

一种锂电池 SOH 估计的 KNN-马尔科夫修正策略

赵光财^{1,2} 林名强¹ 戴厚德¹ 武骥³ 汪玉洁⁴

摘要 锂离子电池的健康状态 (State of health, SOH) 是决定电池使用寿命的关键因素. 由于锂电池生产工艺、工作环境和习惯等的差异性导致其衰退特性具有较大差异, 因此锂电池 SOH 难以精确估算. 本文采用数据驱动的方式通过对采集的电压数据进行特征提取, 使用贝叶斯正则化神经网络对锂电池 SOH 进行预测, 同时引入 KNN-马尔科夫修正策略对预测结果进行修正. 实验结果证明, 贝叶斯正则化算法对锂电池 SOH 的预测准确度较高, KNN-马尔科夫修正策略提高了预测的精确度和鲁棒性, 组合预测模型对锂电池 SOH 的平均预测误差小于 1%, 与采用数据分组处理方法 (Group method of data handling, GMDH)、概率神经网络 (Probabilistic neural network, PNN)、循环神经网络 (Recurrent neural network, RNN) 的预测精度进行对比, 该模型的预测精度分别提高了 33.3%、48.7% 和 53.1%.

关键词 锂电池 SOH, 特征提取, 多层前馈神经网络, 贝叶斯正则化, 马尔科夫链

引用格式 赵光财, 林名强, 戴厚德, 武骥, 汪玉洁. 一种锂电池 SOH 估计的 KNN-马尔科夫修正策略. 自动化学报, 2021, 47(2): 453-463

DOI 10.16383/j.aas.c180124



开放科学 (资源服务) 标识码 (OSID):

A Modified Strategy Using the KNN-Markov Chain for SOH Estimation of Lithium Batteries

ZHAO Guang-Cai^{1,2} LIN Ming-Qiang¹ DAI Hou-De¹ WU Ji³ WANG Yu-Jie⁴

Abstract The state of health (SOH) of lithium batteries is a critical factor in determining the battery's end-of-service-life. The differences of the Lithium-ion battery's production process, work environment, and use habit etc. lead to the massive differences of the battery's fade characteristics, which, in turn, inaccurate estimation of their battery's SOH. In this paper, the data-driven method was employed for experimental feature extraction. Besides, this paper presents an SOH estimation method based on the Bayesian-regularization neural network and the KNN-Markov chain used for amending the prediction results. Experimental results show that the Bayesian-regularization neural network applied to the SOH estimation could obtain superior accuracy performance, and by combining the KNN-Markov chain, the prediction accuracy (the average prediction error of SOH less than 1%) could be improved. On the whole, the combined model shows good robustness. Compared with the group method of data handling (GMDH), probabilistic neural network (PNN) and recurrent neural network (RNN), the prediction accuracy of the model was improved by 33.3%, 48.7% and 53.1% respectively.

Key words Lithium battery SOH, feature extraction, multilayer feedforward neural network, Bayesian regularization, Markov chain

Citation Zhao Guang-Cai, Lin Ming-Qiang, Dai Hou-De, Wu Ji, Wang Yu-Jie. A modified strategy using the KNN-Markov chain for SOH estimation of lithium batteries. *Acta Automatica Sinica*, 2021, 47(2): 453-463

收稿日期 2018-03-05 录用日期 2018-08-01
Manuscript received March 5, 2018; accepted August 1, 2018
国家自然科学基金 (61501428), 福建省科技攻关项目 (引导性项目) (2018H0043), 中国科学院科研装备研制项目 (YZ201510) 资助
Supported by National Natural Science Foundation of China (61501428), Project of Science and Technology Department of Fujian Province (Pilot Project) (2018H0043), Research Equipment Development Project of Chinese Academy of Science (YZ201510)

本文责任编辑 曹向辉

Recommended by Associate Editor CAO Xiang-Hui

1. 中国科学院海西研究院泉州装备制造研究所 晋江 362200 2. 中国科学院大学 北京 100049 3. 合肥工业大学汽车与交通工程学院 合肥 230009 4. 中国科学技术大学信息科学技术学院 合肥 230026

1. Quanzhou Institute of Equipment Manufacturing, Haixi Institutes, Chinese Academy of Sciences, Jinjiang 362200

电池管理系统 (Battery management system, BMS) 是电动汽车的重要组成部分, 在电动汽车电池组的状态监测、保护和电量均衡等方面起到举足轻重的作用^[1-2]. 电池健康状态 (State of health, SOH) 作为电池系统的关键参数之一, 其变化直接影响电池组的使用性能、可靠性及安全性. 由于锂离子电池具有能量密度高、稳定性好、使用寿命长

2. University of Chinese Academy of Sciences, Beijing 100049
3. School of Automotive and Traffic Engineering, Hefei University of Technology, Hefei 230009 4. School of Information and Technology, University of Science and Technology of China, Hefei 230026

等优点, 已经被许多可再生能源系统用作能量存储设备. 但其复杂的内部电化学结构、不确定的外部工作环境等因素使得电池的衰退过程极为复杂, 即使同一规格型号的电池其衰退过程也不尽相同, 这导致锂电池 SOH 的准确估计变得十分困难^[3]. 因此, 快速、精确地实现锂电池 SOH 估计一直是一个重要的研究课题.

电池的 SOH 表示当前电池的最大可用容量占额定容量的百分比, 用来度量电池的退化程度. 锂电池 SOH 随着使用会慢慢减小, 当 SOH 降低至额定容量的 70% 时, 即认为锂电池寿命终止. SOH 的定义如下:

$$SOH = \frac{C_{\text{current}}}{C_{\text{initial}}} \times 100\% \quad (1)$$

上式中: C_{current} 表示锂电池当前最大可用容量; C_{initial} 表示锂电池的额定容量, 通常指出厂时的标称容量^[4].

目前已有许多专家学者采用多种不同方法对锂电池的 SOH 进行估计. Galeotti 等^[5] 采用电化学阻抗谱研究锂聚合物 (LiPO) 电池的老化, 通过拟合阻抗谱提取等效电路模型的参数再现电池放电曲线并引入电池欧姆电阻与可用容量的关系, 借助证据理论评估电池的 SOH. Chen 等^[6] 基于扩散电容与 SOH 的相关性, 采用遗传算法以实时采集的电流和电压来估计包括扩散电容在内的电池模型参数进而估计锂电池 SOH. Mejdoubi 等^[7] 提出混合估计电池荷电状态 (State of charge, SOC) 和 SOH 的思路, 使用自适应观察器估计 SOC 的同时使用扩展卡尔曼滤波器 (Extended Kalman filter, EKF) 估计 SOH, 采用闭环估计策略同时结合李雅普诺夫原理保证稳定性. Liu 等^[8] 将基于数据驱动的高斯过程回归 (Gaussian process regression, GPR) 方法应用于 SOH 估计, 采用改进的组合高斯过程泛函回归 (Gaussian process functional regression, GPFR) 模型实现了较好的 SOH 预测. Moura 等^[9] 提出了一种的基于电化学模型的自适应偏微分方程观测器来估计 SOH 的方法, 其通过测量电压和电流来估计该模型的参数. Ng 等^[10] 认为安时积分法对于具有高充电和高放电效率的锂电池的 SOC 估计是有利的. 他们提出了一种基于库仑计数的方法来提高估计精度, 并利用 SOC 来估计 SOH. Lievre 等^[11] 利用电池电阻来量化 SOH 退化情况, 通过电池组响应的电压和电流数据利用电池模型获得电池电阻, 进而估计电池的 SOH. EKF 被 Plett^[12] 引入到电池组的 SOH 预测中, 通过电池组建模和系统参数识别, 继而后用 EKF 估计 SOC, 最终估算出 SOH. 值得一提的是, 卡尔曼滤波及其衍生算法在电池 SOC、SOH 估计中应用十分广泛.

上述方法在预测 SOH 方面取得了很大的成功, 但在实际应用中也存在部分不足之处. 基于电化学阻抗谱的 SOH 预测需要复杂设备测量电池阻抗谱, 内阻法、化学模型法、安时积分法在预测精度上略显不足, 卡尔曼滤波法在当跟踪目标长时间被遮挡时会导致目标跟踪丢失. 目前很多基于机器学习的方法被用于锂电池 SOH 估计. Wu 等^[13-14] 将重要性采样、数据分组处理方法 (Group method of data handling, GMDH) 等应用于充放电数据采样和锂电池 SOH 估计, 取得了良好的预测效果. Klass 等^[15] 利用电池充放电过程中的电池电流、电压和温度等参数建立基于支持向量机的电池模型, 并用其对电池剩余使用寿命和瞬时电阻的估计进行预测. 循环神经网络 (Recurrent neural network, RNN) 被 Eddahech 等^[16] 引入到锂电池 SOH 估计中, 该方法基于等效电路方法的模型, 使用 RNN 来预测电池性能的退化. Lin 等^[17] 使用概率神经网络 (Probabilistic neural network, PNN) 估计锂电池的 SOH, 将放电时瞬时电压降以及开路电压作为 SOH 估计最重要的参数, 该方法能实现较高精度的 SOH 预测. 以上方法均可实现较好的预测效果, 但 SOH 估计本质是回归问题, PNN 更适合用在模式分类, 用于 SOH 估计需要大量训练样本. RNN 能够学习 SOH 随循环次数衰退的长期依赖, 但在短期预测精度上可进一步提高.

本文将马尔科夫链引入锂电池 SOH 估计中并改进为 KNN-马尔科夫修正策略以提升对锂电池 SOH 的预测效果, 该修正策略可有效减小随机扰动误差, 增强模型的短期预测能力. 此外, 采用的贝叶斯正则化神经网络 (Bayesian regularized neural network, BRNN) 具有复杂度较低, 同时具有良好的泛化性能. 为结合两者优势, 本文建立了贝叶斯正则化神经网络结合 KNN-马尔科夫修正策略的组合模型实现锂电池 SOH 的估计, 有效提高了 SOH 估计的准确性与鲁棒性.

本文结构如下, 第 1 节介绍预测方法原理包括贝叶斯正则化网络和马尔科夫链. 第 2 节介绍所做的工作包括预测模型的建立、特征提取以及 KNN-马尔科夫修正策略. 第 3 节介绍实验结果, 验证 KNN-马尔科夫策略的有效性及其所提出预测模型的准确性. 第 4 节是本文得出的结论.

1 预测方法原理

1.1 贝叶斯正则化神经网络

该神经网络为基于误差反向传播算法的多层前馈神经网络, 其网络结构如图 1^[18] 所示, 包括输入层、隐藏层和输出层三层^[19]. 设神经网络的训练样

本 $D(x_i, t_i), i = \{1, 2, \dots, n\}$, n 为训练样本数, W 为网络参数向量, M 为网络模型, f 为 Sigmoid 激活函数, 表达式为 $f(x) = \frac{1}{1+e^{-x}}$, t 为网络训练目标值, 神经网络的性能函数定义为均方差形式:

$$J_W = \frac{1}{2} \sum_{i=1}^n (f(x_i, W, M) - t_i)^2 \quad (2)$$

采用梯度下降法调整网络权重 $\omega_{hj} = \omega_{hj} - \Delta\omega_{hj}$, 其中 $\Delta\omega_{hj} = \eta \frac{\partial J_W}{\partial \omega_{hj}}$, ω_{hj} 为第 h 层的第 i 个权值, η 为网络学习率.




图 1 多层前馈神经网络结构示意图

Fig. 1 Structure of multilayer feedforward neural network

为防止神经网络训练过程中出现网络过拟合现象, 采用正则化算法优化网络结构, 以提高其泛化能力^[20]. 正则化方法对网络性能函数加入正则项 E_W :

$$E_W = \frac{1}{2} \|W\|_2^2 = \frac{1}{2} \sum_{i=1}^m \omega_i^2 \quad (3)$$

上式中 ω 为网络权值, m 为网络参数总数, 目标函数于是变为 $F(W) = \beta J_W + \alpha E_W$ ^[21], 即:

$$\min_{W, \alpha, \beta} (F(W)) = \frac{1}{2} \beta \sum_{i=1}^n \left\{ f(x_i, W, M) - t_i \right\}^2 + \frac{1}{2} \alpha \|W\|_2^2 \quad (4)$$

α 和 β 为正则化系数, β 侧重于减小训练误差, α 侧重于减小权值规模, 贝叶斯正则化算法在两者之间寻求平衡, 贝叶斯正则化神经网络训练的训练过程即寻找最优化的参数使得该目标函数最小化.

假定数据集和初始网络权值均服从高斯分布, 由贝叶斯准则求解最大后验概率, 即极小化网络训练目标函数, 得到使目标函数最小的 W_{MP} 处的 α 和 β ^[22]:

$$\alpha_{MP} = \frac{\gamma}{2E_W(W_{MP})}, \quad \beta_{MP} = \frac{n - \gamma}{2J_W(W_{MP})} \quad (5)$$

其中神经网络的有效参数个数为 $\gamma = m - 2\alpha_{MP}(\text{tr}(H^{-1}))$, m 是神经网络的参数数量, H 是目标函数在 W_{MP} 处的 Hessian 矩阵 $\alpha \nabla^2 E_W + \beta \nabla^2 J_W$.

首先确定神经网络结构, 由于采用正则化算法, 隐藏层神经元数量可稍大于最优的隐藏层神经元数量, 同时初始化超参数 α 和 β , 利用式 (5) 不断估计参数 α 和 β 的新值; 计算 H 矩阵及有效参数个数 γ , γ 为网络中起减少误差作用参数数量, 如果 γ 接近于 m 时需适当增加隐藏层神经元个数. 在总误差迭代过程中, 当总误差没有较大改变时, 网络训练收敛.

1.2 马尔科夫链

马尔科夫过程描述了一个具有若干个状态的系统, 其每个状态都可以根据固定转移概率传递给另一个状态. 马尔科夫链可以看作是某些概率的状态转换过程, 一个随机过程过渡到未来过程的概率只取决于当前的状态^[23-24]. 一步转移概率矩阵和 m 步转移概率矩阵 P_1 和 P_m 分别为:

$$P_1 = \begin{bmatrix} P_{11}^{(1)} & \dots & P_{1n}^{(1)} \\ \vdots & \ddots & \vdots \\ P_{n1}^{(1)} & \dots & P_{nn}^{(1)} \end{bmatrix},$$

$$P_m = \begin{bmatrix} P_{11}^{(m)} & \dots & P_{1n}^{(m)} \\ \vdots & \ddots & \vdots \\ P_{n1}^{(m)} & \dots & P_{nn}^{(m)} \end{bmatrix} \quad (6)$$

$P_{ij}^{(n)} = m_{ij}^{(n)} / M_i$ 为状态 E_i 经过 n 步后转移到状态 E_j 的转移概率, 其中 $m_{ij}^{(n)}$ 为训练数据中由状态 E_i 一步转移到 E_j 的次数, M_i 为以 E_i 作为起始状态的状态个数. m 步转移的矩阵概率为一步转移矩阵经过 m ($m > 1$) 步从而实现相应状态的概率矩阵. 一步转移概率矩阵和 m 步转移概率矩阵的关系如下:

$$P_m = [P_1]^m \quad (7)$$

2 预测模型的建立

2.1 预测模型的建立流程

基于锂电池衰减过程复杂的非线性特征, 本文采用了数据驱动的思路, 对传感器获取的电池充电过程中的电压数据进行特征提取, 提取具有鲁棒性及多样性的 8 个特征用于 SOH 估计, 这些特征能准确估计电池 SOH. 为保证 SOH 估计具有较高的准确度, 采用贝叶斯正则化神经网络进行 SOH 估计, 该网络能够防止训练过程的过拟合, 具有良好的泛化能力, 提高 SOH 估计准确度. 同时从训练数据中

学习 SOH 估计误差的统计特性并用于预测 SOH 估计误差, 采用 KNN 算法对误差值进行预处理, 划分状态空间并计算状态转移矩阵, 使用马尔科夫链得到预测 SOH 的经验估计误差, 并对神经网络 SOH 预测值进行误差修正得到最终 SOH 估计值. 预测模型如图 2 所示.

2.2 特征提取

本文采用的实验数据来自 NASA 公开数据集^[25]中的一组锂电池 (#5、#6、#7), 该组电池在室温 25 °C 下循环进行充电、放电和阻抗测试. 首先在恒流 (Constant current, CC) 模式下以 1.5 A 电流充电, 直到电池电压达到 4.2 V. 然后继续保持恒压充电 (Constant voltage, CV) 模式, 直到电荷电流降至 20 mA, 充电过程中电压、电流及 SOC 变化曲线如图 3 (a) 所示. 本文使用电压数据并结合 SOC 增量进行特征提取, 基于不同 SOH 电池充电电压随时间变化具有的规律性 (图 3 (b)) 提取特征用作 SOH 估计.

首先对传感器信息进行数据预处理, 根据循环次数对数据进行分组并剔除无效值. 然后利用统计方法提取该组电池恒流充电过程的电压信号特征, 主要包括电压均值和电压增量累积以及其 $dSOC/dV$ 特性三个方面.

电压的均值反映了电压直流分量的大小, 用来刻画电压幅值的大小. 设电池管理系统采集到的离散电压信号表示为, 则电压均值为^[26]:

$$V_{ave} = \frac{1}{n} \sum_{i=1}^n |V(i)| \quad (8)$$

其次, 电压增量累积反映 SOH 变化时电压的波动大小. 设 M 为电压信号的增量累积, 则电压增量

累积公式为^[26]:

$$M = \sum_{i=1}^{n-1} |\Delta V(i)| = \sum_{i=1}^{n-1} |V(i+1) - V(i)| \quad (9)$$

再次, 从电池衰退的物理容量降低的客观实际出发, 即相同电压的所容纳的电量在电池衰退过程中变化明显, 故 $dSOC/dV$ 可作为电池退化特征. 图 3 (c) 为不同充电循环次数下 $dSOC/dV$ 曲线变化曲线^[27], 在 SOH 差异最明显的 Peak1、Peak2 处各取两个 $dSOC/dV$ 值作为神经网络输入的电池退化特征. 为综合考虑特征多样性及预测的准确性, 采用如图 3 (d) 所示组合特征作为 BRNN 的训练输入.

2.3 KNN-马尔科夫修正策略

神经网络对锂电池的 SOH 进行预测得到的非线性模型存在局部偏差过大, 部分区域拟合效果不佳的缺点, 因此本实验采用了 KNN-马尔科夫方法对神经网络模型预测的 SOH 进行必要的修正, 从而整体上减小模型的预测误差, 提高模型的短期预测精度.

2.3.1 KNN 误差处理

假定估计误差分布为一维高斯分布, 由于随机性或者数据误差产生远离其他样本点的野点, 不能准确反映误差区间及分布的真实情况, 如果直接从训练数据中划分马尔科夫状态将会对误差区间估计造成偏差. 对于这种情况, 本文采用一个基于 K 近邻思路来对数据进行预处理. 该方法从误差数据中心取一点开始计算, 计算该点与 k 个近邻点的距离

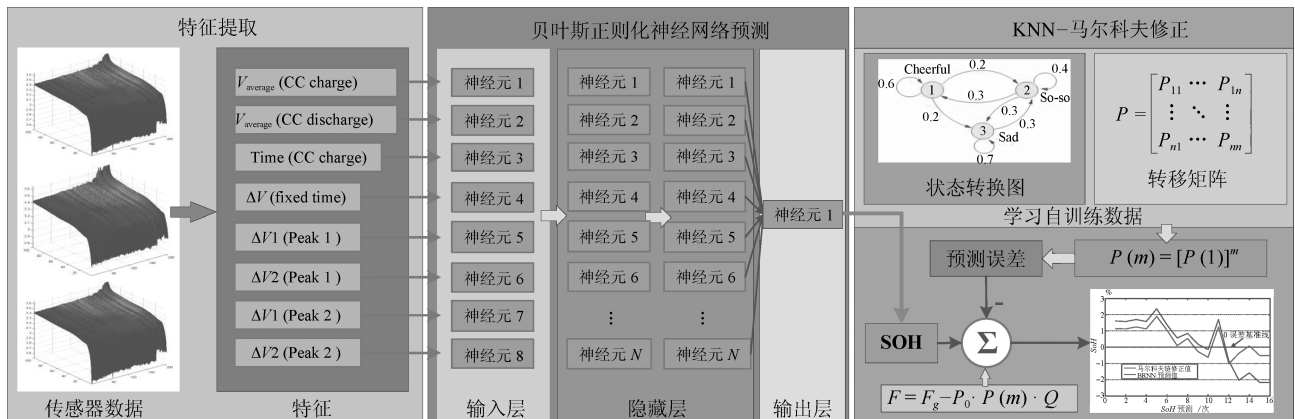


图 2 预测模型流程图

Fig. 2 Flowchart of the proposed prediction model

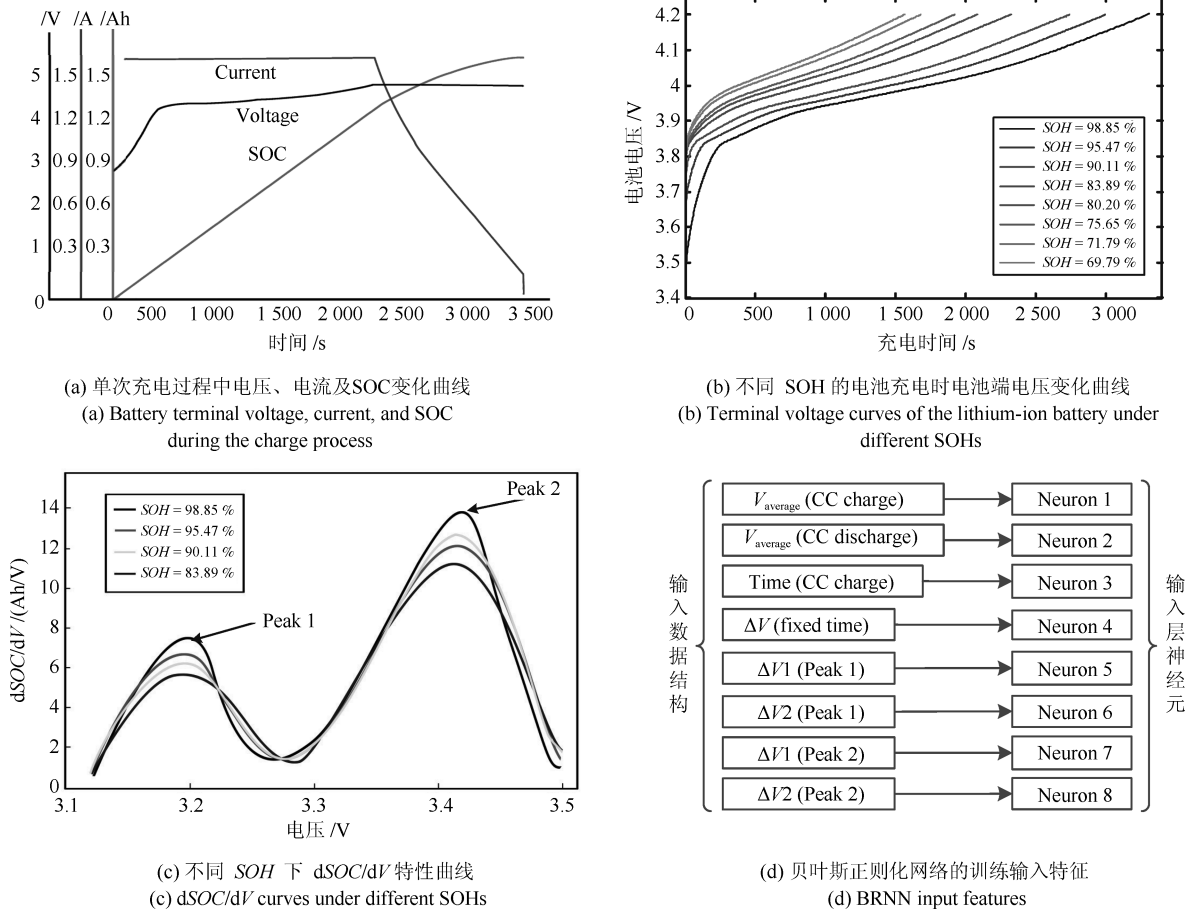


图 3 特征提取

Fig. 3 Feature extraction

的之和以及其相邻点的 k 个近邻的距离之和, KNN 的距离计算公式为^[28]:

$$distance(X, Y) = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (10)$$

其中, X 、 Y 为两个点, 如果相邻两误差点 KNN 距离之和的比值大于某一阈值则相应调整这两个误差点中远离数据中心点的数据使得该点像数据中心靠拢使其满足条件, 其公式为:

$$\lambda_i = \frac{\sum_{m=1}^k distance_m^{i+1}}{\sum_{m=1}^k distance_m^i} \quad (11)$$

其中 λ_i 为第 i 次 KNN 计算的比值, $\sum_{m=1}^k distance_m^{i+1}$ 表示第 i 个点的 k 个近邻点的距离之和, $\sum_{m=1}^k distance_m^i$ 表示其相邻的第 $i+1$ 个点的 k 个近邻点的距离之和. 该方法不会改变误差序列排列顺序, 同时选择合适的阈值不会改变误差内部数据, 仅使数据两端极大或极小的偶然值不

再过于偏离数据中心, 使得误差的状态空间划分更能反映实际情况, 从而降低由于系统不确定性或随机误差造成的干扰.

2.3.2 马尔科夫修正

基于 KNN 对误差数据处理, 采用马尔科夫链对神经网络预测结果进行误差修正. 根据训练数据误差分布划分马尔科夫链预测的状态空间^[29], 本文将状态转换划分为三个状态区间, 分别为 $S1$ $[0, \bar{x} - 0.5s]$, $S2$ $[\bar{x} - 0.5s, \bar{x} + 0.5s]$, $S3$ $[\bar{x} + 0.5s, 1]$, 其中 s 为训练数据的标准差, 在划分马尔科夫链状态空间前需用式 (12) 将数据归一化到 $[0, 1]$ 之间.

$$\tilde{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (12)$$

对神经网络的误差序列进行预测修正. 设残差所处状态为 $\alpha(t)$, 如当 $a < \alpha(t) < b$, 则处于该区间中的马尔科夫预测的修正误差为 $c = (a + b)/2$, 各状态区间的修正误差构成状态误差矩阵 Q , 其中 n 为状态区间个数, 结合第 1.2 节马尔科夫链内容得

修正公式为:

$$F = F_g - P_0 \cdot P_m \cdot Q \quad (13)$$

其中, F 为修正后的预测值; F_g 值为贝叶斯正则化神经网络的预测值; P_0 为 1×3 维初始状态矩阵; P_m 为 3×3 维 m 步状态转移矩阵; Q 指 3×1 维状态误差矩阵.

3 实验结果及分析

3.1 验证 KNN-马尔科夫修正策略

我们通过使用 KNN-马尔科夫修正前后预测值对实测值的拟合程度对比对该修正策略进行实验验证, 以检验该修正策略的有效性.

实验中随机选取 164 次充放电电压电流特征数据的 85% 作为训练数据, 15% 作为测试数据, SOH 真实值作为网络训练目标. 采用平均绝对误差 (Mean absolute error, MAE) 和均方误差 (Mean square error, MSE) 来评估算法 SOH 估计准确度, MAE 反映总体预测误差的大小, MSE 用来反映预测值对于真实 SOH 的偏离程度, MAE 和 MSE 分别定义为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |(x_i - \mu)|,$$

$$MSE = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n - 1}} \quad (14)$$

划分状态空间前使用 KNN 算法对偏离误差分布的孤立点进行调整, 选取阈值 $\lambda = 3$, 从数据中心点开始, 向数据两端分别进行调整, 调整的结果是该假定的一维高斯分布的内部误差数值不发生或微小变化, 仅分布边缘处的由于误差或偶然性出现的过大或过小数据向数据中心调整, 通过调整可以使学习到的误差状态空间更接近真实情况.

由上文状态划分公式计算得一个马尔科夫状态集, 由数据计算得到 $S1 [0, 0.32375]$, $S2 [0.32375, 0.46865]$, $S3 [0.46865, 1]$, 由公式 $x = x_{\min} + \tilde{x} \cdot (x_{\max} - x_{\min})$ 反归一化得到相对误差序列的三个状态分别为 $S1 [-3.236, -1.110]$, $S2 [-1.110, -0.114]$, $S3 [-0.114, -3.539]$. 并按此划分规则将各个预测误差划分为相应的马尔科夫状态, 如表 1 所示.

根据状态空间划分, 计算得到状态转移矩阵, 并对 BRNN 预测值进行修正. 状态转移矩阵见式 (15), BRNN 预测值及马尔科夫修正后误差见表 2.

表 1 BRNN 预测值相对误差及状态划分

Table 1 BRNN prediction error and state division

序号	实测值	预测值	相对误差 (%)	归一化相对误差 (%)	状态
1	0.6445	0.6431	-0.2172	0.4569	2
2	0.7480	0.7253	-3.0347	0.1425	1
3	0.9665	0.9646	-0.1965	0.4496	2
4	0.9502	0.9508	0.0631	0.4865	3
5	0.5802	0.5695	-1.8442	0.3194	1
6	0.7556	0.7344	-2.8057	0.1647	1
7	0.9294	0.9301	0.0753	0.4879	3
8	0.9222	0.9440	2.3639	0.7994	3
9	0.6808	0.6927	1.7479	0.6533	1
10	0.8615	0.8503	-1.3001	0.3123	1
11	0.7556	0.7619	0.8338	0.5706	3
12	0.6445	0.6431	-0.2172	0.4569	2

表 2 BRNN 预测误差及马尔科夫修正误差

Table 2 BRNN prediction and Markov correction error

序号	实测值	预测值	修正前误差 (%)	修正后误差 (%)
1	1.0000	0.9809	1.9090	1.4446
2	0.9942	0.9753	1.8847	1.4203
3	0.9941	0.9741	2.0029	1.5385
4	0.9878	0.9720	1.5855	1.1211
5	0.9665	0.9646	0.1857	-0.2787
6	0.9607	0.9623	-0.1558	-0.6202
7	0.9554	0.9333	2.2035	1.7391
8	0.9387	0.9590	-2.0253	-0.3699
9	0.9329	0.9486	-1.5736	0.0818
10	0.9222	0.9440	-2.1778	-0.5224

$$\left\{ \begin{array}{l} P_1 = \begin{bmatrix} 0.71 & 0.26 & 0.03 \\ 0.08 & 0.71 & 0.22 \\ 0.24 & 0.41 & 0.35 \end{bmatrix} \\ P_2 = \begin{bmatrix} 0.53 & 0.38 & 0.09 \\ 0.16 & 0.61 & 0.03 \\ 0.29 & 0.50 & 0.21 \end{bmatrix} \\ P_3 = \begin{bmatrix} 0.43 & 0.45 & 0.13 \\ 0.22 & 0.57 & 0.22 \\ 0.29 & 0.52 & 0.19 \end{bmatrix} \\ P_4 = \begin{bmatrix} 0.37 & 0.48 & 0.15 \\ 0.25 & 0.59 & 0.20 \\ 0.29 & 0.52 & 0.18 \end{bmatrix} \end{array} \right. \quad (15)$$

由图 4 的 (a)、(c)、(e) 可以看出, 5#、6#、7# 电池马尔科夫修正后的更加接近实测值, 局部放大

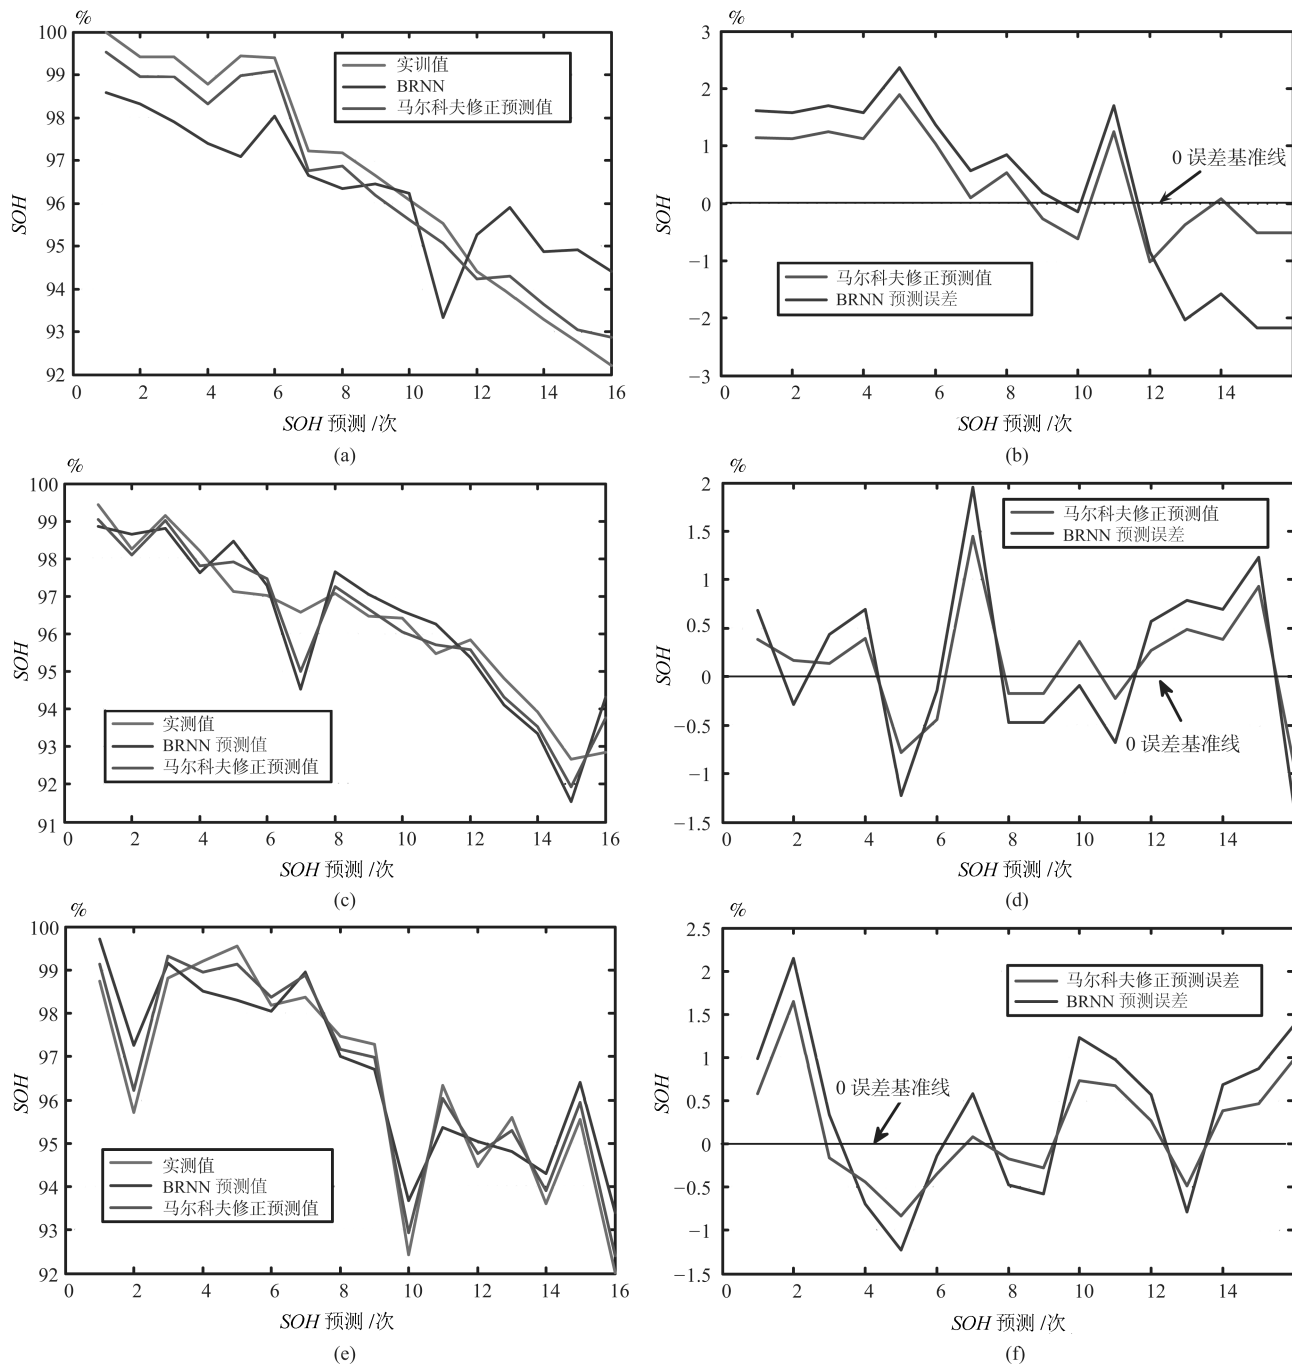


图 4 马尔科夫修正过程修正前后结果对比

Fig. 4 Comparative results of BRNN and Markov correction

图显示组合模型预测准确度好于修正前, 验证了马尔科夫修正的有效性. 图 4 的 (b)、(d)、(f) 为 5#、6#、7# 电池修正前后的误差对比, 从中可以看出马尔科夫修正后绝大部分误差明显减小, 修正误差效果明显.

如表 3 所示, 马尔科夫修正方法在 5、6、7 号的电池上验证均提高了 BRNN 预测精度, 其中 5、6、7 号电池的

MAE 分别降低了 25.5%、17.3%、15.9%,

表 3 KNN-马尔科夫修正结果

Table 3 KNN-Markov correction results

编号	5# 电池		6# 电池		7# 电池	
	无修正	有	无	有	无	有
MAE (%)	0.47	0.35	0.52	0.43	0.44	0.37
MSE (% ²)	0.49	0.37	0.52	0.40	0.48	0.37

MSE 分别降低了 26.5%、22.5%、21.8%. 实验结

果表明, 本文提出的 KNN-马尔科夫修正方法能够获得更加精确和鲁棒的估计结果.

3.2 验证组合模型先进性

为检验 KNN-马尔科夫修正策略与 BRNN 的组合预测模型 (MC-BRNN) 的准确度, 与集中较为先进的预测方法进行对比, 包括 GMDH、PNN、RNN, 采用的算法参数如下:

BRNN: 隐藏层神经元数量为 25 个, 学习率为 0.1.

GMDH: 最大隐藏层数为 4, 单层最大神经元个数为 20.

PNN: 包括输入层、模式层、竞争层、输出层, 平滑系数为 0.1.

RNN: 单层 LSTM-RNN 结构, 隐藏层神经元数量为 70.

由表 4 可知, 与 GMDH、PNN、RNN 相比, MC-BRNN 能够使得预测结果的 MSE 和 MAE 平均分别降低约 45.8%、70.3%、79.3% 和 33.3%、48.7%、53.1%. 通过该实验结果对比可以得出, 组合模型用到的 BRNN 能够避免数据的过拟

合现象, 精度较高.

对各算法的训练时间在 CPU 为 i5-3210M (2.5 GHz), 4 GB RAM 的计算机上进行统计, 得到各算法运行时间如表 5 所示.

从表 5 中可以看出, PNN 训练时间最短, GMDH 和 MC-BRNN 训练时间差别不大, RNN 的训练时间较长. 由于 SOH 变化缓慢, 对算法的实时性要求不高, 同时结合表 3 和表 4 可以看出, BRNN 预测 SOH 的准确度较高, 并可以通过设置较大迭代次数以增加训练时间为代价来实现最佳的预测, 提高估计的准确度. 因此采用 MC-BRNN 在估计 SOH 方面具有更好的效果.

图 5 的 (a)、(c)、(e) 的局部放大图显示 MC-BRNN 与 GMDH、PNN、RNN 相比在 SOH 估计精度方面具有较为明显的优势, 对真实值的拟合度更高. 图 5 的 (b)、(d)、(f) 曲线所示, 5#、7# 电池的 MC-BRNN 预测的最大预测误差为 3% 左右, 6# 电池的最大预测误差小于 2.5%, 误差大部分集中分布在 $\pm 1%$ 的范围内. 综合以上可知, MC-BRNN 组合预测模型相对于 GMDH、PNN、RNN 对锂电池 SOH 的预测性能更好.

表 4 各算法准确度对比



Table 4 Comparison of accuracy of each algorithm

编号 算法	5# 电池				6# 电池				7# 电池			
	MC-BRNN	GMDH	PNN	RNN	MC-BRNN	GMDH	PNN	RNN	MC-BRNN	GMDH	PNN	RNN
MAE (%)	0.35	0.52	0.64	0.67	0.43	0.61	0.81	0.93	0.37	0.59	0.79	0.83
MSE (% ²)	0.37	0.67	0.94	1.21	0.40	0.88	1.30	2.35	0.37	0.58	1.57	1.95

表 5 各算法的时间复杂度对比 (s)

Table 5 Comparison of time complexity of each algorithm (s)

算法	MC-BRNN	GMDH	PNN	RNN
5 号电池	1.5101	1.1184	0.2994	4.5942
6 号电池	1.4361	1.1948	0.2442	3.7446
7 号电池	1.5559	1.1103	0.2748	4.8092
平均值	1.5007	1.1399	0.2726	4.3826



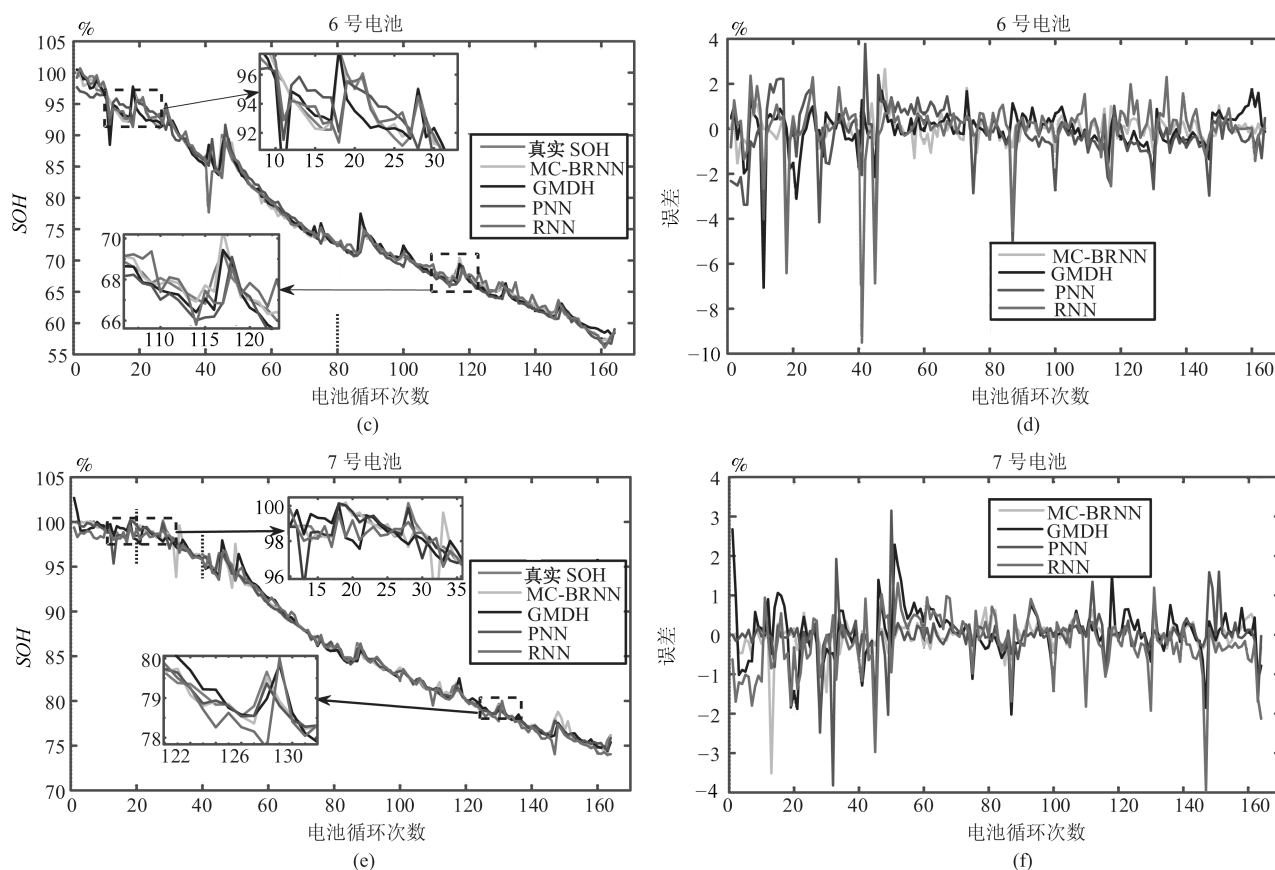


图5 MC-BRNN、GMDH、PNN、RNN 预测结果对比

Fig. 5 Comparative results of MC-BRNN, GMDH, PNN and RNN


4 结论

本文建立了基于贝叶斯正则化神经网络与KNN-马尔科夫链的组合预测模型,该模型结合了贝叶斯正则化算法在能够有效避免过拟合的优点与KNN-马尔科夫修正方法在系统短时预测方面的优势,对锂电池SOH具有较好的预测效果。同时,该组合预测模型对锂电池SOH的平均预测误差小于1%,能准确估计SOH。KNN-马尔科夫链修正方法可显著提高神经网络的估计精度,该修正方法基于SOH退化的客观规律性,可提高神经网络15%~30%的估计精度,该方法也为其他SOH估计方法提供了一种误差修正思路。最后,本文将组合模型与GMDH、PNN、RNN进行了对比实验,经实验验证,该组合模型的预测精度相比以上两种方法分别提高了33.3%、57.2%和53.1%,同时具有良好的鲁棒性。

References


- Cheng K W E, Divakar B P, Wu H J, Ding K, Ho H F. Battery-management system (BMS) and SOC development for electrical vehicles. *IEEE Transactions on Vehicular Technology*, 2011, **60**(1): 76-88
- Chen Hong, Gong Xun, Hu Yun-Feng, Liu Qi-Fang, Gao Bing-Zhao, Guo Hong-Yan. Automotive control: The state of the art and perspective. *Acta Automatica Sinica*, 2013, **39**(4): 322-346
(陈虹, 宫洵, 胡云峰, 刘奇芳, 高炳钊, 郭洪艳. 汽车控制的研究现状与展望. *自动化学报*, 2013, **39**(4): 322-346)
- Scrosati B, Garche J. Lithium batteries: Status, prospects and future. *Journal of Power Sources*, 2010, **195**(9): 2419-2430
- Andre D, Appel C, Soczka-Guth T, Sauer D U. Advanced mathematical methods of SOC and SOH estimation for lithium-ion batteries. *Journal of Power Sources*, 2013, **224**: 20-27
- Galeotti M, Ciná L, Giammanco C, Cordiner S, Carlo D A. Performance analysis and SOH (state of health) evaluation of lithium polymer batteries through electrochemical impedance spectroscopy. *Energy*, 2015, **89**: 678-686
- Chen Z, Mi C C, Fu Y H, Xu J, Gong X Z. Online battery state of health estimation based on genetic algorithm for electric and hybrid vehicle applications. *Journal of Power Sources*, 2013, **240**: 184-192
- Mejdoubi A E, Oukaour A, Chaoui H, Gualous H, Sabor J, Slamani Y. State-of-charge and state-of-health lithium-ion batteries' diagnosis according to surface temperature variation. *IEEE Transactions on Industrial Electronics*, 2016, **63**(4): 2391-2402

- 8 Liu D T, Pang J Y, Zhou J B, Peng Y, Pecht M. Prognostics for state of health estimation of lithium-ion batteries based on combination Gaussian process functional regression. *Microelectronics Reliability*, 2013, **53**(6): 832–839
- 9 Moura S J, Chaturvedi N A, Krstić M. Adaptive partial differential equation observer for battery state-of-charge/state-of-health estimation via an electrochemical model. *Journal of Dynamic Systems, Measurement, and Control*, 2014, **136**(1): 011015
- 10 Ng K S, Moo C S, Chen Y P, Hsieh Y C. Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries. *Applied Energy*, 2009, **86**(9): 1506–1511
- 11 Lievre A, Sari A, Venet P, Hijazi A, Ouattara-Brigaudet M, Pelissier S. Practical online estimation of lithium-ion battery apparent series resistance for mild hybrid vehicles. *IEEE Transactions on Vehicular Technology*, 2016, **65**(6): 4505–4511
- 12 Plett G L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1. Background. *Journal of Power Sources*, 2004, **134**(2): 252–261
- 13 Wu J, Wang Y J, Zhang X, Chen Z H. A novel state of health estimation method of Li-ion battery using group method of data handling. *Journal of Power Sources*, 2016, **327**: 457–464
- 14 Wu J, Zhang C B, Chen Z H. An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks. *Applied Energy*, 2016, **173**: 134–140
- 15 Klass V, Behm M, Lindbergh G. A support vector machine-based state-of-health estimation method for lithium-ion batteries under electric vehicle operation. *Journal of Power Sources*, 2014, **270**: 262–272
- 16 Eddahech A, Briat O, Bertrand N, Deléage J Y, Vinassa J M. Behavior and state-of-health monitoring of Li-ion batteries using impedance spectroscopy and recurrent neural networks. *International Journal of Electrical Power & Energy Systems*, 2012, **42**(1): 487–494
- 17 Lin H T, Liang T J, Chen S M. Estimation of battery state of health using probabilistic neural network. *IEEE Transactions on Industrial Informatics*, 2013, **9**(2): 679–685
- 18 Basheer I A, Hajmeer M. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 2000, **43**(1): 3–31
- 19 Lam C H, Shin F G. Formation and dynamics of modules in a dual-tasking multilayer feed-forward neural network. *Physical Review E*, 1998, **58**(3): 3673–3677
- 20 Sun Z, Chen Y, Li X Y, Qin X L, Wang H Y. A Bayesian regularized artificial neural network for adaptive optics forecasting. *Optics Communications*, 2017, **382**: 519–527
- 21 Yang Hai-Shen, Fu Hong-Zhuo. Stock index forecast based on Bayesian regularization BP neural network. *Science Technology and Engineering*, 2009, **9**(12): 3306–3310, 3318 (杨海深, 傅红卓. 基于贝叶斯正则化 BP 神经网络的股票指数预测. *科学技术与工程*, 2009, **9**(12): 3306–3310, 3318)
- 22 Li Hong-Xia, Xu Shi-Guo, Fan Chui-Ren. Long-term prediction of runoff based on Bayesian regulation neural network. *Journal of Dalian University of Technology*, 2006, **46**(S1): 174–177 (李红霞, 许士国, 范垂仁. 基于贝叶斯正则化神经网络的径流长期预报. *大连理工大学学报*, 2006, **46**(S1): 174–177)
- 23 Neal R M. Markov chain sampling methods for dirichlet process mixture models. *Journal of Computational and Graphical Statistics*, 2000, **9**(2): 249–265
- 24 Li Xin-De, Dong Qing-Quan, Wang Feng-Yu, Luo Chao-Min. A method of conflictive evidence combination based on the Markov chain. *Acta Automatica Sinica*, 2015, **41**(5): 914–927 (李新德, 董清泉, 王丰羽, 雒超民. 一种基于马尔科夫链的冲突证据组合方法. *自动化学报*, 2015, **41**(5): 914–927)
- 25 NASA. PCoE datasets: battery data set [Online], available: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>, August 22, 2017.
- 26 Chen Qiao-Yan, Wei Ke-Xin. Signal Statistic analysis for electric vehicle battery SOH. *Chinese Journal of Power Sources*, 2016, **40**(2): 342–344 (陈峭岩, 魏克新. 电动汽车电池 SOH 的信号统计分析. *电源技术*, 2016, **40**(2): 342–344)
- 27 Weng C H, Feng X N, Sun J, Peng H. State-of-health monitoring of lithium-ion battery modules and packs via incremental capacity peak tracking. *Applied Energy*, 2016, **180**: 360–368
- 28 Ye Tao, Zhu Xue-Feng, Li Xiang-Yang, Shi Bu-Hai. Soft sensor modeling based on a modified k -nearest neighbor regression algorithm. *Acta Automatica Sinica*, 2007, **33**(9): 996–999 (叶涛, 朱雪峰, 李向阳, 史步海. 基于改进 k -最近邻回归算法的软测量建模. *自动化学报*, 2007, **33**(9): 996–999)
- 29 Xue Peng-Song, Feng Min-Quan, Xing Xiao-Peng. Water quality prediction model based on Markov chain improving gray neural network. *Engineering Journal of Wuhan University*, 2012, **45**(3): 319–324 (薛鹏松, 冯民权, 邢肖鹏. 基于马尔科夫链改进灰色神经网络的水质预测模型. *武汉大学学报 (工学版)*, 2012, **45**(3): 319–324)



赵光财 中国科学院海西研究院泉州装备制造研究所硕士研究生。2016 年获得中国海洋大学学士学位。主要研究方向为锂电池状态估计。E-mail: zhaoguangcai17@mailsucas.ac.cn

(ZHAO Guang-Cai Master student at Quanzhou Institute of Equipment Manufacturing, Haixi Institutes, Chinese Academy of Sciences. He received his bachelor degree from Ocean University of China in 2016. His main research interest is states estimation of Li-ion batteries.)



林名强 中国科学院海西研究院泉州装备制造研究所副研究员. 2016 年获中国科学技术大学博士学位. 主要研究方向为计算机视觉, 模式识别, 复杂系统分析与控制. 本文通信作者.

E-mail: kdllmq@fjirsm.ac.cn

(**LIN Ming-Qiang** Associate professor at Quanzhou Institute of Equip-

ment Manufacturing, Haixi Institutes, Chinese Academy of Sciences. He received his Ph. D. degree from the University of Science and Technology of China in 2016. His research interest covers computer vision, pattern recognition, and analysis and control of complex systems. Corresponding author of this paper.)



戴厚德 中国科学院海西研究院泉州装备制造研究所研究员. 2014 年获得慕尼黑工业大学机械工程博士学位. 主要研究方向为智能传感器, 信号处理和移动机器人. E-mail: dhd@fjirsm.ac.cn

(**DAI Hou-De** Professor at Quanzhou Institute of Equipment Man-

ufacturing, Haixi Institutes, Chinese Academy of Sciences. He received his Ph. D. degree in mechanical engineering from TU Munchen, Germany, in 2014. His research interest covers intelligent sensors, information processing, and mobile robots.)



武 骥 合肥工业大学车辆工程系讲师. 2018 年获得中国科学技术大学控制科学与工程博士学位. 主要研究方向为复杂系统建模、控制与优化.

E-mail: wu.ji@hfut.edu.cn

(**WU Ji** Lecturer at the School of Automotive and Traffic Engineering, Hefei University of Technology. He received

his Ph. D. degree in control science and technology from University of Science and Technology of China in 2018. His research interest covers the modeling, control and optimization of the complex systems.)



汪玉洁 中国科学技术大学自动化系副研究员. 2017 年获得中国科学技术大学博士学位. 主要研究方向为电动汽车能源管理, 系统建模、状态估计与控制.

E-mail: wangyujie@ustc.edu.cn

(**WANG Yu-Jie** Associate researcher in the Department of Automation, University of Science and Technol-

ogy of China. He received his Ph. D. degree from the University of Science and Technology of China in 2017. His research interest covers energy management of electric vehicles, system modeling, state estimation and control.)