用动态规划进行求解,该文献还提到,模型预测控制应用于能量管理,预测信息越准确,控制效果越好。所以进行精确的速度预测是必要的,也是近年来智能交通系统(Intelligent transportation system, ITS)新趋势^[8]。文献[9]对比了几种不同的速度预测方法,其中前馈神经网络预测算法最好,但是没有考虑前馈神经网络的过拟合问题。文献[10]提取车速统计特征,采用多种特征作为神经网络的训练输入,并利用粒子群优化算法进行了神经网络的改进优化。文献[11]应用贝叶斯网络方法预测车速,结果表明引入车联网信息可以提高预测精度,但目前基础建设不完善,车联网设施配置不齐全,广泛应用难度较大。马尔科夫链预测模型也被广泛应用于车速预测领域^[12],一阶马尔科夫模型和高阶马尔科夫模型都能根据历史信息提取速度特征进行速度预测,但是一阶马尔科夫模型不能完全利用历史信息,预测精度有限^[13],而高阶马尔科夫模型能较好地进行预测,适当保证精度,但预测过程算力需求过大^[9]。分类、预测领域,基于核方法的支持向量机(Support vector machine, SVM)取得了巨大成功^[14-15],训练时间短,运算快,仍不失为一种较好的车速预测折中方案。文献[16]利用不同驾驶条件下的人-车-路-交通闭环数据,通过 SVM 预测速度,1.25 s 预测时间内方均根误差为 0.067 8 m/s。深度学习在预测领域有着广泛应用,

文献[17]对动力电池历史容量信息进行关键信息提取预测剩余寿命(Remaining useful life, RUL),预测误差在 3%以内。考虑行车速度具有时间序列性质,文献[18]提出一种双序列模型,利用空间-时间交错的二维信息作为数据源训练长短期记忆(Long short term memory, LSTM)再进行交通流预测,与以往利用车辆密度进行序列预测相比精度提高了 15%,因此 LSTM 网络进行扰动量序列预测有很大优势。

本文针对速度预测精度的不足,提出使用基于数据驱动改进的机器学习方法预测扰动量。主要创新有三点:① 基于模型预测控制策略的混合动力能量管理过程中利用机器学习进行速度预测,针对不同预测方法进行预测精度、燃油消耗、计算时间的对比分析;② 为防止神经网络过拟合,第一次在速度预测中使用由 STRIVASTAVA 等^[19]提出的 Dropout 技术改进前馈神经网络,随机地丢弃一些神经元以及它们的连接;③ 找到了基于 LSTM 网络预测的最佳 MPC 预测域长度,平衡了预测域长度与燃油消耗。

1 混合动力汽车动力学建模

1.1 单轴并联式 CVT 混合动力模型

考虑纵向动力学模型如图 1 所示,发动机、电机、车轮转矩之间的关系如下

$$T_w = \eta_t \cdot i_{cvt} \cdot i_f \cdot (T_m + T_e) + T_b \quad (1)$$

$$T_w = \left(mgf_r \cos \theta + \frac{1}{2} C_D \rho A v^2 + mg \sin \theta + m \delta \frac{dv}{dt} \right) \cdot r_w \quad (2)$$

式中, T_w 是车轮转矩, η_t 是传动效率, i_{cvt} 、 i_f 分别是 CVT 和主减速器的传动比, T_m 、 T_e 、 T_b 分别是电机转矩、发动机转矩、制动转矩, m 是整车质量, g 是重力加速度, f_r 是滚动阻力系数, θ 是坡角, C_D 是空气阻力系数, ρ 是空气密度, A 是迎风面积, v 是车速, δ 是旋转质量换算系数, r_w 是轮胎半径。

图 1 基于 CVT 的并联 HEV 模型

发动机模型本身是非常复杂的非线性系统, 整车仿真控制采用数据拟合或查表的方式建立发动机输入输出关系。忽略高频瞬态特性后发动机的数学模型如下

$$q_e = f(\omega_e, T_e) \quad (3)$$

$$T_e = g(\omega_e, \alpha) \quad (4)$$

式中, ω_e 为发动机转速; T_e 为发动机输出转矩; q_e 为燃油消耗率, g/s; α 为节气门开度。

电机具备用电与发电两种工作模式, 其数学模型描述如下

$$T_{\max_dis} = f_1(\omega_m) \quad (5)$$

$$T_{\max_char} = f_2(\omega_m) \quad (6)$$

$$\eta_m = \psi(\omega_m, T_m) \quad (7)$$

$$T_m = \begin{cases} \min(T_{m_req}(t), T_{\max_dis}(\omega_m(t))) & T_{m_req}(t) > 0 \\ \max(T_{m_req}(t), T_{\max_char}(\omega_m(t))) & T_{m_req}(t) < 0 \end{cases} \quad (8)$$

$$P_m = T_m \omega_m \eta_{EM}^{-\text{sgn}(T_m)} / 9550 \quad (9)$$

式中, $T_{\max_dis}(\omega_m)$ 是用电模式下当前转速的最大转矩, $T_{\max_char}(\omega_m)$ 是发电模式下当前转速的最大转矩, ω_m 是电机转速, T_m 是电机转矩, T_{m_req} 是电机需求转矩, f_1 , f_2 分别是最大转矩、最小转矩的插值函数, ψ 是效率函数。

动力电池充放电是一个复杂的电化学过程, 整车控制需要考虑电池充放电过程^[20]。忽略温度、电池寿命等因素对 SOC 的影响后, 电池内阻模型如下

$$V = V_{oc} - I_b R_{in} \quad (10)$$

$$V_{oc}(t) = k_1 \text{SOC}(t) + k_2 \quad (11)$$

$$R_{in}(t) = k_3 \text{SOC}(t)^2 + k_4 \quad (12)$$

$$\frac{d}{dt} \text{SOC} = \frac{V_{oc} - \sqrt{V_{oc}^2 - 4R_{in}T_m\omega_m\eta_m^{-\text{sgn}(T_m)}}}{2R_{in}Q_{\max}} \quad (13)$$

式中, V 为端电压, V_{oc} 是开路电压, I_b 是电池电流, R_{in} 是电池等效内阻; 由于不考虑温度因素, 电池单体开路电压和内阻是关于 SOC 的函数, $k_i (i=1, 2, 3)$ 是与电池结构、单体数量有关的常数, $Q_{\max}$ 是电池容量, $P_{batt} = T_m \omega_m \eta_m^{-\text{sgn}(T_m)}$ 是电池功率, T_m , ω_m 分别是电机转矩、转速。

1.2 非线性模型预测控制

混合动力汽车系统模型表达式如下

$$\dot{x} = f(x, u, d) \quad y = g(x, u, d) \quad (14)$$

$$\begin{cases} x = \text{SOC} \\ u = (i_{cvt}, \alpha)^T \\ d = V_{predict} \\ y = (q_e, P_{batt}, T_m, \omega_m, T_e, \omega_e)^T \end{cases} \quad (15)$$

式中, 发动机加速踏板开度 α 和 CVT 传动比 i_{cvt} 作

为控制变量 u , x 表示状态变量 SOC, 外部扰动 d 表示预测速度 $V_{predict}$, y 是输出变量, 1 s 步长内, k 时刻的代价函数如下

$$\min[J(k) = \int_k^{k+H_p} (w_1 q_e(t) + w_2 (\text{SOC}(t) - \text{SOC}_{ref})^2) dt] \quad (16)$$

式中, H_p 是预测时域大小, 同时设置控制时域 5 s; $q_e(t)$, $\text{SOC}(t)$ 分别是当前时刻的燃油消耗速率和电池荷电状态; w_1 、 w_2 是惩罚权重, 选取原则尽量使终端 SOC 保持一致; 考虑车辆实际运行状态, 需满足如下物理约束条件

$$\begin{cases} \text{SOC}_{\min} \leq \text{SOC} \leq \text{SOC}_{\max} \\ T_e^{\min} \leq T_e \leq T_e^{\max} \\ \omega_e^{\min} \leq \omega_e \leq \omega_e^{\max} \\ T_m^{\min} \leq T_m \leq T_m^{\max} \\ \omega_m^{\min} \leq \omega_m \leq \omega_m^{\max} \\ P_{batt}^{\min} \leq P_{batt} \leq P_{batt}^{\max} \\ \text{SOC}(0) = \text{SOC}(T) \end{cases} \quad (17)$$

对于非插电式混合动力汽车而言, 末端时刻电池 SOC(T) 必须等于初始时刻电池 SOC(0)。要满足 SOC 约束条件, 每个时间窗内进行非线性优化求解时, 需要满足条件 SOC($k+H_p$)=SOC(0), SOC($k+H_p$) 表示控制时间窗内的末端 SOC 状态, 但该方法会损失部分电池能量利用率^[9]。也可以通过惩罚代价函数中的权重因子 w_2 维持 SOC 状态^[21]。MPC 求解实时燃油消耗最小问题可归纳为预测域内的非线性优化问题, 该任务可利用 fmincon 中的“信赖域反射算法”进行求解。

控制过程求解步骤如下。

步骤(1): 从历史速度数据中生成训练数据集, 通过机器学习学习速度特征, 预测未来工况。

$$\begin{aligned} & \text{Prediction}(\cdots v(t_k - 4), v(t_k - 3), \\ & v(t_k - 2), v(t_k - 1), v(t_k)) = \\ & \{v(t_k + 1), v(t_k + 2), v(t_k + 3), v(t_k + 4), \cdots\} \end{aligned} \quad (18)$$

式中, Prediction = {FNN, SVM, LSTM}; FNN 表示前馈神经网络, SVM 是支持向量机, LSTM 是长短期记忆网络。预测模型的预测长度与 MPC 中的预测域长度相同。

步骤(2): 得到扰动量, 既预测速度后, 计算代价函数 $J(k)$ 的最小值, 得到控制时域内的控制变量。

$$u_{predict}^{optimize} = \{u(t_k), u(t_k + 1), \cdots, u(t_k + t_c)\} \quad (19)$$

式中, t_c 是控制域大小。

步骤(3): 将控制时域内的第一个控制变量 $u(t_k)$ 施

加到系统中,得到该时刻的状态量,重复步骤(1)、(2)。

2 基于机器学习的速度窗口预测

三种速度预测方法分别是自回归支持向量机(SVM),前馈神经网络(Feedforward neural network, FNN),长短期记忆网络(LSTM)。其中SVM和LSTM速度预测第一次在混合动力汽车预测能量管理中使用。训练数据需要归一化预处理,消除数值差异带来的训练困难,再反归一化得到预测结果,公式如下

$$\mathbf{x}_{\text{normal}} = \frac{\mathbf{x} - \mathbf{x}_{\min}}{\mathbf{x}_{\max} - \mathbf{x}_{\min}} \quad (20)$$

$$\mathbf{x} = \mathbf{x}_{\text{normal}}(\mathbf{x}_{\max} - \mathbf{x}_{\min}) + \mathbf{x}_{\min}$$

式中, $\mathbf{x}$ 是特征矢量, $\mathbf{x}_{\max}$ 、 $\mathbf{x}_{\min}$ 分别是特征矢量中的最大值和最小值, $\mathbf{x}_{\text{normal}}$ 是归一化后特征矢量。

2.1 自回归支持向量机(SVM)

支持向量机可将原始样本空间映射到高维空间,使样本在高维空间线性可分。特征空间中划分超平面对应的模型^[22]表示为

$$f(x) = \mathbf{w}^T \phi(x) + b \quad (21)$$

式中, $\mathbf{w}$ 、 b 是模型参数, $\phi(x)$ 是映射后的特征向量。为使类别支持向量到超平面的距离之和最小,SVM可转化为如下问题^[22]

$$\begin{aligned} \min_{\mathbf{w}, b} & \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{s.t.} & y_i(\mathbf{w}^T f(x_i) + b) \geq 1 \quad i = 1, 2, \dots, m \end{aligned} \quad (22)$$

上述问题可转化为其对偶问题,利用序列最小优化算法进行参数求解。支持向量机自回归过程如图2所示,历史工况作为输入,下一时刻数据作为输出

$$\text{SVM}(v(t_k - h + 1) \cdots v(t_k)) = v(t_k + 1) \quad (23)$$

式中, h 是历史工况输入大小; SVM代表支持向量机。

图2中 p 是预测工况输出域的大小。预测时,预测值与历史工况值一起作为输入,得到新输出值,然后重复该过程。

2.2 前馈神经网络预测器(FNN)

前馈神经网络是混合动力系统进行转矩或速度预测的重要方式,可拟合高度非线性输入输出。

输入层接收历史工况数据,隐藏层反映输入输出的非线性关系。输出层输出计算值,该计算值与目标值误差通过反向传播更新隐藏层中的权重和偏差^[10]。激活函数采用双曲型正切S型函数

$$\begin{aligned} a_1 &= \text{Tansig}(n) = \frac{\exp n - \exp(-n)}{\exp n + \exp(-n)} \\ n &= \mathbf{W}a^0 + b \end{aligned} \quad (24)$$

图2 自回归支持向量机模型

式中, a^0 是上一层神经元输出, a_1 是当前层输出, n 是累积输出, $\mathbf{W}$ 是权重, b 是偏执。

神经网络训练过程中易出现过拟合,可利用Dropout技术或者DropConnect技术防止过拟合^[23]。Dropout技术通过舍弃一部分单元来防止过拟合,该方法不同于DropConnect技术把一部分权重随机设置为0,而是将单元输出按照一定概率随机设置为0,即随机丢弃一些神经元。使用DropConnect的神经网络泛化能力更强,但是由于随机数生成方法的不同,DropConnect很难得到相同的识别性能,导致训练难度上升,本文使用训练难度更低的Dropout技术提高预测器泛化能力。

前馈神经网络窗口式预测过程如图3所示,预测公式如下

$$\begin{aligned} \text{FNN}(v(t_k - h + 1) \cdots v(t_k)) = \\ (v(t_k + 1), v(t_k + 2) \cdots v(t_k + p)) \end{aligned} \quad (25)$$

式中, h 是历史工况大小, p 是预测工况大小,隐藏层一层, FNN代表前馈神经网络。

2.3 长短期记忆网络预测器(LSTM-NN)

循环神经网络进行时间序列预测时面临长期依赖问题,即当计算图变的很深时,经过多阶段反向传播之后会出现梯度消失或者梯度爆炸,使模型失去学习先前信息的能力。为了解决该问题,采用门控循环神经网络,即LSTM进行速度的时间序列预

图3 带 Dropout 的前馈神经网络模型

测。LSTM 与普通神经网络的区别在于，其神经单元不仅有输入和输出，神经单元内部有更多的权重参数和控制梯度流动的门控单元表达式系统，见图4和式(26)^[24]

$$\begin{cases} f_t = \sigma(W_f(h_{t-1}, x_t) + b_f) \\ i_t = \sigma(W_i(h_{t-1}, x_t) + b_i) \\ g_t = \text{Tanh}(W_g(h_{t-1}, x_t) + b_g) \\ S_t = f_t \cdot S_{t-1} + i_t \cdot g_t \\ o_t = \sigma(W_o(h_{t-1}, x_t) + b_o) \\ h_t = o_t \cdot \text{Tanh}(S_t) \end{cases} \quad (26)$$

式中， f_t 是时刻 t 的遗忘门； i_t 是时刻 t 的输入门；

图4 LSTM 网络单元模型

g_t 是时刻 t 的 gate 门； S_t 是状态变量，它是整个神经网络的核心； o_t 是时刻 t 的输出门； W_f, W_i, W_g, W_o 分别是相应门控权重； σ 是 sigmoid 单元，Tanh 是 Tanh 计算单元， x_t 是当前输入矢量； h_{t-1} 是 $t-1$ 时刻的隐藏层矢量； h_t 是 t 时刻的隐藏层矢量； b_f, b_i, b_g, b_o 分别是遗忘门偏执，输入门偏执，gate 门偏执，输出门偏执。

内部状态变量 S_t 被线性函数激活，是遗忘历史信息 and 储存历史信息的载体。对于速度预测而言遗忘门有助于丢弃数据噪声、异常值以及相邻工况数据中的冗余信息，提高速度预测序列精度。通过独特的门控逻辑结构，LSTM 能够学习长时间历史工况速度中隐含的信息及内部数据特征，实现扰动量准确预测，降低 MPC 能量管理过程中的油耗。为选择合适的网络模型，构建了单、双层结构的 LSTM 网络分别如图 5、6 所示。LSTM 网络的特性输入与速度的时间序列有关，历史数据个数等于 LSTM 单元的个数。最后一个 LSTM 单元的隐藏层作为输出。改变隐藏层宽度可改变预测域大小。

图5 单层 LSTM 网络模型

图6 双层 LSTM 网络模型

3 仿真结果对比与分析

本节着重分析三种不同预测方案在城市、高速工况下的结果，同时与 DP、ECMS 方案进行对比。首先选择包括高速工况，城市工况在内的 9 种工况数据作为训练集。然后使用不同于训练集的 9 种工况作为验证集验证模型。整合后的训练集与验证集如图 7 所示。车辆参数与效率图皆从 Advisor 中提取，车辆参数如表 1 所示。仿真过程采用 Intel Core i7-6700 CPU 3.4 GHz 计算机配置。Python 环境下支持向量机通过 Sklearn 库搭建，前馈神经网络与 LSTM 网络通过 TensorFlow 搭建。预测过程调用

Python 文件模型, MPC 控制过程利用 Matlab 搭建。

利用验证集验证预测模型合格之后, UDDS 工况与 HWFET 工况作为运行工况进行速度预测, 得到的速度预测值作为已知扰动量参与 MPC 控制过程, 预测域范围 8~20 s 不等。由于非线性规划求解 MPC 的复杂度受控制域影响, 控制域固定为 5 s。通过平衡油耗性能指标与预测精度, 找到各方法下的最小油耗预测域如表 2、3 和图 8、9 所示。

MPC 算法不能保证 $SOC(0)=SOC(T)$, 所以燃油消耗会等效初末时刻 SOC 差值换算后的消耗值。下面列出预测结果的评价指标: ① 预测域边界的方均根误差(RMSE, 单位 km/h); ② 训练模型所需时间; ③ 预测过程所需计算时间 T_{cal} , ms; ④ UDDS\ HWFET 工况下的燃油消耗量。

表 1 车部件主要参数

参数	数值
整车质量/kg	1 601
主减速器传动比	3.94
CVT 传动比最大值	3.69
CVT 传动比最小值	0.74
电池容量/(A·h)	25
迎风面积/m ²	2.0
滚阻系数	0.01
发动机最大扭矩/(N·m)	80.9
电机最大扭矩/(N·m)	271
SOC 范围	0.4~1
轮胎半径/m	0.282
风阻系数	0.3
发动机最大转速/(r/min)	6 000
电机最大转速/(r/min)	10 000
SOC 参考值	0.7

图 7 训练集和验证集数据

表 2 UDDS 工况下的最小油耗预测域

自适应支持向量机	前馈神经网络	LSTM 神经网络
11	13	14

表 3 HWFET 工况下的最小油耗预测域

自适应支持向量机	前馈神经网络	LSTM 神经网络
12	13	15

图 8 UDDS 工况下的预测域-油耗

图 9 HWFET 工况下的预测域-油耗

3.1 自适应支持向量机结果分析

由表 4、5 可得, 不同核函数下的预测精度不同, 燃油消耗量也不同。预测精度越高, 燃油消耗量越少。线性核函数预测精度最低, 燃油消耗最高。这是因为线性核更适用线性可分数据, 而车辆工况数据属于非线性数据类型。高斯核预测精度最高, 燃

油消耗最小, 这是因为高斯核对非线性数据有很好的适应性。多项式核的结果不优于高斯核, 并且多项式核计算时间较长、参数多、难调节。拉

普拉斯核和 Sigmoid 核与高斯核的预测精度相差不大, 它们的差异主要来自自身核函数内部参数的不同。

表 4 基于 UDDS 工况的自适应支持向量机仿真结果

编号	核函数	SOC(T)	RMSE/(km/h)	燃油消耗/(L/100 km)	计算时间/ms
1	线性核	0.695 4	16.55	3.74	0.110
2	多项式核	0.701 2	15.87	3.70	0.112
3	高斯核	0.696 9	15.62	3.67	0.102
4	拉普拉斯核	0.693 3	15.63	3.67	0.106
5	Sigmoid 核	0.694 3	15.64	3.69	0.109

表 5 基于 HWFET 工况的自适应支持向量机仿真结果

编号	核函数	SOC(T)	RMSE/(km/h)	燃油消耗/(L/100 km)	计算时间/ms
1	线性核	0.698 3	9.62	3.70	0.110
2	多项式核	0.693 9	8.91	3.68	0.118
3	高斯核	0.695 1	8.11	3.61	0.101
4	拉普拉斯核	0.695 6	8.15	3.62	0.105
5	Sigmoid 核	0.697 1	8.16	3.63	0.107

3.2 前馈神经网络结果分析

由表 6~9 可得, 前馈神经网络预测模型的输入维度 $h=20$ 。神经元节点越多, 训练精度越高, 但是易出现过拟合, 造成实际预测精度下降。Dropout 技术能防止过拟合, 提高实际预测精度。如何权衡神经元个数和应用 Dropout 技术对预测精度和燃油消耗都有很大影响。前馈神经网络节点数为 20 和 50, 采用 Dropout 技术的预测精度比不采用时低, 节点数大于 80 时, 与上述情况相反。这是因为少量神经元并不会造成过拟合, 相反应该考虑多样性而

增加神经元数量。当神经元数量增加时, 容易出现过拟合, 所以此时使用 Dropout 技术可提高预测精度。另一方面, 从节点数维度看, 若采用 Dropout 技术, 110 是精度最高的节点数, 即少量节点不足以描述预测模型, 节点数过多 Dropout 技术不能抑制过拟合。若不采用 Dropout 技术, 精度最佳节点数为 80, 即大于该值的前馈神经网络模型出现过拟合, 预测模型不能很好泛化。前馈神经网络与自适应支持向量机相同, 预测精度越高, 燃油消耗量越少, 所以利用 Dropout 技术提高预测精度是必要的。

表 6 基于 UDDS 工况的前馈神经网络仿真结果(采用 Dropout 技术)

隐藏层节点数	SOC(T)	RMSE/(km/h)	燃油消耗/(L/100 km)	计算时间/ms
20	0.697 1	15.38	3.66	0.220
50	0.700 2	15.17	3.62	0.221
80	0.692 0	14.45	3.56	0.221
110	0.691 4	14.38	3.55	0.224
140	0.699 1	14.82	3.59	0.225

表 7 基于 UDDS 工况的前馈神经网络仿真结果(不采用 Dropout 技术)

隐藏层节点数	SOC(T)	RMSE/(km/h)	燃油消耗/(L/100 km)	计算时间/ms
20	0.694 5	15.25	3.63	0.218
50	0.695 5	14.88	3.59	0.218
80	0.692 1	14.47	3.56	0.219
110	0.701 1	14.92	3.61	0.220
140	0.698 1	15.41	3.66	0.222

表 8 基于 HWFET 工况的前馈神经网络仿真结果(采用 Dropout 技术)

隐藏层节点数	SOC(T)	RMSE/(km/h)	燃油消耗/(L/100 km)	计算时间/ms
20	0.698 1	8.13	3.62	0.210
50	0.700 5	8.06	3.59	0.213
80	0.696 6	7.31	3.51	0.213
110	0.694 9	7.24	3.50	0.214
140	0.697 1	7.46	3.52	0.216

表 9 基于 HWFET 工况的前馈神经网络仿真结果(不采用 Dropout 技术)

隐藏层节点数	SOC(T)	RMSE/(km/h)	燃油消耗/(L/100 km)	计算时间/ms
20	0.693 7	8.02	3.59	0.202
50	0.694 1	7.91	3.55	0.202
80	0.697 3	7.32	3.51	0.205
110	0.693 8	7.55	3.52	0.210
140	0.698 2	8.21	3.65	0.212

3.3 长短期记忆网络结果分析

训练过程中 LSTM 网络 1 500 次可达到预测精度要求,虽然减少了迭代次数,但是单次迭代时间较长,总训练时长 187 s。前馈神经网络内部无门控单元,参数更新更快,训练迭代次数 20 000 次,总训练时长仅 62 s。从计算时间上看,LSTM 网络计算时间比前馈神经网络长,但预测精度更高。即

LSTM 网络以计算复杂度换取预测精度,不过其计算复杂度在接受范围之内。

表 10、11 对比了单层和双层情况下的仿真结果。可以看到双层网络的结果整体比单层网络结果差,这是因为双层网络参数过多,产生了过拟合,因此单层结构的预测模型已足够适用速度预测。

表 10 基于 UDSS 工况的 LSTM 网络仿真结果

层数	SOC(T)	RMSE/(km/h)	燃油消耗/(L/100 km)	计算时间/ms
单层	0.697 0	13.95	3.38	0.228
双层	0.691 4	15.89	3.68	0.234

表 11 基于 HWFET 工况的 LSTM 网络仿真结果

层数	SOC(T)	RMSE/(km/h)	燃油消耗/(L/100 km)	计算时间/ms
单层	0.693 0	6.28	3.32	0.218
双层	0.692 7	8.03	3.60	0.227

4 预测能量管理评估

4.1 预测精度

将 DP、ECMS 与 DMPC 作为预测能量管理的比较基准。其中 DMPC 策略每一步的预测域扰动量已知。

分别提取三种预测模型中 RMSE 最小的模型进行分析比较,即采用高斯核的自回归支持向量机,采用 110 个节点数且 Dropout 概率等于 0.2 的前馈神经网络,采用单层结构的 LSTM 网络。表 12 进一步说明 LSTM 网络是最小 RMSE 策略,证明速度预测中 LSTM 网络门控单元的梯度流记忆功能发挥了良好作用。

图 10、11 直观反映了三种预测方法的结果。自回归支持向量机在长期预测时间段内没有很好地捕

捉速度趋势;前馈神经网络和 LSTM 网络都能较好地预测速度趋势,它们的预测精度分别比自回归支持向量机高 7.94%,10.69%。LSTM 网络比前馈神经网络能更好地预测速度细节,所以 LSTM 网络的 RMSE 更低。从 UDSS\HWFET 工况的维度来看,后者的 RMSE 明显小于前者,这是因为高速工况路况简单,预测更容易。

4.2 SOC 轨迹与计算时间

由表 12、13 可得,ECMS 策略比自回归 SVM 策略燃油消耗低,因为 ECMS 策略通过调节等效因子可以达到特定工况下的最佳值。三种预测模型中基于单层 LSTM 网络的模型预测控制策略燃油消耗量最小,因为该策略下的预测精度最高。图 12、13 为表 12、13 所示策略下 SOC 轨迹的结果。DP 与 MPC 的不同之处在于 DP 策略是全局优化离线策略,MPC 策略是预测域内的局部最优在线策略。MPC

下的预测域扰动量预测精度越高，SOC 轨迹越容易和 DMPC 策略相重合。

表 12 UDDS 工况下各种方法的结果对比

方法	SOC(T)	RMSE/(km/h)	燃油消耗/(L/100 km)	计算时间/ms
DP	0.700 0	—	3.27	—
ECMS	0.702 0	—	3.32	—
DMPC	0.697 1	0	3.30	—
自回归 SVM	0.696 9	15.62	3.67	0.102
前馈神经网络	0.691 4	14.38	3.55	0.220
LSTM 网络	0.697 0	13.95	3.38	0.228

表 13 HWFET 工况下各种方法的结果对比

方法	SOC(T)	RMSE/(km/h)	燃油消耗/(L/100 km)	计算时间/ms
DP	0.700 0	—	3.22	—
ECMS	0.705 2	—	3.30	—
DMPC	0.703 8	0	3.28	—
自回归 SVM	0.694 2	8.11	3.61	0.101
前馈神经网络	0.694 9	7.24	3.50	0.214
LSTM 网络	0.693 0	6.28	3.32	0.218

图 10 UDDS 工况车速预测结果

图 11 HWFET 工况车速预测结果

图 12 UDDS 工况下基于不同方法的 SOC 轨迹

图 13 HWFET 工况下基于不同方法的 SOC 轨迹

由表 12、13 的计算时间得知, LSTM 网络预测时间比其他预测模型长。因为 LSTM 网络内部存在门控单元, 计算复杂度高。但是其计算时间在接受范围内。同时预测过程处于毫秒量级, 满足实际系统的控制需求。

针对预测域内加速度超过约束的情况, 自适应支持向量机不会违反加速度约束。前馈神经网络和 LSTM 网络都会出现超过加速度约束边界的情况。将预测结果与加速度约束边界比较, 令超过的部分等于边界值。超过约束的部分相对整体来说占比很小, 对整体预测精度没有太大影响。

5 结论

利用机器学习方法设计了自回归支持向量机、

前馈神经网络、LSTM 网络三种不同的速度预测模型。得到以下结论。

(1) 利用模型预测控制策略进行了混合动力能量管理, 发现扰动量预测精度越高, 燃油消耗量越少。

(2) 单层 LSTM 网络的预测精度最高, 燃油消耗量最少; 前馈神经网络采用 Dropout 技术比未采用该技术时预测精度高, 即 Dropout 技术有效改善了预测模型, 防止了过拟合。

(3) UDDS 工况的预测 RSME 比 HWFET 工况下的 RSME 大, 可见行驶工况速度越大, 预测越精准。

(4) 利用 LSTM 网络预测扰动量的模型预测控制策略, UDDS 的最佳预测域大小是 14 s, HWFET 的最佳预测域大小是 15 s, 此时燃油消耗最少。

机器学习方法预测扰动量, 提升了模型预测控

制算法框架下扰动量的预测精度, 降低了控制过程中的代价值, 为多维外界环境信息预测高精度扰动量提供了计算思路。接下来的工作可以放在改变数据集上, 思路之一是把单一的历史速度信息和车车间距信息作为预测函数的输入进行未来工况的预测。

参 考 文 献

- [1] SABRI M F M, DANAPALASINGAM K A, RAHMAT M F. A review on hybrid electric vehicles architecture and energy management strategies[J]. *Renewable and Sustainable Energy Reviews*, 2016, 53: 1433-1442.
- [2] 王钦普, 游思雄, 李亮, 等. 插电式混合动力汽车能量管理策略研究综述[J]. *机械工程学报*, 2017, 53(16): 15-33.
WANG Qinpu, YOU Sixiong, LI Liang, et al. Survey on energy management strategy for plug-in hybrid electric vehicles[J]. *Journal of Mechanical Engineering*, 2017, 53(16): 15-33.
- [3] HUANG Y, WANG H, KHAJEPOUR A, et al. Model predictive control power management strategies for HEVs: A review[J]. *Journal of Power Sources*, 2017, 341: 91-106.
- [4] 张凤奇, 胡晓松, 许康辉, 等. 混合动力汽车模型预测能量管理研究现状与展望[J]. *机械工程学报*, 2019, 55(10): 86-108.
ZHANG Fengqi, HU Xiaosong, XU Kanghui, et al. Current status and prospects for model predictive energy management in hybrid electric vehicles[J]. *Journal of Mechanical Engineering*, 2019, 55(10): 86-108.
- [5] KAMAL M A S, MUKAI M, MURATA J, et al. Model predictive control of vehicles on urban roads for improved fuel economy[J]. *IEEE Transactions on Control Systems Technology*, 2013, 21(3): 831-841.
- [6] JOHFNNESSON L, ASBOGARD M, EGARDT B. Assessing the potential of predictive control for hybrid vehicle powertrains using stochastic dynamic programming[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2007, 8(1): 71-83.
- [7] 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(11): 1289-1294.
ZHAO Han, WU Di. A research on the control strategy of a parallel hev based on stochastic model predictive control[J]. *Automotive Engineering*, 2014(11): 1289-1294.
- [8] ZHANG F, XI J, LANGARI R. Real-time energy management strategy based on velocity forecasts using V2V and V2I communications[J]. *Intelligent Transportation Systems*, *IEEE Transactions on*, 2017, 18(2): 416-430.
- [9] SUN C, HU X, 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.
- [10] 谢浩. 基于 BP 神经网络及其优化算法的汽车车速预测[D]. 重庆: 重庆大学, 2014.
XIE Hao. Vehicle velocity prediction based on BP neural network and its optimization algorithm[D]. Chongqing: Chongqing University, 2014.
- [11] DOMINIK M, HARALD W, ROMAN S, et al. Short term prediction of a vehicle's velocity trajectory using ITS[J]. *SAE International Journal of Passenger Cars-Electronic and Electrical Systems*, 2015, 8(2): 364-370.
- [12] LIU J, PENG H. Modeling and control of a power-split hybrid vehicle[J]. *IEEE Transactions on Control Systems Technology*, 2008, 16(6): 1242-1251.
- [13] LANGARI R, WON J S. Intelligent energy management agent for a parallel hybrid vehicle-part I: System architecture and design of the driving situation identification process[J]. *IEEE Transactions on Vehicular Technology*, 2005, 54(3): 925-934.
- [14] SCHULDT C, LAPTEV I, CAPUTO B. Recognizing human actions: A local SVM approach[C]// *Proceedings of the 17th International Conference on Pattern Recognition*, 2004, ICPR. 26-26 Aug 2004, Cambridge, UK, IEEE, 2004: 32-36.
- [15] RIBEIRO B, SILVA C, VIEIRA A, et al. Financial distress model prediction using SVM+[C]// *The 2010 International Joint Conference on Neural Networks (IJCNN)*. 18-23 July 2010, Barcelona, Spain, IEEE, 2010: 1-7.
- [16] LI Y F, CHEN M N, LU X D, et al. Research on optimized GA-SVM vehicle speed prediction model based on driver-vehicle-road-traffic system[J]. *Science China*, 2018, 61(5): 782-790.
- [17] ZHANG Y, XIONG R, HE H, et al. Long short-term memory recurrent neural network for remaining useful life prediction of lithium-ion batteries[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(7): 5695-5705.
- [18] ZHAO Z, CHEN W, WU X, et al. LSTM network: A deep learning approach for short-term traffic forecast[J]. *IET Intelligent Transport Systems*, 2017, 11(2): 68-75.

- [19] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [20] 胡晓松, 唐小林. 电动车辆锂离子动力电池建模方法综述[J]. 机械工程学报, 2017, 53(16): 34-45.
HU Xiaosong, TANG Xiaolin. Review of modeling techniques for lithium-ion traction batteries in electric vehicles[J]. Journal of Mechanical Engineering, 2017, 53(16): 34-45.
- [21] BORHAN H A, VAHIDI A, PHILLIPS A M, et al. Predictive energy management of a power-split hybrid electric vehicle[C]// 2009 American Control Conference, 10-12 June 2009, St. Louis, MO, USA, 2009, IEEE 2009: 3970-3976.
- [22] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [23] IOSIFIDIS A, TEFAS A, PITAS I. DropELM: Fast neural network regularization with dropout and DropConnect[J]. Neurocomputing, 2015, 162: 57-66.
- [24] GRAVES A. Generating sequences with recurrent neural networks[J/OL]. Computer Ence, 2013[2014-06-05]. <https://arxiv.org/abs/1308.0850>.

作者简介: 胡晓松, 男, 1983 年出生, 博士, 教授, 博士研究生导师。主要研究方向为电池储能系统、混合动力系统控制、车联网系统。

E-mail: xiaosonghu@cqu.edu.cn

陈科坪, 男, 1994 年出生。主要研究方向为混合动力系统控制, 路径规划。

E-mail: kepingchen@cqu.edu.cn

唐小林(通信作者), 男, 1984 年出生, 博士, 副教授, 博士研究生导师。主要研究方向为混合动力汽车 NVH 与能量管理, 路径规划。

E-mail: tangxiaolin6@126.com