

基于模糊神经网络优化扩展卡尔曼滤波的 锂离子电池荷电状态估计

商云龙, 张承慧[†], 崔纳新, 张 奇

(山东大学 控制科学与工程学院, 山东 济南 250061)

摘要: 电池荷电状态(state of charge, SOC)的精确估计是判断电池是否过充或过放的重要依据, 是电动汽车安全、可靠运行的重要保障. 传统基于扩展卡尔曼滤波(extended Kalman filter, EKF)的SOC估计方法过度依赖于精确的电池模型, 并且要求系统噪声必须服从高斯白噪声分布. 为解决上述问题, 基于模糊神经网络(fuzzy neural network, FNN)建立模型误差预测模型, 并藉此修正扩展卡尔曼滤波测量噪声协方差, 以实现当模型误差较小时对状态估计进行测量更新, 而当模型误差较大时只进行过程更新. 仿真和实验结果表明, 该算法能有效消除由于模型误差和测量噪声统计特性不确定而引入的SOC估计误差, 误差在1.2%以内, 并且具有较好的收敛性和鲁棒性, 适用于电动汽车的各种复杂工况, 应用价值较高.

关键词: 动力电池; SOC估计; 模型误差; 模糊神经网络; 扩展卡尔曼滤波

中图分类号: TM912 文献标识码: A

State of charge estimation for lithium-ion batteries based on extended Kalman filter optimized by fuzzy neural network

SHANG Yun-long, ZHANG Cheng-hui[†], CUI Na-xin, ZHANG Qi

(School of Control Science and Engineering, Shandong University, Jinan Shandong 250061, China)

Abstract: The accurate estimation for state of charge (SOC) is the important basis to prevent overcharge or overdischarge of batteries, and is the important guarantee for the electric vehicle safety and reliability. In the traditional SOC estimation methods based on extended Kalman filter (EKF), the SOC estimation precision was highly dependent on an accurate battery model. To solve the above problems, an error prediction model was built based on fuzzy neural network (FNN), by which the measurement noise covariance of EKF was real-time revised. When the predicted model error was small, the measurement model was updated, otherwise, the process model was updated only. The simulation and experimental results show that the proposed algorithm can effectively eliminate the SOC estimation error caused by the model error and the uncertain noise statistical properties, with the maximum error of less than 1.2%. The proposed algorithm has good convergence and robustness, and is applicable to various complicated driving cycles for electric vehicles, with high application value.

Key words: power battery; SOC estimation; model error; fuzzy neural networks; extended Kalman filters

1 引言(Introduction)

车载动力电池作为电动汽车的“心脏”, 其性能对整车的动力性、经济性和安全性至关重要, 是制约电动汽车规模发展的关键因素^[1-2]. 锂离子电池因具有能量密度高、使用寿命长、性价比好和单体电压高等优点, 被认为是最具希望的电动汽车动力电池^[3]. 为最大限度地发挥动力电池的性能并延长其使用寿命, 对其有效管理至关重要. 电池荷电状态 (state of charge, SOC)是判断电池是否过充过放, 是否需要均衡或更换某一电池单体的重要依据^[4-8], 是电池管理

最核心的技术之一. 与传统燃油汽车的剩余油量检测方法不同, 电池SOC无法使用一种传感器直接测量得到, 它必须通过对一些其他物理量的测量(如电池端电压、充放电电流、电池温度等)并采用相应的数学模型和估计算法估算得到. 然而, 锂离子动力电池内部的化学反应是一个对环境敏感且极其复杂的非线性变化过程, 其性能参数易受SOC、电流倍率、温度、老化程度及自放电等多个耦合因素的影响, 随机波动性强. 此外, 其建模问题涉及到材料、化学、热学、电学、机械、控制等多个学科, 横跨活性材料、电芯、电池组等

收稿日期: 2014-12-15; 录用日期: 2016-01-04.

[†]通信作者. E-mail: zchui@sdu.edu.cn; Tel.: +86 531-88395717.

本文责任编辑: 李少远.

国家自然科学基金项目(61527809, 61273097, 51277116, 61403162), 国家自然科学基金重大国际(地区)合作研究项目(61320106011)资助.

Supported by National Natural Science Foundation of China (61527809, 61273097, 51277116, 61403162) and Major International (Regional) Joint Research Project of the National Natural Science Foundation of China (61320106011).

宽广空间尺度, 以及稳态和暂态多时间尺度等. 显而易见, 动力电池SOC的准确估计具有很大的挑战性, 并已成为动力电池研究领域的一个热点问题.

如图1所示, 现有的电池SOC估计方法可以分为以下4大类: ① 基于安时计量的估计方法, 主要有放电实验法和Ah计量法^[3-6]; ② 基于电池表征参数测量值的估计方法, 主要有开路电压法^[3-5]和内阻法^[3,6-7]; ③ 基于经验方程和数学模型的估计方法, 主要有线性模型法^[3,6-7]、神经网络法^[8-11]、模糊逻辑法^[12]、支持向量机法^[13-14]和相关向量机法^[15]; ④ 基于电池等效电路模型的估计方法, 主要有扩展卡尔曼滤波(extended Kalman filter, EKF)法^[16-26]、观测器法^[27-30]和粒子滤波法^[31]. 其中, 近几年新兴的基于等效电路模型的估计方法因模型物理意义明确、参数辨识容易, 已成为电池研究的热点, 并取得了大量的研究成果. 特别是, EKF算法因适用于电动汽车电流波动比较剧烈的各种复杂工况, 备受国内外学者关注. 文献[16]和[17]分别提出了一种基于采样点卡尔曼滤波和有限差分扩展卡尔曼滤波的SOC估计方法, 解决了EKF在求取估计误差方差时将非线性函数用Taylor级数展开并忽略高阶项而引入线性化误差的问题; 文献[18]提

出了一种基于自适应无迹卡尔曼滤波的SOC估计算法, 通过在线估计未知噪声的均值和方差, 有效解决了算法对精确先验噪声信息过于依赖的问题. 文献和[20]分别考虑了温度和电池老化对电池模型参数的影响, 并建立了多个电池模型用于估计电池SOC. 总之, 上述方法主要是从3个方面改善SOC的估计精度: 1) 避免将非线性函数用Taylor级数展开, 消除因忽略高阶项而引入的线性化误差; 2) 采用自适应估计算法, 在线估计未知噪声的均值和方差, 以降低未知干扰噪声的影响; 3) 提高电池模型精度. 事实上, 影响EKF估计精度的主要因素是电池模型存在误差, 而锂离子电池是一个非常复杂的封闭电化学系统, 性能参数易受库伦效率、工作电流、温度和循环次数等诸多因素的影响, 且实际运行环境复杂多变, 导致建立的电池模型必然存在误差. 与其尽量建立其精确模型, 不如预测模型误差并对电池模型进行补偿, 以间接提高模型精度. 文献[24]和[25]将电池模型误差建立成SOC和电流的分段线性函数, 并根据计算的模型误差对EKF的测量噪声进行修正, 在一定程度上提高了SOC的估计精度, 但是建立的测量噪声修正模型是定性的, 需根据经验获得, 不具普适性.

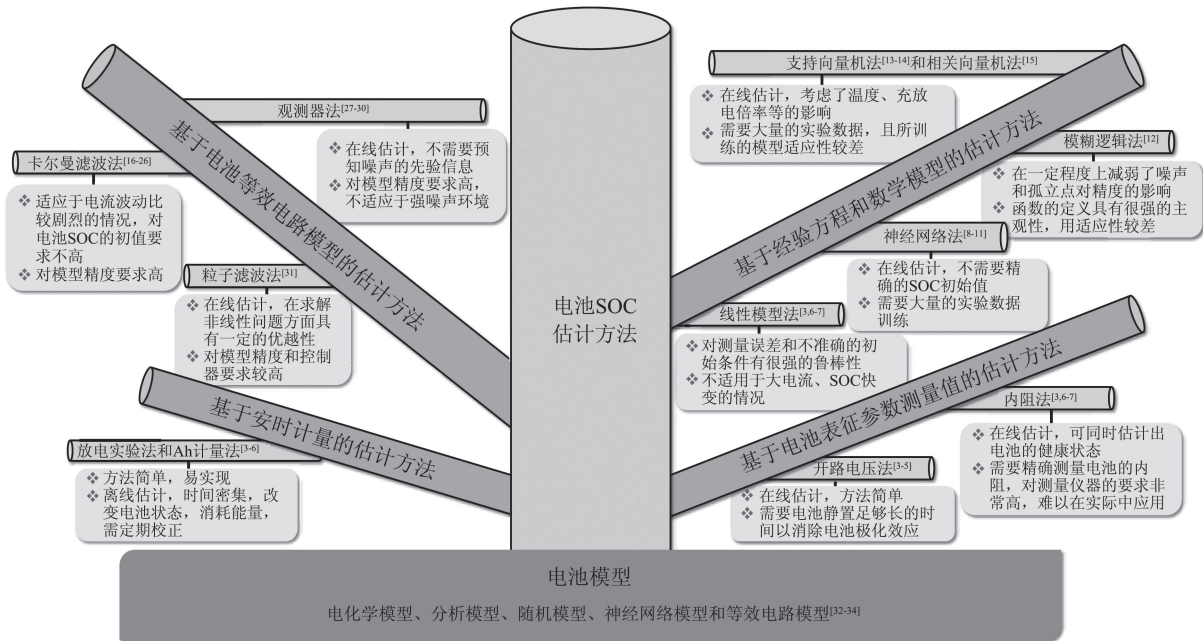


图 1 电池SOC估计方法概念树

Fig. 1 The conceptual tree of SOC estimation methods for batteries

为此, 本文提出了一种基于模糊神经网络(fuzzy neural network, FNN)优化EKF(FNN-EKF)的估计方法. 针对定结构电池模型不能很好地模拟锂离子电池两端陡中间平的非线性电压特性, 采用作者新近提出的基于AIC(Akaike information criterion, AIC)准则的变阶RC等效电路模型^[33], 有效解决了模型准确性和实用性之间的矛盾; 针对传统基

于EKF的SOC估计方法过度依赖于精确的电池模型, 并且要求系统噪声必须服从高斯白噪声分布的问题, 基于FNN建立了模型误差预测模型, 并藉此在滤波过程中对测量噪声协方差实时修正, 以实现当模型误差较小时对状态估计进行测量更新, 而当模型误差较大时, 只进行过程更新, 从而消除了由于较大模型误差而引进的SOC估计误差. 仿真与实

验结果验证了该方法的有效性.

2 基于AIC准则的变阶RC等效电路模型 (Variable-order RC equivalent circuit model based on the AIC criterion)

电动汽车动力电池SOC的精确估计依赖于一个精确且易实现的电池模型. 一般来说, 一个好的电池模型应具备以下两点: ①能够准确描述电池的动、静态特性; ②模型本身的复杂度较低, 易于工程实现^[32-34]. 事实上, 锂离子电池具有两端陡中间平的非线性电压特性, 采用3阶的电池模型虽然能够获得较高的精度, 但是模型过于复杂, 实用性较差; 而采用2阶的电池模型会造成重要数据丢失, 特别是在电池充放电的初期和末期不能很好地拟合电池特性, 模型精度较低. 显而易见, 用传统定阶的电池模型难以解决模型准确性和实用性之间矛盾. 因此, 本文采用了作者新近提出的变阶RC等效电路模

型^[33].

如图2所示为变阶RC模型的结构图, 包括运行时间电路和I-V特性电路两部分. 模型的两条支路中: 下标d表示放电, c表示充电; U_{bat} 为电池的端电压; i_{bat} 为电池的端电流; R_d 表示电池的自放电电阻; C_Q 表示电池的可用容量; R_o 为欧姆内阻; R_1 为电化学极化内阻; C_1 为电化学极化电容; R_2 为浓差极化内阻; C_2 为浓差极化电容; R_3 为变阶内阻; C_3 为变阶电容; Q_1, S_1, Q_2, S_2 为变阶RC模型的切换开关, 通过其开关状态可实现1阶、2阶和3阶RC模型的按需切换; OCV为电池的开路电压, 是SOC的函数, 可表述为:

$$\text{OCV} = a_1 + a_2 \ln \text{SOC} + a_3 \ln(1 - \text{SOC}) + \frac{a_4}{\text{SOC}} + a_5 \text{SOC}, \quad (1)$$

式中 a_1 - a_5 为待定常数, 可根据实验数据基于最小二乘法辨识得到.

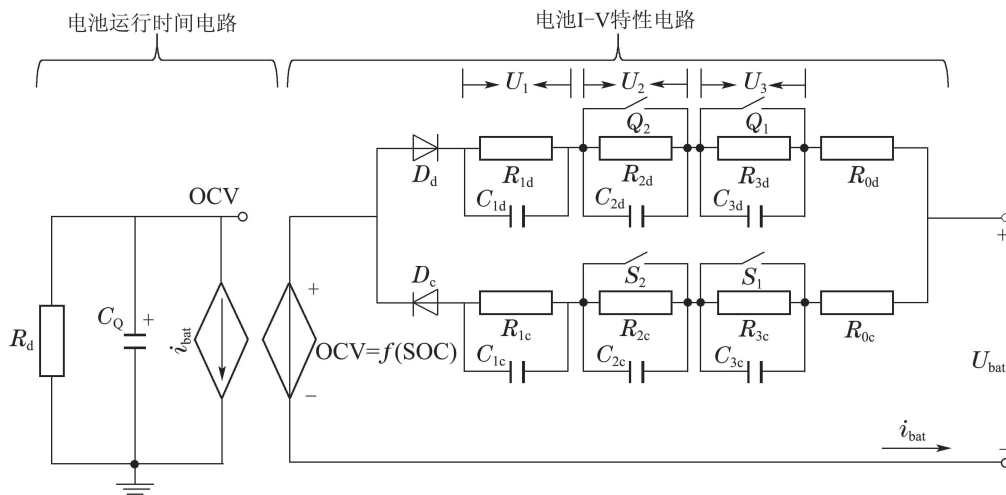


图2 变阶RC等效电路模型

Fig. 2 The variable-order RC equivalent circuit model

由于电池实际系统的阶数是未知的, 如何在不同SOC处确定一个最优的RC模型阶数, 能够同时兼顾模型的准确性和简便性, 是变阶RC模型的一个难点. AIC因同时兼顾了模型的精度和实用性, 成为衡量模型优良性的一种有效方法.

AIC的一般形式可表述为^[35-36]

$$\text{AIC} = \ln \frac{\text{SSE}}{T} + \frac{2m}{T}, \quad (2)$$

式中: T 为实验数据个数; m 为模型未知参数个数. SSE为残差平方和, 本文中可表述为^[35-36]

$$\text{SSE} = \sum_{t=1}^T [U_{\text{bat}}(t) - \text{OCV} + \sum_{i=1}^n (R_i i_{\text{bat}} e^{-\frac{t}{\tau_i}})]^2, \quad (3)$$

式中: $U_{\text{bat}}(t)$ 为实验中获得的电池端电压; 下标 i 为RC网络标号, 其值为1, 2或3; τ_i 为第 i 个RC网络的时间常数, 即 $\tau_i = R_i C_i$; R_i 为第 i 个RC网络中并联的电阻; n 为RC网络的阶数, 其值为1, 2或3; t 为采样时刻. 式(2)中, $\ln \frac{\text{SSE}}{T}$ 表示模型拟合的优良性, 其值越小表示模型越精确; $\frac{2m}{T}$ 表示对模型过拟合的惩罚, 其值越小表示模型越简洁. 显而易见, 当模型变得更加复杂时, $\ln \frac{\text{SSE}}{T}$ 将变得更小, 但 $\frac{2m}{T}$ 由于模型参数的增加将变得更大. AIC鼓励数据拟合的优良性, 但是尽量避免出现过度拟合的情况. 所以, 最佳模型应是AIC值最小的那一个.

当实验数据个数 T 较大时, 对模型过拟合的惩罚

力度将变小. 因此, 为了在大实验数据下也能保证模型准确性和简便性的平衡, 将AIC准则改进为^[33]

$$\text{AIC} = \ln \frac{\text{SSE}}{T} + \frac{2m^d}{T}, \quad (4)$$

式中指数 d 的引进增加了对模型过拟合的惩罚力度, 其为大于1的恒值, 本文取 $d = 4$.

如图2所示电池模型, 一阶RC模型需要辨识的未知参数分别有开路电压OCV、极化内阻 R_1 和极化电容 C_1 , 为3个未知参数, 并且模型每增加一阶, 就会增加极化内阻和极化电容两个未知参数. 因此, 未知参数 m 与模型阶数 n 之间的关系可表述为

$$m = 2n + 1. \quad (5)$$

将式(3)和(5)代入式(4), 可得到RC阶数选择的AIC准则

$$\text{AIC} = \ln \frac{\sum_{t=1}^T [U_{\text{bat}}(t) - \text{OCV} + \sum_{i=1}^n (R_i i_{\text{bat}} e^{-\frac{t}{\tau_i}})]^2}{T} + \frac{2(2n+1)^d}{T}. \quad (6)$$

基于AIC辨识不同SOC处的最优模型阶数, 兼顾了模型的准确性和简便性, 特别适用于锂离子电池两端陡中间平的非线性电压特性^[33], 为SOC的精确估计提供了一个精确且易实现的电池模型.

3 基于模糊神经网络优化EKF(FNN-EKF)的SOC估计(SOC estimation based on EKF optimized by fuzzy neural network)

EKF是一种高效率的递归滤波器, 它能够通过对观测量的更新, 获得对系统状态的估计. 但是, EKF必须应用在噪声服从高斯分布的系统中并且对系统的模型精度要求很高. 事实上, 电池的系统噪声并不满足高斯分布并且所建立的电池模型也不可避免地存在误差. 尤其是, 当模型误差较大和测量噪声协方差为常值时, 会通过测量更新对状态估计引入较大的估计误差. 为了解决这一问题, 本节建立了基于模糊神经网络的模型误差预测模型; 并藉此在滤波过程中对测量噪声协方差实时修正, 以实现当模型误差较小时才对状态估计进行测量更新, 而当模型误差较大时, 只进行过程更新的目的. 式(7)–(20)中, k 为采样时刻; “ $-$ ”代表先验; “ \wedge ”代表估计.

文献[16–26]通常将电池SOC和模型中电容电压作为状态变量, 但是由于电池模型中的参数均是SOC的函数, 对于同一个模型输出值可能存在多个SOC解, 有可能导致SOC估计偏离真值. 而在电池静置足够长的时间后, 电池模型中的电容电压初始

值为0, 可通过下式递推计算得到

$$U_{R_i C_i, k} = \exp(-\Delta t / \tau_i) U_{R_i C_i, k-1} + R_i (1 - \exp(-\Delta t / \tau_i)) i_{\text{bat}, k}, \quad (7)$$

式中 Δt 为采样周期, 且 $\Delta t = 1$ s; $i_{\text{bat}, k}$ 为第 k 步的电流值, 充电时 $i_{\text{bat}, k} > 0$, 放电时 $i_{\text{bat}, k} < 0$; $U_{R_i C_i, k-1}$ 为第 i 个RC网络的第 $k-1$ 步电容两端电压.

因此, 可将SOC作为唯一状态变量, 其状态方程为

$$\text{SOC}_k = f(\text{SOC}_{k-1}, i_{\text{bat}, k-1}) = \text{SOC}_{k-1} + \frac{\eta \Delta t}{C} i_{\text{bat}, k-1} + w_k, \quad (8)$$

式中: η 为库仑系数, 可通过电池充放电实验得到; 电池充电时, $\eta = 1$; 放电时, $\eta < 1$; C 为电池标称容量, 单位为A·s; 随机信号 w_k 为过程激励噪声, 服从正态分布:

$$p(w_k) \sim N(0, Q), \quad (9)$$

式中 Q 为过程噪声协方差, 为一常数.

由图2所示, 模型的观测方程可表述为

$$U_{\text{bat}, k} = h(\text{SOC}_k, i_{\text{bat}, k}) = \text{OCV}(\text{SOC}_k) + i_{\text{bat}, k} R_o + \sum_{i=1}^n U_{R_i C_i, k} + v_k, \quad (10)$$

式中: n 为变阶RC模型的阶数, 是SOC的函数; v_k 为测量噪声.

定义

$$\begin{cases} x_k = \text{SOC}_k, \\ u_k = i_{\text{bat}, k}, \\ A_k = \frac{\partial f}{\partial x}(\hat{x}_{k-1}, u_{k-1}) = 1, \\ B_k = \frac{\partial f}{\partial u}(\hat{x}_{k-1}, u_{k-1}) = \frac{\eta \Delta t}{C}, \\ H_k = \frac{\partial h}{\partial x}(\hat{x}_k^-, u_k) = \frac{a_2}{\text{SOC}_k^-} - \frac{a_3}{1 - \text{SOC}_k^-} - \frac{a_4}{(\text{SOC}_k^-)^2} + a_5, \end{cases} \quad (11)$$

式中: x_k 是状态变量; u_k 为输入变量; A 是 f 对 x 的偏导的雅可比矩阵; B 是 f 对 u 的偏导的雅可比矩阵; H 是 h 对 x 的偏导的雅可比矩阵.

FNN-EKF滤波算法的循环递推计算如下:

第1步 初始化.

滤波器状态和误差协方差初始化:

$$\begin{cases} \hat{x}_0 = E(x_0), \\ P_0 = E[(x_0 - \hat{x}_0)(x_0 - \hat{x}_0)^T], \end{cases} \quad (12)$$

式中: x_0 为状态真值的初值; \hat{x}_0 为状态估计值的初值; P_0 为误差协方差矩阵初值.

第2步 过程更新(预测).

$$\hat{x}_k^- = A_k \hat{x}_{k-1} + B_k u_{k-1} + w_k, \quad (13)$$

式中: \hat{x}_k^- 为在已知第 k 步以前状态条件下第 k 步的先验状态估计; \hat{x}_{k-1} 为第 $k-1$ 步的后验状态估计.

误差协方差更新可表述为

$$P_k^- = A_k P_{k-1} A_k^T + w_k Q w_k^T, \quad (14)$$

式中 P_k^- 为第 k 步的误差协方差矩阵先验值.

第3步 测量噪声协方差 R_k 修正.

由于电池端电压及端电流不可避免地存在测量误差, 加之所建立的模型也不可能完全准确地描述复杂的电池动态系统. 因此, 需要建立电池模型误差预测模型并藉此修正EKF测量噪声协方差. 图3给出了基于BP神经网络的模型误差预测结果, 其中电池端电压和电流为输入, 电池模型误差为输出. 可见, 模型误差与电池端电压和电流的关系极为复杂, 直接建立其关系精度很低. 事实上, 对EKF测量噪声协方差修正并不需要精确预测模型误差, 只需预测模型误差大或小即可. 为此, 首先将模型误差模糊化为0和1的开关变量, 即当模型误差大于等于0.001 V时, 记为1; 当模型误差小于0.001 V时, 记为0. 把电池端电压和电流作为输入, 模糊化的模型误差作为输出, 建立基于模糊神经网络的模型误差预测模型

$$\text{Flag}_k = g(U_{\text{bat},k}, i_{\text{bat},k}), \quad (15)$$

式中: $U_{\text{bat},k}$ 和 $i_{\text{bat},k}$ 分别为第 k 步电池端电压和电流的测量值; 非线性函数 g 为神经网络函数; Flag_k 为第 k 步基于模糊神经网络预测的模糊化模型误差, 其值在0和1之间. 图4给出了基于模糊神经网络的模型误差预测结果. 以0.5为分界线, 当 $0.5 \leq \text{Flag}_k \leq 1$ 时, 认为模型误差较大; 而当 $0 \leq \text{Flag}_k < 0.5$ 时, 认为模型误差较小.




图3 UDDS循环工况下模型误差及基于BP神经网络的模型误差预测结果

Fig. 3 Model errors and their prediction values based on BP neural networks under UDDS test cycles




图4 UDDS循环工况下模型误差及基于模糊神经网络的模型误差预测结果

Fig. 4 Model errors and their prediction values based on FNN under UDDS test cycles

如式(17)所示, 测量噪声协方差 R_k 是计算增益矩阵 K_k 的一个重要变量. R_k 越小, 残余的增益 K_k 就越大, 对滤波状态的修正作用就越大, 这时状态估计主要依赖于测量更新; 当 R_k 越大时, 残余的增益 K_k 就越小, 对滤波状态的修正作用就越小, 这时状态估计主要依赖于过程更新. 因此, 当预测的模型误差较大时, 即 $0.5 \leq \text{Flag}_k \leq 1$, 可令 R_k 等于一个无穷大值, K_k 接近于0, 测量更新不起作用, 这时状态估计主要取决于过程更新, 从而避免了由于较大模型误差而引入的状态估计误差; 当预测模型误差较小时即 $0 \leq \text{Flag}_k < 0.5$, 令 R_k 等于一个较小的值(本文为1), 这时状态估计主要取决于测量更新, 实现了对状态估计的校正, 从而提高了估计精度和收敛速度. 综上所述, 测量噪声修正模型可表述为

$$R_k = \begin{cases} 1, & 0 \leq \text{Flag}_k < 0.5, \\ \infty, & 0.5 \leq \text{Flag}_k \leq 1. \end{cases} \quad (16)$$

第4步 计算滤波增益矩阵.

经滤波增益系数优化后的滤波增益矩阵可表述为

$$K'_k = \Gamma K_k = \Gamma P_k^- H_k^T [H_k P_k^- H_k^T + v_k R_k v_k^T]^{-1}, \quad (17)$$

式中: Γ 为滤波增益系数; v_k 服从协方差为变值 (R_k) 的正态分布:

$$p(v_k) \sim N(0, R_k). \quad (18)$$

第5步 测量更新(校正).

$$\hat{x}_k = \hat{x}_k^- + K'_k [y_k - h(\hat{x}_k^-, u_k)], \quad (19)$$

式中: \hat{x}_k 为已知电池端电压的测量真值 y_k 时, 第 k 步的后验状态估计.

误差协方差测量更新:

$$P_k = (1 - K'_k H_k) P_k^-, \quad (20)$$

式中 P_k 为误差协方差矩阵第 k 步的估计值。

图5直观地给出了基于模糊神经网络优化EKF的SOC估计流程图. 其滤波过程本质上是基于小模型误差准则的EKF估计. 原理是通过模糊神经网络预测的模型误差对测量噪声协方差 R_k 实时修正从而实现: 当预测的模型误差较小时, 令 R_k 取一个较小值, 从而实现测量更新, 以保证算法的收敛速度; 当预测的模型误差较大时, 令 R_k 为无穷大, 这时只进行过程更新, 克服了由于较大模型误差和测量噪声不确定性而引入的状态估计误差, 从而提高了算法的估计精度.

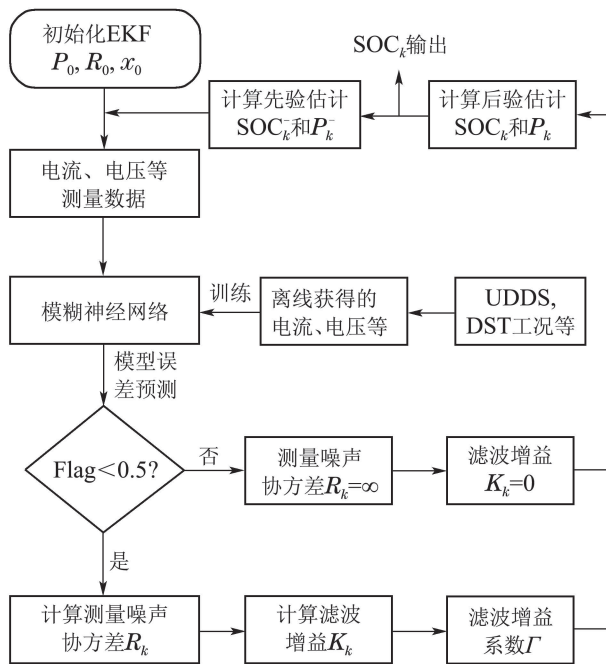


图 5 基于FNN-EKF的SOC估计算法流程图

Fig. 5 Flow chart of SOC estimation algorithm based on FNN-EKF

4 仿真及实验验证 (Simulation and experimental verification)

本文研究对象为16并16串圆柱型26650磷酸铁锂动力电池组, 标称容量为50 Ah, 标称电压为51.2 V. 电池测试平台由AVL电池模拟/测试柜、AVL控制柜、温控箱以及AVL Lynx软件组成. 实验记录电池的端电压、电流和SOC真值(Ah积分法得到)等工况值, 记录频率为1 Hz.

图6给出了UDDS循环工况下基于EKF的单一状态变量与传统多状态变量的SOC估计结果. 为了消除由于建模误差而引入的SOC估计误差的影响, 观测值均使用模型仿真值. EKF的初始参数设置为: SOC真值初始值 $SOC_{t_0} = 90\%$, SOC估计初始值 $SOC_{e_0} = 80\%$, 协方差矩阵 $P_0 = 1$, 过程激励噪声

协方差 $Q = 0.05$, 测量噪声协方差初值 $R_0 = 1$, 滤波增益系数 $\Gamma = 0.8$. 从图6中可以看出, 单一状态变量的SOC估计值很快收敛到真值附近, 并且之后与真值完全重合, 具有很高的估计精度; 而多状态变量的SOC估计结果不能收敛到真值, 一直存在较大的误差. 可见, 基于单一状态变量的SOC估计算法更为有效.





图 6 UDDS循环工况下单一状态变量和多状态变量的SOC估计结果对比

Fig. 6 An SOC estimation result comparison between a single state variable and the multi-state variables under UDDS test cycles

图7给出了UDDS循环工况下基于各种建模误差补偿EKF的SOC估计结果. 其中EKF的初始参数设置为:

$$SOC_{t_0} = 90\%, SOC_{e_0} = 90\%, P_0 = 1, Q = 0.05, R_0 = 1, \Gamma = 0.05.$$

如图7(a)所示为基于传统EKF的SOC估计结果; 图7(b)为基于 ± 0.01 V 固定误差补偿EKF的SOC估计结果; 图7(c)为基于BP神经网络优化EKF的SOC估计结果, 其工作原理是基于BP神经网络预测模型误差, 并与0.001 V比较, 当大于0.001 V时EKF不进行测量更新, 小于0.001 V时EKF可进行测量更新; 图7(d)为基于FNN-EKF的SOC估计结果.



(a) 基于传统EKF的SOC估计结果

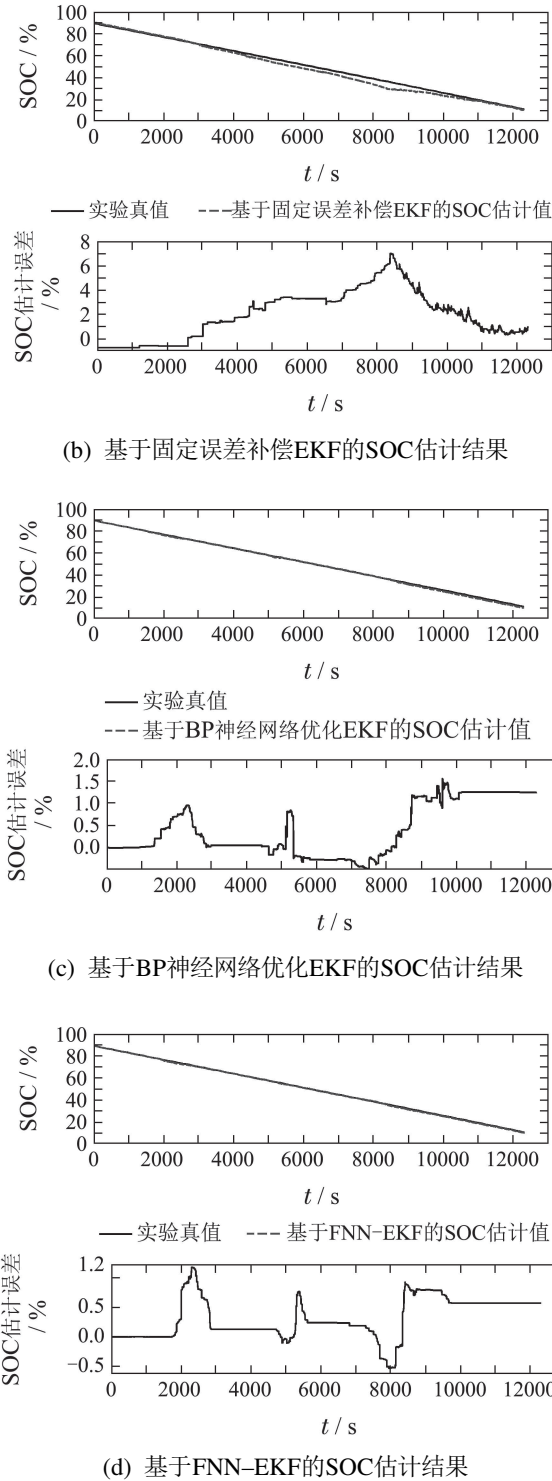


图7 UDDS循环工况下基于不同方法优化EKF的SOC估计结果比较

Fig. 7 SOC estimation result comparisons based on EKF algorithms optimized by different methods under UDDS test cycles

表1总结了UDDS循环工况下基于各种建模误差补偿EKF的SOC估计结果. 通过对比可知, 基于FNN-EKF的SOC估计方法, 最大估计误差小于1.2%, 无论在估计精度还是在收敛速度方面均优于其他几种估计方法. 为了进一步验证FNN-EKF算

法的优越性, 图8给出了脉冲放电下基于各种建模误差补偿EKF的SOC估计对比结果.

图9分别给出了UDDS循环工况和脉冲放电工况下滤波增益系数对FNN-EKF算法收敛速度的影响结果. 其初始参数设置为 $SOC_{t_0} = 90\%$, 图9(a)-(b)中的 SOC_{e0} 分别为85%和80%, $P_0 = 1, Q = 0.05, R_0 = 1$. 实验结果表明, 滤波增益系数越大, 收敛速度越快, 但是当负载变化较大时, 会引起SOC估计波动较大, 导致估计误差增大; 滤波增益系数越小, 估计稳定精度较高, 但是收敛速度较慢. 由图9可知, 本文滤波增益系数在0.05~0.1之间取值较为合适.

表1 UDDS循环工况下基于不同方法优化EKF的SOC估计结果

Table 1 SOC estimation results based on EKF algorithms optimized by different methods under UDDS test cycles

	传统EKF	±0.01V固定误差补偿EKF	BP神经网络优化EKF	FNN-EKF
标准差	$4.170e^{-4}$	$3.908e^{-4}$	$3.630e^{-5}$	$1.139e^{-5}$
最大误差	7%	7%	1.6%	1.2%

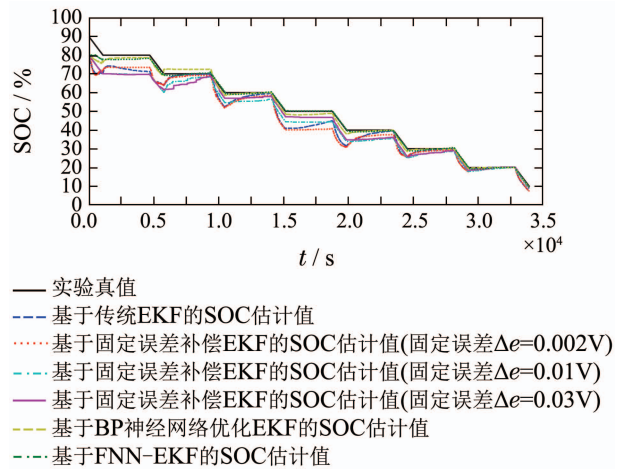




图8 脉冲放电工况下基于不同方法优化EKF的SOC估计结果比较

Fig. 8 SOC estimation result comparisons based on EKF algorithms optimized by different methods under pulse discharge test cycle



(a) UDDS循环工况



(b) 脉冲放电工况

图9 不同工况下滤波增益系数对FNN-EKF算法收敛速度的影响

Fig. 9 The influence of the filter gain coefficient on the convergence rate of FNN-EKF algorithm under different test cycles

图10给出了FNN-EKF算法的鲁棒性测试结果. 其初始参数设置为 $SOC_{t_0} = 90\%$, $P_0 = 1$, $Q = 0.05$, $R_0 = 1$, $\Gamma = 0.05$. ΔSOC_0 为真值与估计值的初始差值. 实验结果表明, 估计值在初始SOC有较大误差的情况下能迅速向真值逼近, 之后SOC估计值在SOC真值附近微小波动, 证明了本文提出的FNN-EKF算法具有较好的鲁棒性.




图10 UDDS循环工况下FNN-EKF算法的鲁棒性

Fig. 10 The robustness of FNN-EKF algorithm under UDDS test cycles

5 结论(Conclusions)

本文提出了一种基于模糊神经网络优化EKF的估计方法. 一方面, 针对锂离子电池两端陡中间平的非线性电压特性, 采用作者新近提出的变阶RC等效电路模型, 有效解决了模型准确性和实用性之间的矛盾; 另一方面, 基于模糊神经网络建立了模型误差预测模型, 并藉此在滤波过程中对测量噪声协方差实时修正, 从而克服了由于较大模型误差和将系统噪声假设为高斯白噪声而引入的状态估计误差. 在自定义UDDS循环工况和脉冲放电工况下, 通过基于各种建模误差补偿EKF的SOC估计结果对比, 证明了FNN-EKF算法的优越性, 最大估计误差在1.2%以内, 具有较高的工程应用价值. 该算法目前在实验室AVL开发平台上运行效果良好, 下一步将应用到车载电池管理系统中.

参考文献(References):

- [1] SHANG Y L, ZHANG C H, CUI N X, et al. A cell-to-cell battery equalizer with zero-current switching and zero-voltage gap based on quasi-resonant LC converter and boost converter [J]. *IEEE Transactions on Power Electronics*, 2015, 30(7): 3731 – 3741.
- [2] 陈清泉, 孙逢春, 祝嘉光. 现代电动汽车技术 [M]. 北京: 北京理工大学出版社, 2002: 289 – 296.
- [3] PILLER S, PERRIN M, JOSSEN A. Methods for state-of-charge determination and their applications [J]. *Journal of Power Sources*, 2001, 96(1): 113 – 120.
- [4] MA Youliang, CHEN Quanshi, QI Zhanning. Research on the SOC definition and measurement method of batteries used in EVs [J]. *Journal of Tsinghua University (Sci & Tech)*, 2001, 41(11): 95 – 97, 105. (麻友良, 陈全世, 齐占宁. 电动汽车用电池SOC定义与检测方法 [J]. 清华大学学报(自然科学版), 2001, 41(11): 95 – 97+105.)
- [5] MA Youliang, CHEN Quanshi, ZHU Yuan. Research on the definition of SOC of batteries in the condition of changing currents [J]. *Battery Bimonthly*, 2001, 31(1): 7 – 9. (麻友良, 陈全世, 朱元. 变电流下的电池荷电状态定义方法探讨 [J]. 电池, 2001, 31(1): 7 – 9.)
- [6] LIN Chengtao, WANG Junping, CHEN Quanshi. Methods for state of charge estimation of EV batteries and their application [J]. *Battery Bimonthly*, 2004, 34(5): 376 – 378. (林成涛, 王军平, 陈全世. 电动汽车SOC估计方法原理与应用 [J]. 电池, 2004, 34(5): 376 – 378.)
- [7] LIN Chengtao, CHEN Quanshi, WANG Junping, et al. Improved ah counting method for state of charge estimation of electric vehicle batteries [J]. *Journal of Tsinghua University (Science and Technology)*, 2006, 46(2): 247 – 251. (林成涛, 陈全世, 王军平, 等. 用改进的安时计量法估计电动汽车动力电池SOC [J]. 清华大学学报(自然科学版), 2006, 46(2): 247 – 251.)
- [8] CHEN Hong, GONG Xun, HU Yunfeng, et al. Automotive control: the state of the art and perspective [J]. *Acta Automatica Sinica*, 2013, 39(4): 322 – 346. (陈虹, 宫训, 胡云峰, 等. 汽车控制的研究现状与展望 [J]. 自动化学报, 2013, 39(4): 322 – 346.)
- [9] LEI Xiao, CHEN Qingquan, LIU Kaipei, et al. Battery state of charge estimation based on neural-network for electric vehicles [J]. *Transactions of China Electrotechnical Society*, 2007, 22(8): 155 – 160. (雷肖, 陈清泉, 刘开培, 等. 电动车蓄电池荷电状态估计的神经网络方法 [J]. 电工技术学报, 2007, 22(8): 155 – 160.)
- [10] LEI Xiao, CHEN Qingquan, LIU Kaipei, et al. Radial-based-function neural network based SOC estimation for electric vehicles [J]. *Transactions of China Electrotechnical Society*, 2008, 23(5): 81 – 87. (雷肖, 陈清泉, 刘开培, 等. 电动车电池SOC估计的径向基函数神经网络方法 [J]. 电工技术学报, 2008, 23(5): 81 – 87.)
- [11] WEIGERT T, TIAN Q, LIAN K. State-of-charge prediction of batteries and battery – supercapacitor hybrids using artificial neural networks [J]. *Journal of Power Sources*, 2011, 196(8): 4061 – 4066.
- [12] SALKIND A J, FENNIE C, SINGH P, et al. Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology [J]. *Journal of Power Sources*, 1999, 80(1): 293 – 300.
- [13] HANSEN T, WANG C J. Support vector based battery state of charge estimator [J]. *Journal of Power Sources*, 2005, 141(2): 351 – 358.
- [14] LEI Xiao, CHEN Qingquan, LIU Kaipei, et al. Support vector machine based SOC estimation for electric vehicles [J]. *Transactions of China Electrotechnical Society*, 2008, 28(18): 114 – 118. (雷肖, 陈清泉, 刘开培, 等. 电动车蓄电池荷电状态估计的支持向量机方法 [J]. 中国电机工程学报, 2008, 28(18): 114 – 118.)
- [15] GAO Xiangyang, ZHANG Jun, NING Ning. SOC prediction for battery based on relevance vector machine [J]. *Chinese Journal of Power Sources*, 2010, 34(12): 1273 – 1275.

- (高向阳, 张骏, 宁宁. 基于相关向量机的蓄电池荷电状态预测 [J]. 电源技术, 2010, 34(12): 1273 – 1275.)
- [16] GAO Mingyu, HE Zhiwei, XU Jie. Sigma point Kalman filter based SOC estimation for power supply battery [J]. *Transactions of China Electrotechnical Society*, 2011, 26(11): 161 – 167.
(高明煜, 何志伟, 徐杰. 基于采样点卡尔曼滤波的动力电池SOC估计 [J]. 电工技术学报, 2011, 26(11): 161 – 167.)
- [17] LIU Yanli, DAI Sheng, CHENG Ze, et al. Estimation of state of charge of lithium-ion battery based on finite difference extended Kalman filter [J]. *Transactions of China Electrotechnical Society*, 2014, 1(29): 221 – 228.
(刘艳莉, 戴胜, 程泽, 等. 基于有限差分扩展卡尔曼滤波的锂离子电池SOC估计 [J]. 电工技术学报, 2014, 1(29): 221 – 228.)
- [18] WEI Kexin, CHEN Qiaoyan. States estimation of li-ion power batteries based on adaptive unscented Kalman filters [J]. *Proceedings of the CSEE*, 2014, 34(3): 445 – 452.
(魏克新, 陈峭岩. 基于自适应无迹卡尔曼滤波算法的锂离子动力电池状态估计 [J]. 中国电机工程学报, 2014, 34(3): 445 – 452.)
- [19] XU Ying, SHEN Ying. Improved battery state-of-charge estimation based on Kalman filter [J]. *Journal of Beijing University of Aeronautics Astronautics*, 2014, 6(40): 855 – 860.
(徐颖, 沈英. 基于改进卡尔曼滤波的电池SOC估算 [J]. 北京航空航天大学学报, 2014, 6(40): 855 – 860.)
- [20] WEI Kexin, CHEN Qiaoyan. Electric vehicle battery SOC estimation based on multiple-model adaptive Kalman filter [J]. *Proceedings of the CSEE*, 2012, 32(31): 19 – 26, 214
(魏克新, 陈峭岩. 基于多模型自适应卡尔曼滤波器的电动汽车电池荷电状态估计 [J]. 中国电机工程学报, 2012, 32(31): 19 – 26, 214.)
- [21] YUAN S, WU H, YIN C. State of charge estimation using the extended Kalman filter for battery management systems based on the ARX battery model [J]. *Energies*, 2013, 6(1): 444 – 470.
- [22] HAN J, KIM D, SUNWOO M. State-of-charge estimation of lead-acid batteries using an adaptive extended Kalman filter [J]. *Journal of Power Sources*, 2009, 188(2): 606 – 612.
- [23] HE H, XIONG R, ZHANG X, et al. State-of-charge estimation of the lithium-ion battery using an adaptive extended Kalman filter based on an improved Thevenin model [J]. *IEEE Transactions on Vehicular Technology*, 2011, 60(4): 1461 – 1469.
- [24] ZHANG Di. Electric vehicle battery state-of-charge estimation based on adaptive Kalman filtering [D]. *Changchun: JinLin University*, 2012.
(张颀. 基于自适应卡尔曼滤波的电动汽车动力电池SOC估计 [D]. 长春: 吉林大学, 2012.)
- [25] LEE J, NAM O, CHO B H. Li-ion battery SOC estimation method based on the reduced order extended Kalman filtering [J]. *Journal of Power Sources*, 2007, 174(1): 9 – 15.
- [26] LEE S, KIM J, LEE J, et al. State-of-charge and capacity estimation of lithium-ion battery using a new open-circuit voltage versus state-of-charge [J]. *Journal of Power Sources*, 2008, 185(2): 1367 – 1373.
- [27] HE Hongwen, XIONG Rui. State-of-charge estimation of lithium-ion power battery using sliding mode observer [J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2011, 41(3): 623 – 628.
(何洪文, 熊瑞. 基于滑模观测器的锂离子动力电池荷电状态估计 [J]. 吉林大学学报(工学版), 2011, 41(3): 623 – 628.)
- [28] ZHANG Fei, LIU Guangjun, FANG Lijin, et al. Battery state of charge estimation based on H^∞ observer [J]. *Automation & Instrumentation*, 2010, 25(4): 1 – 5.
(张飞, 刘光军, 房立金, 等. 一种基于 H^∞ 观测器的电池荷电状态估计方法 [J]. 自动化与仪表, 2010, 25(4): 1 – 5.)
- [29] ZHANG Yun, ZHANG Chenghui, CUI Naxin. Estimation of state-of-charge of lithium-ion battery: nonlinear observer method [J]. *Control Theory & Applications*, 2012, 29(12): 1639 – 1644.
(张云, 张承慧, 崔纳新. 锂离子电池荷电状态估计: 非线性观测器方法 [J]. 控制理论与应用, 2012, 29(12): 1639 – 1644.)
- [30] YUN Haitao, ZHAO Yulan, ZHONG Zaimin. On-line SOC estimation of li-ion battery using luenberger closed-loop states observer [J]. *China Mechanical Engineering*, 2011, 21(20): 2505 – 2509.
(贡海涛, 赵玉兰, 钟再敏. 基于龙贝格状态观测器的车载辅助动力电池SOC估计 [J]. 中国机械工程, 2011, 21(20): 2505 – 2509.)
- [31] ZHANG Jie. *Dynamic estimation for state of charge in electric vehicles based on particle filter* [D]. Beijing: Beijing Jiaotong University, 2012.
(张洁. 基于粒子滤波算法的电动汽车剩余电量动态估计研究 [D]. 北京: 北京交通大学, 2012.)
- [32] CHEN M, RINCON-MORA G A. Accurate electrical battery model capable of predicting runtime and I-V performance [J]. *IEEE Transactions on Energy Conversion*, 2006, 21(2): 504 – 511.
- [33] SHANG Yunlong, ZHANG Qi, CUI Naxin, et al. Research on variable-order RC equivalent circuit model for lithium-ion battery based on the AIC criterion [J]. *Transactions of China Electrotechnical Society*, 2015, 30(17): 42 – 50.
(商云龙, 张奇, 崔纳新, 等. 基于AIC准则的锂电池变阶RC等效电路模型研究 [J]. 电工技术学报, 2015, 30(17): 42 – 50.)
- [34] HU Peng, CAO Guangyi, ZHOU Xinjian. Temperature model and fuzzy control for the proton-exchange-membrane fuel cell [J]. *Control Theory & Applications*, 2011, 28(10): 1371 – 1376.
(胡鹏, 曹广益, 朱新坚. 质子交换膜燃料电池温度模型与模糊控制 [J]. 控制理论与应用, 2011, 28(10): 1371 – 1376.)
- [35] BURNHAM K P, ANDERSON D R, HUYVAERT K P. AIC model selection and multimodel inference in behavioral ecology: some background, observations, and comparisons [J]. *Behavioral Ecology and Sociobiology*, 2011, 65(1): 23 – 35.
- [36] Qi M, ZHANG G P. An investigation of model selection criteria for neural network time series forecasting [J]. *European Journal of Operational Research*, 2001, 132(3): 666 – 680.

作者简介:

商云龙 (1984–), 男, 博士研究生, 目前研究方向为电动汽车动力电池建模、状态估计和均衡控制等, E-mail: shangyunlong@mail.sdu.edu.cn;

张承慧 (1963–), 男, 教授, 博士生导师, 目前研究方向为电动汽车、新能源及储能控制、工程优化控制、智能控制、控制理论与应用等, E-mail: zchui@sdu.edu.cn;

崔纳新 (1968–), 女, 教授, 博士生导师, 目前研究方向为电动汽车、工程优化控制、电力电子与电力传动、控制理论与应用等, E-mail: cuinx@sdu.edu.cn;

张奇 (1987–), 男, 助理实验师, 目前研究方向为电动汽车、控制理论与应用、实验技术等, E-mail: zhangqi2013@sdu.edu.cn.