



(12)发明专利

(10)授权公告号 CN 107688343 B

(45)授权公告日 2019.12.06

(21)申请号 201710645889.2

(22)申请日 2017.08.01

(65)同一申请的已公布的文献号
申请公布号 CN 107688343 A

(43)申请公布日 2018.02.13

(73)专利权人 北京理工大学
地址 100081 北京市海淀区中关村南大街5号

(72)发明人 项昌乐 王伟达 丁峰 马越
韩立金

(74)专利代理机构 北京隆源天恒知识产权代理
事务所(普通合伙) 11473
代理人 闫冬

(51)Int.Cl.
G05D 1/02(2006.01)

(56)对比文件

CN 103914985 A,2014.07.09,
CN 202703576 U,2013.01.30,
CN 105416077 A,2016.03.23,
CN 104925063 A,2015.09.23,
CN 102729991 A,2012.10.17,
CN 104627185 A,2015.05.20,
CN 106494388 A,2017.03.15,
CN 102019926 A,2011.04.20,
CN 106427987 A,2017.02.22,
JP 2016055759 A,2016.04.21,
林歆悠 等.基于随机动态规划的混联式混合动力客车能量管理策略.《汽车工程》.2012,第34卷(第9期),第830-836页.

审查员 杜晓强

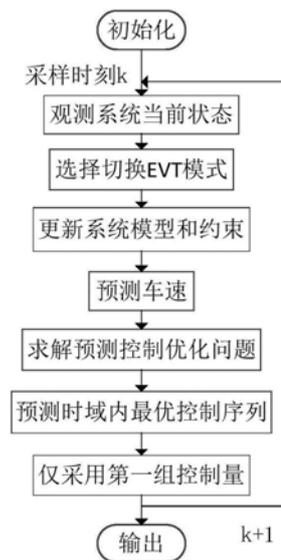
权利要求书2页 说明书11页 附图5页

(54)发明名称

一种混合动力车辆的能量控制方法

(57)摘要

本发明公开了一种混合动力车辆的能量控制方法,该方法包括:(1)观测当前系统状态,包括车辆行驶车速,驾驶员踏板信息,电池SOC,发动机转速转矩等;(2)依据车辆行驶车速与驾驶员踏板信息判断当前EVT模式状态,并更新当前系统模型与系统约束,并假设在预测时域内EVT模式状态保持不变;(3)对预测时域内的未来车速进行预测,得到预测时域内系统观测输入量;(4)在预测时域内构造预测控制优化问题,并通过动态规划算法在线进行数值求解;(5)计算得到预测时域内的最优控制序列;(6)仅采用第一组最优控制量,在该采样时刻作用于系统,舍弃其余控制量;(7)在下一时刻重复这一过程,直至行驶结束。



1. 一种混合动力车辆的能量控制方法,该方法包括:

(1) 观测当前系统状态,包括车辆行驶车速,驾驶员踏板信息,电池SOC,发动机转速转矩;

(2) 依据车辆行驶车速与驾驶员踏板信息判断当前EVT模式状态,并更新当前系统模型与系统约束,并假设在预测时域内EVT模式状态保持不变;

(3) 对预测时域内的未来车速进行预测,得到预测时域内系统观测输入量;

(4) 在预测时域内构造预测控制优化问题,并通过动态规划算法在线进行数值求解;

(5) 计算得到预测时域内的最优控制序列;

(6) 仅采用第一组最优控制量,在当前采样时刻作用于系统,舍弃其余控制量;

(7) 在下一时刻重复步骤(1)至(6),直至行驶结束。

2. 根据权利要求1所述的能量控制方法,其中根据以下分类预测方法预测未来车速:

利用K均值聚类算法在离线状态下将车辆行驶工况分类为平稳工况与快变工况两类,并在在线阶段实时判断车辆当前所处工况类别;

针对平稳工况,采用基于马尔科夫链的车速预测方法,而针对快变工况,采用基于径向基神经网络的车速预测方法,以此综合利用两种方法的优点以达到最优的预测效果。

3. 根据权利要求2所述的能量控制方法,其中根据以下特征参数:最大加速度、最大减速度、平均加速度、车速标准方差、最高车速与最低车速之差、加速度标准方差来将车辆行驶工况分类。

4. 根据权利要求2所述的能量控制方法,其中采用K均值聚类算法,通过计算样本间的亲疏程度来进行数据分类,具体工况判断步骤如下:

离线阶段:(1) 组合多个标准循环工况构成样本;

(2) 在循环工况中每一采样时刻计算过去10秒的工况特征参数,得到特征参数样本数据 $[x_{11}, x_{12}, \dots, x_{1m}]$, $[x_{21}, x_{22}, \dots, x_{2m}]$, \dots , $[x_{n1}, x_{n2}, \dots, x_{nm}]$,其中 m 为特征参数序数, n 为循环工况长度;

(3) 应用K均值聚类算法,随机选取聚类中心 $c_1 = [c_{11}, c_{12}, \dots, c_{1m}]$, $c_2 = [c_{21}, c_{22}, \dots, c_{2m}]$,计算所有样本与聚类中心的距离,并将样本按照最近邻规则分组,归属不同 $\theta_m(k)$ 聚类域,其中 k 为迭代次数, n_m 为第 m 类特征参数中包含的循环工况长度, x_i 为特征参数样本数值,再按下式调整聚类中心:

$$c_m(k+1) = \frac{1}{n_m} \sum_{x_i \in \theta_m(k)} x_i, i=1, 2, \dots, n_m \quad (16)$$

如果 $c_m(k+1) \neq c_m(k)$,则继续调整聚类中心,直至聚类中心不再变化,则认为分类稳定,得到平稳工况的聚类中心 c_1 和快变工况的聚类中心 c_2 ;

在线阶段:(1) 车辆实际行驶过程中,在当前采样时刻计算出过去10秒的工况特征参数值 $[x_1, x_1, \dots, x_m]$;

(2) 依据下式计算特征参数值 $[x_1, x_1, \dots, x_m]$ 到两个聚类中心 c_1 和 c_2 的距离 d :

$$d_j = \sqrt{(x_1 - c_{j1})^2 + (x_2 - c_{j2})^2 + \dots + (x_m - c_{jm})^2} \quad (17)$$

式中: $j=1, 2$ 对应着两类工况;

(3) 若 $d_1 \leq d_2$,则判断当前时刻为平稳工况,若 $d_1 > d_2$,则判断当前时刻为快变工况。

5. 根据权利要求2所述的能量控制方法,其中平稳工况下假设车辆在每一时刻的加速度与历史信息无关,只由当前信息决定,从而认为车辆的加速度变化是一种马尔科夫过程,使用马尔科夫链模型来模拟车速与加速度的变化规律,并在平稳工况下对未来车速进行预测。

6. 根据权利要求2所述的能量控制方法,其中针对快变工况,运用径向基神经网络理论,通过在线对驾驶员驾驶行为的学习进行未来车速的预测。

7. 根据权利要求2所述的能量控制方法,其中径向基神经网络模型依据历史车速和当前驾驶员踏板信息,预测出未来车速,同时,当前产生的车辆信息即作为新的历史信息,通过自组织中心选取和伪逆法确定权值的方法实现神经网络的自适应在线学习。

一种混合动力车辆的能量控制方法

技术领域

[0001] 本发明涉及一种车辆的能量控制方法,尤其是一种混合动力车辆的能量控制方法。

背景技术

[0002] 混合动力车辆是目前解决车辆能源消耗过度和空气质量污染的有效途径之一。其中双模式传动系统相较于其他形式的混合动力传动方案能够更好的满足重型非道路车辆调速范围广和驱动功率大等特殊需求,但是该方案结构较为复杂,对能量控制方法的要求更高,设计出可实时使用的最优的能量控制方法将成为保证双模式混合动力车辆能够正常高效运行的核心内容。

[0003] 目前,在工业界使用最多的是基于规则的能量控制方法,规则的设计大都来源于启发式发现和工程师经验,虽然其设计简单,易于实现,但是对不同工况适应性差,无法得到最优的控制效果。为了追求更好的控制效果,学术界做了大量的科学研究探索基于优化的能量控制方法,其主要思路是建立系统目标成本函数和约束条件,通过优化算法求解得到最优控制量。其中动态规划算法应用最为广泛,但是其需要预先知晓全局工况,所以只能用于仿真。等效燃油消耗策略可以实时在线运用,但是却有着针对不同工况等效因子难以设定的弊端。而近年来发展起来的预测控制算法(Model Predictive Control, MPC)采用多步测试、滚动优化和反馈校正的思路,得到了良好的实时控制效果。该方法很大程度上依赖于有效的对未来车速进行预测,现有技术中假设未来车速保持不变;或者假设车速按指数规律变化,这些方法简单却并不准确;或者借助车载导航系统获得车辆未来行驶车速;或者通过识别特种工作车辆的重复工况来预测未来车速,这些方法需要借助GPS系统或是先验工况信息,并不适用于没有定位系统和感知雷达的非道路车辆。

发明内容

[0004] 针对以上问题,本发明提出了一种混合动力车辆的能量控制方法,采用K均值(Kmeans)聚类算法将工况分类,并针对不同类型的工况采用马尔科夫链或是径向基神经网络的方法对未来车速进行预测,实现非道路双模式混合动力车辆性能的改善。

[0005] 本发明的主要目的是提供一种混合动力车辆的能量控制方法。

[0006] 本发明的目的可以通过以下途径来实现:

[0007] 一种混合动力车辆的能量控制方法,该方法包括:

[0008] (1) 观测当前系统状态,包括车辆行驶车速,驾驶员踏板信息,电池SOC,发动机转速转矩等;

[0009] (2) 依据车辆行驶车速与驾驶员踏板信息判断当前EVT模式状态,并更新当前系统模型与系统约束,并假设在预测时域内EVT模式状态保持不变;

[0010] (3) 对预测时域内的未来车速进行预测,得到预测时域内系统观测输入量;

[0011] (4) 在预测时域内构造预测控制优化问题,并通过动态规划算法在线进行数值求

解；

[0012] (5) 计算得到预测时域内的最优控制序列；

[0013] (6) 仅采用第一组最优控制量，在该采样时刻作用于系统，舍弃其余控制量；

[0014] (7) 在下一时刻重复步骤(1)至(6)，直至行驶结束。

[0015] 本发明的混合动力车辆的能量控制方法，进一步地，其中根据以下特征参数：最大加速度(m/s²)、最大减速度(m/s²)、平均加速度(m/s²)、车速标准方差(km/h)、最高车速与最低车速之差(km/h)、加速度标准方差(m/s²)来将车辆行驶工况分类。

[0016] 本发明的混合动力车辆的能量控制方法，进一步地，其中采用K均值聚类算法，通过计算样本间的亲疏程度来进行数据分类，最终实现同一类中的数据具有较大的特征相似性，不同类之间则差异较大，具体工况判断步骤如下：

[0017] 离线阶段：(1) 组合多个标准循环工况构成样本；

[0018] (2) 在循环工况中每一采样时刻计算过去10秒的工况特征参数，得到特征参数样本数据 $[x_{11}, x_{12}, \dots, x_{1m}]$, $[x_{21}, x_{22}, \dots, x_{2m}]$, \dots , $[x_{n1}, x_{n2}, \dots, x_{nm}]$ ，其中m为特征参数序号，n为循环工况长度；

[0019] (3) 应用K均值聚类算法，随机选取聚类中心 $c_1 = [c_{11}, c_{12}, \dots, c_{1m}]$, $c_2 = [c_{21}, c_{22}, \dots, c_{2m}]$ ，计算所有样本与聚类中心的距离，并将样本按照最近邻规则分组，归属不同 $\theta_m(k)$ 聚类域，其中k为迭代次数， n_m 为第m类特征参数中包含的循环工况长度， x_i 为特征参数样本数值，再按下式调整聚类中心：

$$[0020] \quad c_m(k+1) = \frac{1}{n_m} \sum_{x_i \in \theta_m(k)} x_i, i=1, 2, \dots, n_m \quad (16)$$

[0021] 如果 $c_m(k+1) \neq c_m(k)$ ，则继续调整聚类中心，直至聚类中心不再变化，则认为分类稳定，得到平稳工况的聚类中心 c_1 和快变工况的聚类中心 c_2 ；

[0022] 在线阶段：(1) 车辆实际行驶过程中，在当前采样时刻计算出过去10秒的工况特征参数值 $[x_1, x_1, \dots, x_m]$ ；

[0023] (2) 依据下式计算特征参数值 $[x_1, x_1, \dots, x_m]$ 到两个聚类中心 c_1 和 c_2 的距离d：

[0024]

$$d_j = \sqrt{(x_1 - c_{j1})^2 + (x_2 - c_{j2})^2 + \dots + (x_m - c_{jm})^2} \quad (17)$$

[0025] 式中： $j=1, 2$ 对应着两类工况；

[0026] (3) 若 $d_1 \leq d_2$ ，则判断当前时刻为平稳工况，若 $d_1 > d_2$ ，则判断当前时刻为快变工况。

[0027] 本发明的混合动力车辆的能量控制方法，进一步地，其中平稳工况下假设车辆在每一时刻的加速度与历史信息无关，只由当前信息决定，从而认为车辆的加速度变化是一种马尔科夫过程，使用马尔科夫链模型来模拟车速与加速度的变化规律，并在平稳工况下对未来车速进行预测。

[0028] 本发明的混合动力车辆的能量控制方法，进一步地，其中针对快变工况，运用径向基神经网络理论，通过在线对驾驶员驾驶行为的学习进行未来车速的预测。

[0029] 本发明的混合动力车辆的能量控制方法，进一步地，其中径向基神经网络模型依

据历史车速和当前驾驶员踏板信息,预测出未来车速,同时,当前产生的车辆信息即作为新的历史信息,通过自组织中心选取和伪逆法确定权值的方法实现神经网络的自适应在线学习。

附图说明

- [0030] 图1是一种双模式混合动力车辆系统结构示意图。
- [0031] 图2是本发明的能量控制方法流程图。
- [0032] 图3是本发明组合的循环工况示意图。
- [0033] 图4是本发明的马尔科夫链模型转移概率矩阵图。
- [0034] 图5是本发明的径向基神经网络车速预测结构图。
- [0035] 图6是本发明的在线工况判断结果图。
- [0036] 图7是本发明的车速预测结果图。
- [0037] 图8是部分循环工况预测误差对比图。
- [0038] 图9是本发明的车速,EVT模式,电池SOC仿真结果图。
- [0039] 图10是本发明的发动机、电机A与电机B的转速转矩仿真结果图。
- [0040] 图11是本发明的发动机工作点分布仿真结果图。
- [0041] 图12是本发明的发动机工作点仿真结果对比:(a) 预测控制,(b) 保持控制,(c) 动态规划,(d) 规则。
- [0042] 图13是本发明的电池SOC仿真结果对比:(a) 预测控制,(b) 保持控制,(c) 动态规划,(d) 规则。

具体实施方式

[0043] 以某型双模式混合动力车辆为例说明本发明的具体实施方式。系统结构如图1所示,主要参数如表1所示。系统两种混合动力工作模式EVT1 (Electronically Controlled Continuously Variable Transmission,EVT) 模式和EVT2模式的切换可以通过操纵离合器和制动器来实现,当离合器分离,制动器接合时为EVT1模式;当离合器接合,制动器分离时为EVT2模式。

[0044] 表1双模式混合动力车辆主要参数

[0045]

部件	参数	选值
整车	动力结构	双模式混合动力
	整车质量	2500kg
发动机	类型	柴油机
	最大功率	120kW@2130r/min
	最大扭矩	600Nm@1600r/min
电机 A、B	类型	永磁同步电机
	额定功率	60kW
电池组	容量	7.6Ah
	额定电压	360V
传动系统	行星排 1 系数	2.13
	行星排 2 系数	2.13
	行星排 3 系数	2.33

[0046] 面向控制的建模中,忽略行星轮的惯量以及各元件之间的摩擦,并假设连接都是刚性的,可得传动系统模型,

[0047] EVT1模式:

$$[0048] \begin{bmatrix} \omega_A \\ \omega_B \end{bmatrix} = \begin{bmatrix} \frac{(1+k_1)(1+k_2)}{k_1 k_2} & -\frac{(1+k_1+k_2)(1+k_3)}{k_1 k_2} \\ 0 & 1+k_3 \end{bmatrix} \begin{bmatrix} \omega_i \\ \omega_o \end{bmatrix} \quad (1)$$

$$[0049] \begin{bmatrix} T_A \\ T_B \end{bmatrix} = \begin{bmatrix} -\frac{k_1 k_2}{(1+k_1)(1+k_2)} & 0 \\ \frac{1+k_1+k_2}{(1+k_1)(1+k_2)} & \frac{1}{1+k_3} \end{bmatrix} \begin{bmatrix} T_i \\ T_o \end{bmatrix} \quad (2)$$

[0050] EVT2模式:

$$[0051] \begin{bmatrix} \omega_A \\ \omega_B \end{bmatrix} = \begin{bmatrix} -\frac{1+k_2}{k_1} & \frac{1+k_1+k_2}{k_1} \\ 1+k_2 & -k_2 \end{bmatrix} \begin{bmatrix} \omega_i \\ \omega_o \end{bmatrix} \quad (3)$$

$$[0052] \begin{bmatrix} T_A \\ T_B \end{bmatrix} = \begin{bmatrix} -\frac{k_1 k_2}{(1+k_1)(1+k_2)} & 0 \\ \frac{1+k_1+k_2}{(1+k_1)(1+k_2)} & \frac{1}{1+k_3} \end{bmatrix} \begin{bmatrix} T_i \\ T_o \end{bmatrix} \quad (4)$$

[0053] 式中: k_1, k_2, k_3 分别为三个行星排的固有参数, ω_A, ω_B 为电机A、B的转速, T_A, T_B 为电机A、B的转矩, ω_i, ω_o 为耦合机构输入端和输出端转速, T_i, T_o 分别为耦合机构输入端和输出端转矩。

[0054] 同时由于部件之间的机械连接,系统还满足以下关系式:

$$[0055] \omega_e = i_q \omega_i \quad (5)$$

$$[0056] V = r_w \omega_o / i_f \quad (6)$$

$$[0057] T_e = T_i / i_q \quad (7)$$

$$[0058] T_w = i_f T_o \quad (8)$$

[0059] 式中: ω_e 为发动机转速, T_e 为发动机转矩, V 为车速, T_w 为车轮上输出转矩, i_q 为前传动传动比, r_w 为车轮半径, i_f 为后传动传动比。

[0060] 发动机模型采用由试验数据构造的MAP图模型,假设发动机已经完全预热,其燃油消耗率为转速转矩的静态函数:

$$[0061] \dot{m}_f = f_e(\omega_e, T_e) \quad (9)$$

[0062] 式中: \dot{m}_f 为发动机燃油消耗, f_e 为MAP图。

[0063] 电池的荷电状态SOC是混合动力车辆能量控制方法中的一个重要变量,这里采用内阻模型建模,并忽略温度的影响,得到如下SOC表达式:

$$[0064] \dot{SOC} = \frac{-V_{oc} + \sqrt{V_{oc}^2 - 4R_{batt}(T_A \omega_A \eta_A^{k_A} + T_B \omega_B \eta_B^{k_B})}}{2C_{batt} R_{batt}} \quad (10)$$

[0065] 式中: V_{oc} 为电池开路电压, R_{batt} 为电池内阻, C_{batt} 为电池容量, η_A, η_B 分别为电机A、B的效率,指数 k_A, k_B 当电机给电池充电时,等于1,当电机为电池放电时,等于-1。

[0066] 不考虑车辆横向和垂向的运动,忽略坡度,则根据车辆行驶平衡方程可得整车动

力学模型：

$$[0067] \quad m\dot{V} = \frac{T_w}{r_w} - \frac{1}{2}\rho C_d A_f V^2 - \mu mg \quad (11)$$

[0068] 式中： m 为整车质量， ρ 为空气密度， C_d 为空气阻力系数， A_f 为车辆迎风面积， μ 为车轮滚动阻力系数， g 为重力加速度。

[0069] 双模式混合动力车辆的能量控制方法主要目的是在满足行驶需求和系统约束的条件下，在线合理分配需求功率，调整发动机工作点，以获得更佳的燃油经济性，并维持电池SOC。本发明基于预测控制算法在线进行功率分配的实时优化，选取发动机转速与转矩为系统控制量 u ，定义系统状态量为 x ，系统观测输入量为 v ，系统输出量为 y ，则可以将面向控制系统模型表述为：

$$[0070] \quad \begin{aligned} \dot{x} &= f(x, u, v) \\ y &= g(x, u, v) \end{aligned} \quad (12)$$

[0071] 式中： $x = [SOC]$ ， $u = [T_e \ \omega_e]^T$ ， $v = [V \ T_w]^T$ ， $y = [SOC \ \dot{m}_f]^T$ 。

[0072] 在每一个采样时刻 k ，预测时域内的优化目标函数为：

$$[0073] \quad J = \int_k^{k+P} (w_s (SOC(t) - SOC_r)^2 + w_m (\dot{m}_f(t))^2) dt \quad (13)$$

[0074] 式中： w_s 和 w_m 分别为对应项的权重系数， SOC_r 为电池SOC参考值， P 为预测时域。同时，以下物理约束需要被满足：

$$[0075] \quad \begin{aligned} SOC_{\min} &\leq SOC \leq SOC_{\max} \\ T_{e_{\min}} &\leq T_e \leq T_{e_{\max}} \\ \Delta T_{e_{\min}} &\leq \Delta T_e \leq \Delta T_{e_{\max}} \\ T_{A_{\min}} &\leq T_A \leq T_{A_{\max}} \\ T_{B_{\min}} &\leq T_B \leq T_{B_{\max}} \\ \omega_{e_{\min}} &\leq \omega_e \leq \omega_{e_{\max}} \\ \Delta \omega_{e_{\min}} &\leq \Delta \omega_e \leq \Delta \omega_{e_{\max}} \\ \omega_{A_{\min}} &\leq \omega_A \leq \omega_{A_{\max}} \\ \omega_{B_{\min}} &\leq \omega_B \leq \omega_{B_{\max}} \end{aligned} \quad (14)$$

[0076] 式中： $*_{\max}$ 与 $*_{\min}$ 分别为对应项的上下界。

[0077] 求解优化问题时将系统模型离散化，由于预测时域较短，并且电池SOC每一时刻可行域范围小，所以动态规划算法可被用来在线实时求解优化问题，假设 $u^*(k) = [u^*(k), \dots, u^*(k+P-1)]$ 为预测时域内的最优控制量序列，则当前时刻系统所采用的控制量为

$$[0078] \quad u(x(k)) = u^*(k) \quad (15)$$

[0079] 预测控制的核心思想就是在每一个采样时刻对有限预测时域内求解一个优化问题，计算出预测时域内的最优控制序列，但只实施该采样时刻的最优控制并舍弃其他控制量，再在下一采样时刻重复这一过程。将预测控制用于双模式混合动力车辆能量控制方法中，即可根据当前驾驶员踏板信息，并结合车速、电池SOC、发动机转速转矩等车辆信息，通过实时优化进行功率分配，提高车辆燃油经济性。由于无法预知整个循环工况，所以该策略

无法得到全局最优解,但是其能够在线实施,并通过滚动优化的方式得到全局近似最优解,同时能够顾及由于模型失配、干扰等因素引起的不确定性,使得控制保持实际的最优。在每一个采样时刻 k ,能量控制方法流程图如图2所示,具体来说,将进行以下步骤:

[0080] (1) 观测当前系统状态,包括车辆行驶车速,驾驶员踏板信息,电池SOC等。

[0081] (2) 依据车辆行驶车速与驾驶员踏板信息判断当前EVT模式状态,并更新当前系统模型与系统约束。并假设在预测时域内EVT模式状态保持不变。

[0082] (3) 对预测时域内的未来车速进行预测,得到预测时域内系统观测输入量 v ,详细方法将在下文进行介绍。

[0083] (4) 在预测时域内构造预测控制优化问题,并通过动态规划算法在线进行数值求解。

[0084] (5) 计算得到预测时域内的最优控制序列。

[0085] (6) 仅采用第一组最优控制量,在该采样时刻作用于系统,舍弃其余控制量。

[0086] (7) 在下一时刻重复步骤(1)至(6)。

[0087] 在没有任何行驶工况先验信息的情况下,如何利用车辆历史和当前数据合理精确的预测车辆未来车速,将很大程度上影响能量控制方法的优化效果。本发明利用K均值聚类算法在离线状态下将工况分类为平稳工况与快变工况两类,并在在线阶段实时判断车辆当前所处工况类别。针对平稳工况,采用基于马尔科夫链的车速预测方法,而针对快变工况,采用基于径向基神经网络的车速预测方法,以此综合利用两种方法的优点以达到最优的预测效果。同时,将预测车速代入式(11)即可计算得到预测时域内的需求转矩。

[0088] 平稳工况与快变工况的主要差别在于工况内速度的波动以及加速度的大小,为了区别两种工况类型,需要依据工况内的特征参数将两种工况分类,表2为选取的工况特征参数。

[0089] 表2工况特征参数

序号	特征参数
1	最大加速度 (m/s^2)
2	最大减速度 (m/s^2)
3	平均加速度 (m/s^2)
4	车速标准方差 (km/h)
5	最高车速与最低车速之差 (km/h)
6	加速度标准方差 (m/s^2)

[0091] 采用K均值聚类算法,通过计算样本间的亲疏程度来进行数据分类,最终实现同一类中的数据具有较大的特征相似性,不同类之间则差异较大,具体工况判断步骤如下:

[0092] 离线阶段:(1) 组合多个标准循环工况构成样本,如图3所示。

[0093] (2) 在循环工况中每一采样时刻计算过去10秒的工况特征参数,得到特征参数样本数据 $[x_{11}, x_{12}, \dots, x_{1m}], [x_{21}, x_{22}, \dots, x_{2m}], \dots, [x_{n1}, x_{n2}, \dots, x_{nm}]$,其中 m 为特征参数序数, n 为循环工况长度。

[0094] (3) 应用K均值聚类算法,随机选取聚类中心 $c_1 = [c_{11}, c_{12}, \dots, c_{1m}]$, $c_2 = [c_{21}, c_{22}, \dots, c_{2m}]$,计算所有样本与聚类中心的距离,并将样本按照最近邻规则分组,归属不同 θ_m (k) 聚类域,其中 k 为迭代次数, n_m 为第 m 类特征参数中包含的循环工况长度, x_i 为特征参数样本数值,再按下式调整聚类中心:

$$[0095] \quad c_m(k+1) = \frac{1}{n_m} \sum_{x_i \in \theta_m(k)} x_i, i=1,2,\dots,n_m \quad (16)$$

[0096] 如果 $c_m(k+1) \neq c_m(k)$,则继续调整聚类中心,直至聚类中心不再变化,则认为分类稳定,得到平稳工况的聚类中心 c_1 和快变工况的聚类中心 c_2 。

[0097] 在线阶段:(1)车辆实际行驶过程中,在当前采样时刻计算出过去10秒的工况特征参数值 $[x_1, x_1, \dots, x_m]$ 。

[0098] (2)依据下式计算特征参数值 $[x_1, x_1, \dots, x_m]$ 到两个聚类中心 c_1 和 c_2 的距离 d :

[0099]

$$d_j = \sqrt{(x_1 - c_{j1})^2 + (x_2 - c_{j2})^2 + \dots + (x_m - c_{jm})^2} \quad (17)$$

[0100] 式中: $j=1,2$ 对应着两类工况。

[0101] (3)若 $d_1 \leq d_2$,则判断当前时刻为平稳工况,若 $d_1 > d_2$,则判断当前时刻为快变工况。

[0102] 假设车辆在每一时刻的加速度与历史信息无关,只由当前信息决定,从而认为车辆的加速度变化是一种马尔科夫过程,这里即可以使用马尔科夫链模型来模拟车速与加速度的变化规律,并在平稳工况下对未来车速进行预测。

[0103] 依据不同的驾驶员踏板开度 $\alpha \leq 0, 0 < \alpha \leq 0.2, 0.2 < \alpha \leq 0.4, 0.4 < \alpha \leq 0.6, 0.6 < \alpha \leq 0.8, 0.8 < \alpha \leq 1$,建立六组相应的一阶马尔科夫链模型。每一组马尔科夫链模型均由车速 V (0至30m/s)和加速度 a (-1.5至1.5m/s²)构成离散的网格空间,定义车辆速度为当前状态量,将其划分为 p 个区间,由 $i \in \{1, \dots, p\}$ 索引,定义车辆加速度为下一时刻输出量,将其划分为 q 个区间,由 $j \in \{1, \dots, q\}$ 索引。则每一组马尔科夫链模型的转移概率矩阵 T 可以被表述为:

$$[0104] \quad T_{ij} = \Pr[a_{k+n+1} = \bar{a}_j | V_{k+n} = \bar{V}_i] \quad (18)$$

[0105] 式中: $n \in \{1, \dots, N_p\}$ 为预测时域内所需要预测车速的目标时刻, T_{ij} 为在当前时刻车速 $V_{k+n} = V_i$ 的情况下,车辆加速度在下一时刻演变至 a_j 的概率。

[0106] 在初始状态下,选择典型平稳工况,根据下式计算得出马尔科夫链模型转移概率矩阵,

$$[0107] \quad T_{ij} = \frac{N_{ij}}{\sum_{j=1}^q N_i} \quad (19)$$

[0108] 式中: N_{ij} 为当前时刻为 i 下一时刻为 j 出现的次数。图4所示即为在驾驶员踏板开度 $0 < \alpha \leq 0.2$ 时,马尔科夫链模型转移概率矩阵。

[0109] 在实时运行中,马尔科夫链模型需要在线自我修正以适应工况的变化,在当前时刻 k ,若前一时刻车速 $V_{k-1} = V_i$,这一时刻发生 $a_k = a_j$,则这一事件下马尔科夫链转移概率矩阵自适应修正为:

$$[0110] \quad T(k)_{ij} = T(k-1)_{ij} + \lambda \quad (20)$$

$$[0111] \quad T(k)_{is} = T(k-1)_{is} - \frac{\lambda}{q} \quad (21)$$

[0112] 式中： $s \in \{1, \dots, q\}$, $s \neq j$, λ 为自适应系数。式(20)观测到当前时刻发生的这一事件,并将马尔科夫链转移概率矩阵中这一事件的概率修正,式(21)修正这一事件发生时该状态下其他输出值的概率。可以注意到,实际自适应修正过程中,当前时刻转移概率矩阵中仅有一列概率数据被更新,其他概率均保持不变。

[0113] 根据以上马尔科夫链模型,即可在当前时刻 k 预测出下一时刻车辆加速度,并求出下一时刻车速:

$$[0114] \quad V(k+1) = V(k) + \sum_{j=1}^q (a_j(k+1) \times T_{V(k),j}) \quad (22)$$

[0115] 同理,预测时域内各时刻的车速均可由上一时刻车速计算得到:

$$[0116] \quad V(k+n+1) = V(k+n) + \sum_{j=1}^q (a_j(k+n+1) \times T_{V(k+n),j}) \quad (23)$$

[0117] 式中： $n \leq P$ 为预测时域内各目标时刻。

[0118] 基于马尔科夫链的预测方法在平稳工况下能够有效的预测未来车速,但是在快变工况下无法有效的学习驾驶员行为,致使其预测精度较差。所以,针对快变工况,本发明运用径向基神经网络理论,通过在线对驾驶员驾驶行为的学习进行未来车速的预测。

[0119] 径向基神经网络是一种局部逼近网络,相较于其他形式的神经网络,其收敛速度快且计算量小,最适合应用于混合动力车辆在线车速预测。这里,定义神经网络模型的输入 N_{in} 为驾驶员踏板信息和过去一段时间的车速:

$$[0120] \quad N_{in} = \alpha, V_k, V_{k-1}, \dots, V_{k-H_h} \quad (24)$$

[0121] 式中： H_h 为过去车速向量长度。模型的输出 N_{out} 为未来一段时间的预测车速:

$$[0122] \quad N_{out} = V_{k+1}, V_{k+2}, \dots, V_{k+P} \quad (25)$$

[0123] 隐藏层中神经元采用高斯函数作为径向基函数:

$$[0124] \quad y_j = \sum_{i=1}^h \omega_{ij} \exp\left(-\frac{\|b_j x - c_i\|^2}{2\sigma^2}\right), \quad j = 1, 2, \dots, P \quad (26)$$

[0125] 式中： y_j 为神经网络输出, ω_{ij} 为输出权值, b_f 为开发者预设的神经元阈值, x 为神经网络输入, c_i 为神经元节点中心, σ 为神经元径向基函数扩散宽度, h 为隐藏层节点数。如此,即可得到车速预测的非线性神经网络模型:

$$[0126] \quad [V_k, V_{k+1}, \dots, V_{k+P}] = f_n[\alpha, V_k, V_{k-1}, \dots, V_{k-H_h}] \quad (27)$$

[0127] 式中： f_n 为径向基神经网络映射,其结构如图5所示。

[0128] 设定 H_h 为9,即历史车速为过去10个车速量,则该径向基神经网络输入量为11个,预测车速为未来5秒的车速,则神经网络输出量为5个,神经元个数与输入量个数相等,即 $h = 10$ 。在车辆行驶过程中,径向基神经网络模型依据历史车速和当前驾驶员踏板信息,预测出未来车速,同时,当前产生的车辆信息即作为新的历史信息,通过自组织中心选取和伪逆法确定权值的方法实现神经网络的自适应在线学习。

[0129] 为了验证本发明提出的能量控制方法的有效性,在Matlab环境下进行了仿真试验。仿真中设定能量控制方法采样时间间隔为1秒,这既可以保证系统动态过程的稳定控制,又可以容许较大的控制计算量。同时设定预测时域为 $P = 5$ 秒,电池SOC初始值与参考值皆为0.65,仿真结果如图6所示。

[0130] 图6所示为仿真在线过程中,针对一典型综合循环工况,判断出的工况类别结果。由图中可以看出,在车辆速度急剧变化时,如370s至440s,980s至1030s和1160s至1220s之间,工况判断为快变工况;而在车速小范围波动或是车辆缓慢加减速时,如600s至700s和1220s至1900s之间,工况判断为平稳工况,由此可以说明工况类别判断方法的有效性。

[0131] 图7所示为车速预测结果的直观展示,可以看出,在大部分时间内本发明提出的车速预测方法都能较为准确的进行预测。

[0132] 为了进一步合理的通过数据对比评价预测结果,这里引入均方根误差(Root Mean Square Error, RMSE)作为评价指标。RMSE通过计算样本值与真实值之间差值的标准差表征样本精度,适用于用来对比预测值与真实值,其计算公式如下:

$$[0133] \quad RMSE(k) = \sqrt{\frac{\sum_{i=1}^P (V_p(k+i) - V_c(k+i))^2}{P}} \quad (28)$$

$$[0134] \quad RMSE = \frac{\sum_{k=1}^{N_c} RMSE(k)}{N_c} \quad (29)$$

[0135] 式中:RMSE(k)为循环工况中第k个采样点在预测时域内的均方根误差值, RMSE为整个循环工况的均方根误差值, N_c 为整个循环工况采样点个数, $V_c(k+i)$ 为循环工况中第k个采样点后第i个采样点的真实车速。

[0136] 在同一循环工况下,参与对比的预测方法有:保持预测,即预测车速保持不变;马尔科夫链预测,即全程基于马尔科夫链进行车速预测;神经网络预测,即全程基于径向神经网络进行车速预测;综合预测,即本发明提出的综合车速预测方法。仿真结果的对比如表3所示。

[0137] 表3不同预测方法结果比较

	预测方法	RMSE (km/h)	精度较基准提升
[0138]	保持预测	3.5789	---
	马尔科夫链预测	2.6761	25.22%
	神经网络预测	2.8334	20.83%
	综合预测	2.4435	31.72%

[0139] 由表中可以看出,作为基准的保持预测RMSE较高,预测精度较差,综合预测结合了马尔科夫链预测与神经网络预测的优点,其RMSE最小,预测精度最佳,较基准提升了31%左右。

[0140] 图8所示为部分循环工况中,综合预测与马尔科夫链预测和神经网络预测在每一采样时刻预测时域内未来第5秒的预测误差对比,图中左侧第一列为循环工况980s至1030s之间的预测,可以看出此时工况被判断为快变工况,综合预测采用神经网络预测,其结果明显优于马尔科夫链预测。图中第二列为循环工况600s至700s之间的预测,此时车速波动较小,工况判断为平稳工况,综合预测采用马尔科夫链预测,其结果也明显优于神经网络预测。

[0141] 图9所示为车速, EVT模式, 电池SOC的仿真结果, 由图中可以看出, 实际车速基本与目标车速相一致, 电池SOC能够维持在0.65附近波动, 说明了能量控制方法能够在首先满足驾驶员需求的情况下, 很好的维持住电池SOC, 并在一定程度上通过电能的消耗补充发动机

少提供的能量,以更好的调整发动机工作点。

[0142] 图10所示为该工况下发动机、电机A与电机B的转速和转矩,由图中可以看出,发动机转速波动较小,这是由于路面与发动机解耦,电机的调速性能又远优于发动机,使得车速的波动主要由两个电机的转速变化来弥补。而电机的转矩由于相对较小,所以由路面变化而引发的发动机转矩波动只能在一定程度上被电机所弥补。

[0143] 图11所示为该工况下发动机工作点分布图,可以看出,能量控制方法能够较好的调整发动机工作点,使得发动机在绝大多数情况下能够工作在最优燃油经济曲线附近,发动机工作效率较高,也就能够使得车辆经济性更优。

[0144] 为了进一步验证本发明提出的基于预测控制的能量控制方法对车辆性能的改善,在此将对多种能量控制方法在不同工况下的仿真试验结果,其中参与对比的策略有:预测控制,即本发明提出的能量控制方法;保持控制,即假设车速保持不变并采用预测控制的能量控制方法;动态规划,即假设工况已知,能够得到全局最优解;规则,即基于规则的能量控制方法,用于作为待提升的基准。对比结果如下:

[0145] 图12所示为发动机工作点分布的仿真结果对比,由图中可以看出,预测控制与保持控制所得到的结果与动态规划相似,而预测控制的发动机工作点分布相较于保持控制更为集中于高效区,而规则所得到的结果则较差,发动机则常工作在低效区。

[0146] 图13所示为电池SOC的仿真结果对比,由图中可以看出,预测控制与保持控制是一种实时优化,得到的是局部最优解,其结果与动态规划所得到的全局最优解类似,而规则的结果SOC过于稳定,与动态规划的结果差别很大,没有有效的通过电池SOC的波动调节发动机,控制效果较差。

[0147] 表4所示为不同能量控制方法在不同循环工况下的仿真结果对比。由于基于预测控制的能量控制方法是一种实时优化,无法确保循环工况终止时刻的电池SOC与初始时刻相同,所以为了公平的比较,需要同时考虑电能的消耗,这里依据能源价格将终止时刻电池SOC转化而得到等效燃油消耗,

$$[0148] \quad E_{c,s} = F_{c,s} - \varphi \cdot \Delta SOC_{c,s} \quad (30)$$

[0149] 式中, $E_{c,s}$, $F_{c,s}$ 和 $\Delta SOC_{c,s}$ 分别为对应循环工况和优化方法的等效燃油消耗,燃油消耗和电池SOC变化值, φ 为通过能源价格将电能转化为燃油的转化因子,当前柴油的价格为5.54元/升,电能的价格为0.9元/度。由表中可以看出,对于车辆经济性的改善,预测控制接近于动态规划,较规则有较大的提升,并优于保持控制,相较于基准有最大可达18%的提升。

[0150] 表4不同能量控制方法仿真结果对比

优化方法	终止时刻 SOC	等效燃油消耗率 (L/100km)	较基准的提升
循环工况 1			
预测控制	0.7028	21.64	12.68%
保持控制	0.6985	22.53	9.16%
动态规划	0.7091	20.61	16.82%
规则	0.6476	24.78	--
循环工况 2			
预测控制	0.6379	20.03	18.81%
保持控制	0.6291	21.39	13.36%
动态规划	0.6315	18.96	23.14%
规则	0.6519	24.67	--

[0151]

[0152] 通过对仿真结果的分析对比,验证了本发明的车速预测方法的有效性,精确度提升31%,同时也验证了基于预测控制能量控制方法的有效性,燃油经济性较规则的策略有18%的提升。

[0153] 当然,以上所述仅是本发明的一种实施方式而已,应当指出本技术领域的普通技术人员来说,在不脱离本发明原理的前提下,还可以做出若干改进和润饰,这些改进和润饰均属于本发明权利要求的保护范围之内。

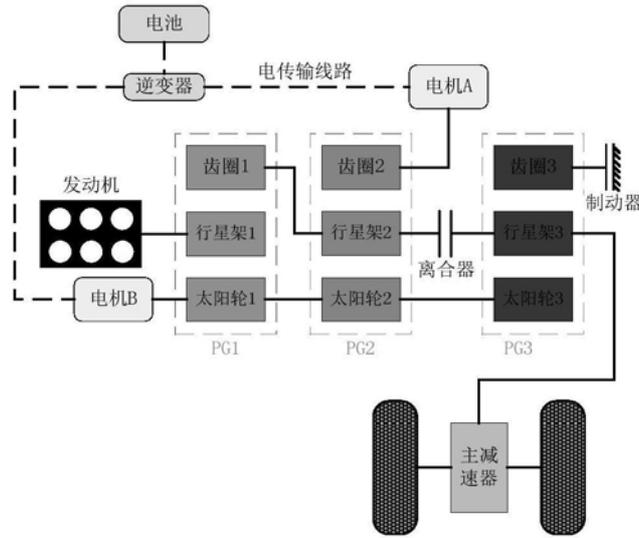


图1

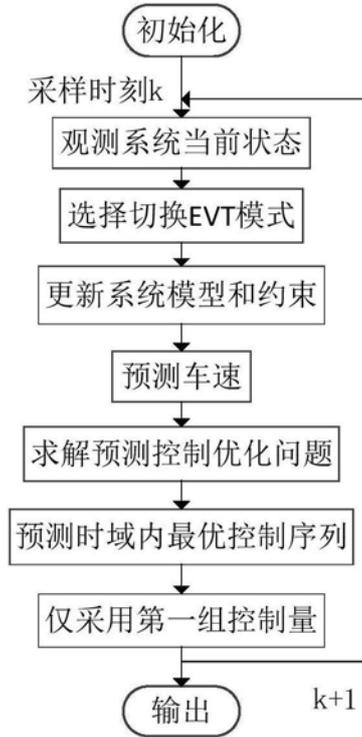


图2

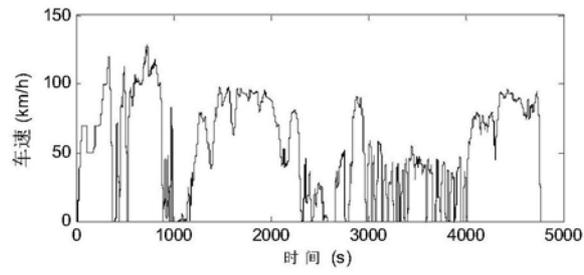


图3

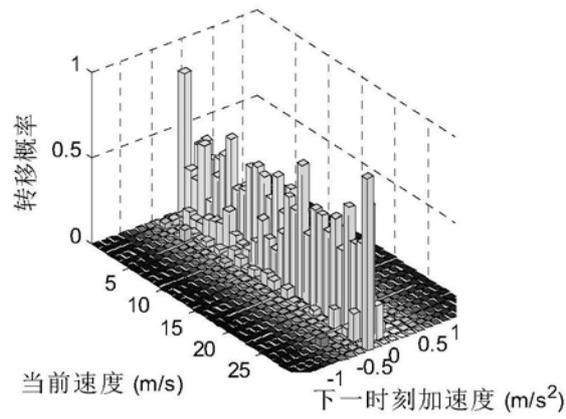


图4

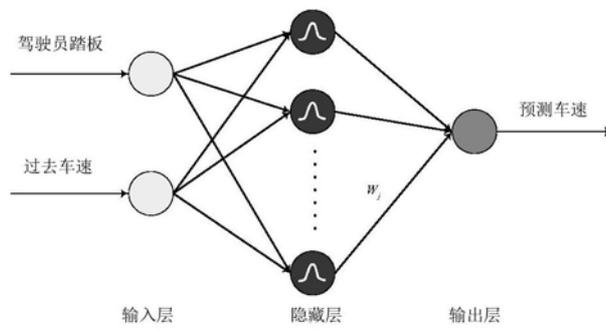


图5

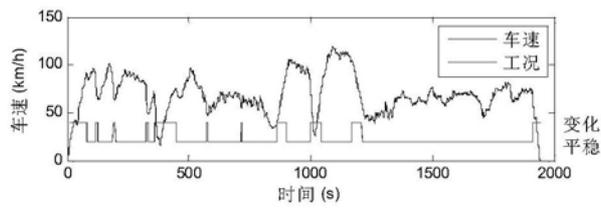


图6

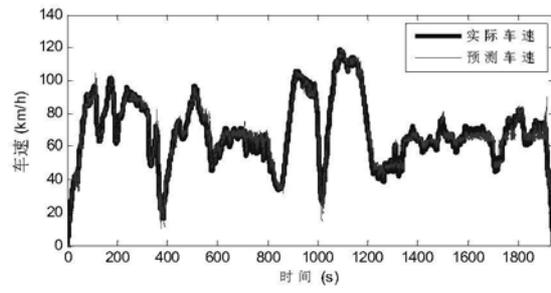


图7

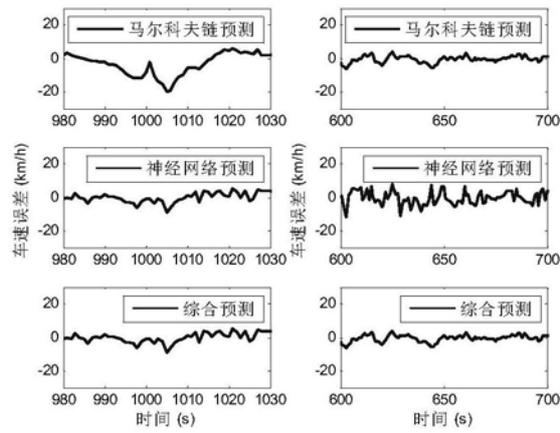


图8

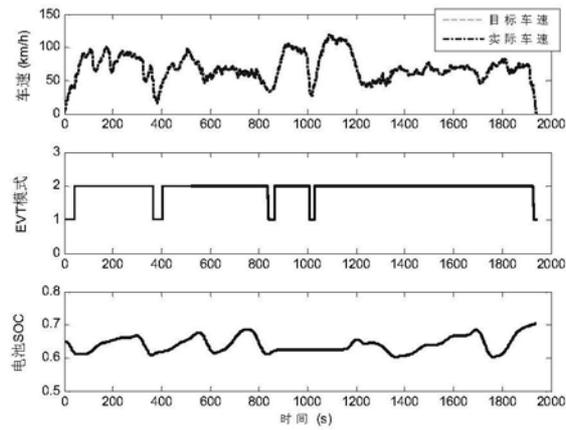


图9

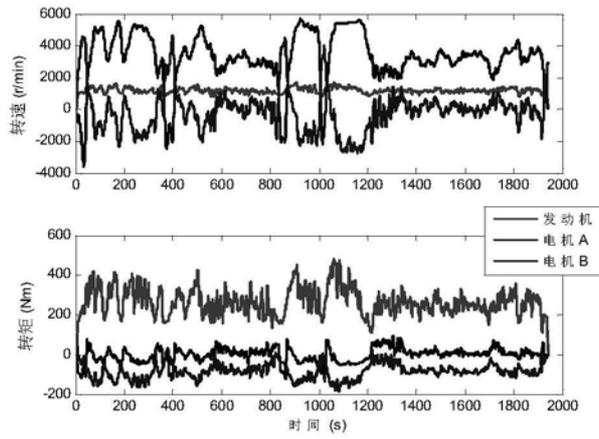


图10

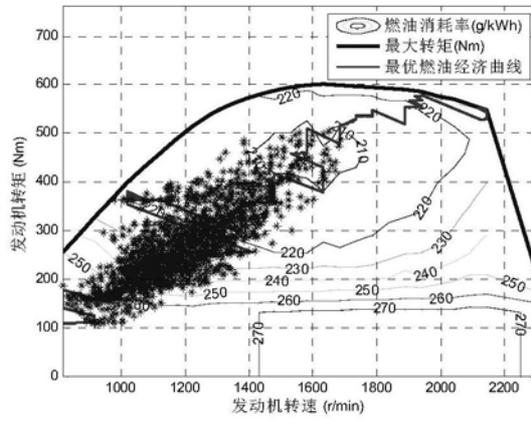


图11

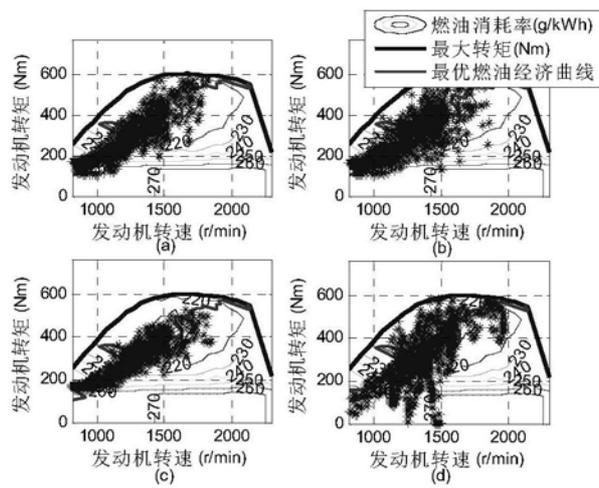


图12

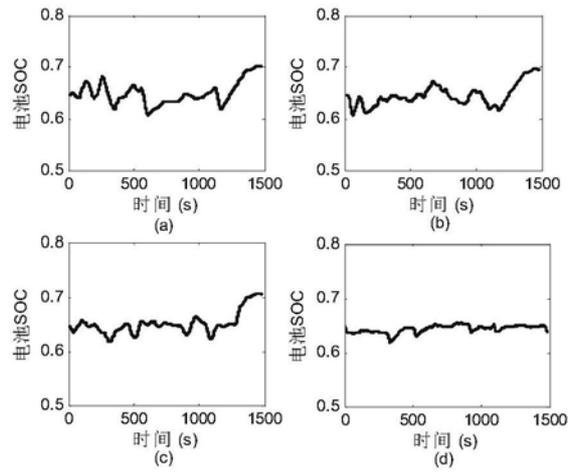


图13