



DOI:10.13364/j.issn.1672-6510.20190133

基于深度强化学习卡尔曼滤波锂离子电池 SOC 估计

高洪森¹, 游国栋², 王 雪², 房诚信², 张 尚²

(1. 天津力神电池股份有限公司, 天津 300384; 2. 天津科技大学电子信息与自动化学院, 天津 300222)

摘要: 针对锂离子电池的荷电状态(state of charge, SOC)估算精度,设计了一种基于深度强化学习卡尔曼滤波锂离子电池 SOC 估计算法. 首先以锂离子电池二阶 RC 等效电路为研究对象,应用卡尔曼滤波算法,构建了锂离子电池的离散系统数学模型;然后结合深度强化学习思想,构造了一种深度强化学习卡尔曼滤波算法,该算法利用贝叶斯规则确保最佳协方差. 仿真结果表明,深度强化学习卡尔曼滤波算法对锂离子电池荷电状态的精度有较好的估计.

关键词: 锂离子电池; 荷电状态; 卡尔曼滤波; 深度学习

中图分类号: TM912 文献标志码: A 文章编号: 1672-6510(2020)04-0065-05

Estimating the State of Charge of Li-ion Batteries Based on Reinforcement Learning of Kalman Filters

GAO Hongsen¹, YOU Guodong², WANG Xue², FANG Chengxin², ZHANG Shang²

(1. Tianjin Lishen Battery Joint-stock Co., Ltd., Tianjin 300384, China;

2. College of Electronic Information and Automation, Tianjin University of Science & Technology, Tianjin 300222, China)

Abstract: In order to improve the estimation accuracy of the state of charge (SOC) of the lithium-ion battery, an algorithm to estimate the state of charge of lithium-ion batteries based on reinforcement learning of Kalman filters was proposed. Firstly, a second-order RC equivalent circuit model was introduced, and a state-space model of coefficient of variation of the lithium-ion battery was structured by using Kalman filter. Then, a reinforcement learning algorithm of Kalman filters was structured, while Bayes rule was used to ensure optimal covariance. Simulation shows that the algorithm can more accurately estimate the state of charge of the batteries.

Key words: lithium-ion battery; state of charge; Kalman filter; reinforcement learning

随着新能源交通工具的普及,锂离子电池具有了广泛的应用空间. 锂离子电池的状态估计是储能系统的重要组成部分之一^[1-3]. 锂离子电池状态估计的准确性与电池的充放电过程以及新能源交通工具的运行状态密切相关. 为了提高锂离子电池状态估计的精度,国内外相关学者进行了大量研究.

卡尔曼滤波(Kalman filter)是一种利用线性系统状态方程,通过系统输入输出观测数据,对系统进行最优估计的算法. 由于观测数据中包括系统中的噪声和干扰的影响,所以最优估计也可看作是滤波过

程,是一种常见的锂离子电池状态估计算法^[4-5]. 锂离子电池运行状态复杂,状态估计受很多因素的干扰. 针对串联锂离子电池组不一致性辨识与状态估计,葛云龙等^[6]提出一种 STF&LM 算法,该算法将各单体状态、内阻估计误差控制在合理范围内,提升了电池组不一致性辨识与状态估计. 程泽等^[7]在分析锂离子电池二阶 RC 等效电路基础上,将 Sage-Husa 自适应滤波思想与传统平方根无迹卡尔曼滤波(square-root unscented Kalman filter, SRUKF)相结合,构建了一种自适应平方根无迹卡尔曼滤波算法,该算法提高

收稿日期: 2019-05-03; 修回日期: 2019-07-09

基金项目: 天津市科技支撑重点项目(17YFZCNC00230, 13JCZDJC29100); 天津科技大学实验室创新基金资助项目(1902A030)

作者简介: 高洪森(1977—),男,山东沂水人,高级工程师;通信作者: 游国栋,副教授, yougdong1973@sohu.com

了对电池欧姆电阻和容量的估计. 上述算法大都设置已知系统的噪声特性, 然而系统的过程噪声方差阵或观测噪声方差阵事先是未知的, 并且具有很强的不确定性和时变性, 因此如果出现错误的参数估计常常会造成滤波的发散.

深度强化学习将深度学习感知能力和强化学习决策能力相结合, 可直接根据输入图像进行控制, 是一种更接近人类思维方式的人工智能方法^[8-10]. 文献[11]利用深度强化学习思维, 提出了一种强化学习的锂离子电池的状态估计算法, 该方法对于锂离子电池的状态估计更加精确和灵活, 弊端是更改参数存在困难. 文献[12]和[13]分别将神经网络和卡尔曼滤波算法相结合, 提出了两种不同的算法, 实验均验证了能够提高锂离子电池状态估计的精度. 上述算法中初始学习参数的选择主要依靠经验, 若选择不当的话, 很容易产生局部最优解. 赵明等^[14]将深度学习与卷积神经网络相结合, 应用于地震波形自动分类与识别, 并以汶川余震事件中 8 900 个检测数据作为训练值, 训练和检测准确率均达到 95% 以上. 针对蜂窝网资源分配多目标优化问题, 廖晓闽等^[15]构建了一种深度强化学习的蜂窝网资源分配算法, 论文通过 Q-learning 机制设计了误差函数, DNN 的权值利用梯度下降法训练, 训练结果表明该算法能够自主设置资源分配方案的偏重程度, 且收敛速度快.

基于上述分析, 本文通过对锂离子电池二阶 RC 等效电路拓扑, 建立了离散系统数学模型, 提出了一种新的深度强化学习卡尔曼滤波锂离子电池荷电状态(SOC)估计方法. 首先, 通过分析锂离子电池二阶 RC 等效电路模型, 建立了电池的状态空间模型, 并利用传统的卡尔曼滤波算法构建了锂离子电池的离散系统数学模型. 结合人工智能思想, 进一步设计了一个深度强化学习卡尔曼滤波锂离子电池 SOC 估计方法. 最后, 通过贝叶斯规则确保了最佳协方差. 仿真结果表明, 该算法能够较好地提高电池 SOC 估计的精度.

1 电池状态空间模型

1.1 电池模型的建立

锂离子电池的运行状态较为复杂, 其涉及电化学反应、电荷传递等多个相互耦合的过程, 具有强烈的非线性动态特性. 针对锂离子电池的 SOC 估计, 学者们建立了不同的模型, 其主要包括等效电路模型、电化学反应模型和人工神经网络模型. 等效电路模型

可以更准确地表达锂离子电池外特性, 最能代表电池的动态特性线性模型. 论文将二阶等效电路模型作为研究对象(如图 1), 数学模型为

$$\begin{cases} u_0 = r_0 i_t \\ i_t = \frac{u_1}{r_1} + C_1 \frac{du_1}{dt} \\ i_t = \frac{u_2}{r_2} + C_2 \frac{du_2}{dt} \\ u_t = u_{OCV} - u_1 - u_2 - u_0 \end{cases} \quad (1)$$

式中: r_0 为锂离子电池内阻; r_1, r_2, C_1, C_2 为锂离子电池的极化内阻和极化电容; i_t 为锂离子电池电流; u_0 为锂离子电池内阻端电压; u_{OCV} 为锂离子电池开路电压; u_1, u_2 分别为锂离子电池的极化内阻 r_1, r_2 的电压; u_t 为锂离子电池开路端电压; t 为运行时间.




图 1 锂离子电池等效电路

Fig. 1 Equivalent circuit model for lithium-ion battery

采用安时积分法有锂离子电池的 SOC

$$S_t = S_{t_0} - \frac{\lambda}{Q_c} \int_{t_0}^t i_t dt \quad (2)$$

式中: λ 为库仑效率系数; Q_c 为电池标定容量; t_0 为初始时间; S_{t_0} 和 S_t 分别为 SOC 的初始值和变化值.

结合最小二乘法对模型各参数进行参数辨识. 定义状态变量 $x_k = [s_k \ u_{1,k} \ u_{2,k}]^T$, 结合式(1)和(2), 可得锂离子电池的状态空间模型

$$\begin{cases} \begin{bmatrix} s_{k+1} \\ u_{1,k+1} \\ u_{2,k+1} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-T/\tau_1} & 0 \\ 0 & 0 & e^{-T/\tau_2} \end{bmatrix} \times \begin{bmatrix} s_k \\ u_{1,k} \\ u_{2,k} \end{bmatrix} \\ + \begin{bmatrix} -\lambda T / Q_c \\ r_1(1 - e^{-T/\tau_1}) \\ r_2(1 - e^{-T/\tau_2}) \end{bmatrix} \times i_{t,k} + \begin{bmatrix} w_{1,k} \\ w_{2,k} \\ w_{3,k} \end{bmatrix} \\ u_{t,k} = u_{OCV}(s_k) - u_{1,k} - u_{2,k} - r_0 i_{t,k} + v_k \end{cases} \quad (3)$$

式中: $\tau_1 = r_1 C_1$, $\tau_2 = r_2 C_2$; $u_k (u_k = i_{t,k})$ 为控制变量; $y_k (y_k = u_{t,k})$ 为观测变量; T 为变化周期; $w_k (w_k = [w_{1,k} \ w_{2,k} \ w_{3,k}]^T)$ 为系统噪声干扰, 协方差为 Q ; v_k 为观测噪声干扰, 协方差为 R .

1.2 电池模型的参数辨识

通过放电实验可以得到 SOC-OCV 关系式. 图 2

为天津力神公司生产的 18650 型锂离子电池在常温 (20 ~ 25 °C) 下的 SOC-OCV 特性曲线图。




图 2 锂离子电池 SOC-OCV 特性曲线

Fig. 2 SOC-OCV characteristic mapping curve of lithium-ion battery

2 深度学习卡尔曼估计电池 SOC

结合公式 (1) — (3), 应用卡尔曼滤波器, 建立锂离子电池的离散系统数学模型

$$\begin{cases} x_{k+1} = f(x_k, u_k) + w_k \\ y_k = h(x_k, u_k) + v_k \end{cases} \quad (4)$$

式中: 噪声干扰 w_k 、 v_k 分别设置为 $w_k \in (0, Q)$, $v_k \in (0, R)$ 。

强化学习由动物学习、参数扰动自适应控制等理论发展而来, 是一种机器学习算法。深度强化学习将深度学习的感知能力和强化学习的决策能力相结合, 不断以试错的方式与环境进行交互, 通过最大化累积奖赏的方式获得最优策略^[10]。本文采用深度 Q 网络 (DQN, deep Q-network) 具体求解资源分配问题, 核心思想是将值网络作为评判模块, 基于值网络遍历当前观测状态下的各种动作, 与环境进行实时交互, 将状态、动作和奖赏值存储在记忆单元中, 采用 Q-learning 算法反复训练值网络, 最后选择能获得最大价值的动作作为输出。基于深度强化学习的卡尔曼锂电池 SOC 估计的基本框架如图 3 所示。




图 3 深度强化学习的卡尔曼滤波 SOC 估算原理图

Fig. 3 SOC estimation process under reinforcement learning of Kalman filters

图 3 中 s_k 为算法进行到第 $t (t = 1, 2, \dots, k, \dots, n)$ 步时对应的观测, u_k 为观测 s_k 下所执行的动作,

$r(s_k, u_k) = r_k$ 为观测 s_k 下执行动作 u_k 后, 获得的奖赏 (或惩罚)。

深度学习卡尔曼估计电池 SOC 估算流程如图 4 所示。

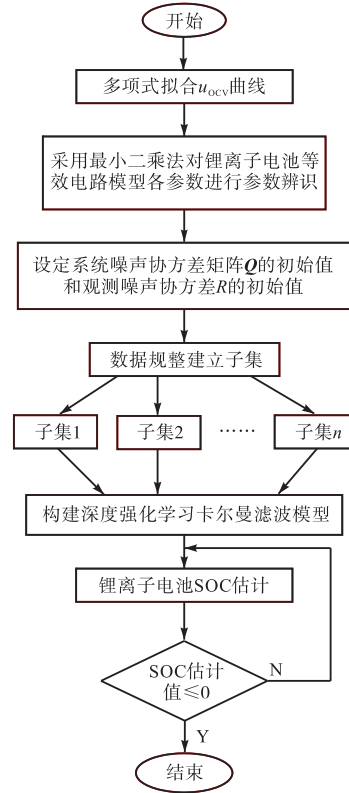


图 4 深度学习卡尔曼滤波锂离子电池 SOC 估算流程图

Fig. 4 SOC estimation flow chart under reinforcement learning of Kalman Filters

将卡尔曼滤波算法与深度强化学习相结合, 对锂离子电池 SOC 进行估计, 有动作状态值函数

$$\begin{cases} Q^\pi(s_t, u_t) = \mathbb{Z}_{r_t \geq 1, s_t \geq 1-E, u_t \geq 1-\pi} [G_t | s_t, u_t] \\ L(\theta^\pi) = \mathbb{Z} x \sim \rho^\beta, s_t \sim \beta, r_t \sim E \left[\left(Q(s_t, u_t | \theta^\pi) - y_t \right)^2 \right] \\ y_t = r(s_t, u_t) - \gamma Q[s_{t+1}, u_{t+1}] \end{cases} \quad (5)$$

式中: $s_t \in \mathcal{X}$, $u_t \in \mathcal{U}$, $r(s_t, u_t)$, $t \in [1, T]$, $\pi(u_t | s_t) \in \rho^\pi(s_t)$, $G_t = \sum_{i=t}^T \gamma^{i-t} r(s_i, u_i)$, $G = \mathbb{Z}_{r_t \geq 1, s_t \geq 1-E, u_t \geq 1-\pi} [G_t]$. $\gamma \in (0, 1)$ 为折扣因子。

当 $r(s_t, u_t) + \gamma \max Q[s_{t+1}, u_{t+1}] - Q[s_t, u_t] \rightarrow 0$ 时, $Q^{\pi_{k+1}}(s_t, u_t) \approx Q^{\pi_k}(s_t, u_t)$ 成立。可通过 $\min L(\theta^\pi) = \min \{ r(s_t, u_t) + \gamma \max Q[s_{t+1}, u_{t+1}] - Q[s_t, u_t] \}$ 优化获得参数更替。

定义最佳 Q 函数为

$$Q(s_k, u_k, a_k) = \mathbb{C}[G_k | s_k, u_k, a_k] \quad (6)$$

利用贝叶斯规则, 方程 (6) 可以改写为

$$Q(s_k, u_k, a_k) = \mathbb{C}[r_k | s_k, u_k, a_k] - \gamma \sum_{a_{k+1}} \left\{ \max_{a_{k+1}} Q[f(s_k, u_k, a_k), u_{k+1}, a_{k+1}] \right\} p[u_{k+1} | f(s_k, u_k, a_k)] \quad (7)$$

式中: f 为过渡函数, 即 $s_{k+1} = f(s_k, u_k, a_k)$.

由此可知, 设置 s_k 和 u_k 为决策量, 则可获得最佳协方差.

3 仿真及实验分析

在 MATLAB 环境下, 模拟天津力神公司生产的 18650 型锂离子充放电过程, 仿真数据采用图 2 数据, SOC 真实的初始值为 1, 设定初始值为 0.9. 图 5 为平方根高阶容积卡尔曼滤波 (square-root unscented Kalman filter, SRUKF) 和深度强化学习卡尔曼滤波 (reinforcement learning Kalman filter, RLKF) SOC 估计曲线. 由图 5 可以看出: 两种方法都能较准确地跟踪锂离子电池 SOC 的设置值, 其中本文所提方法更接近 SOC 的设置值.




图 5 SOC 估计曲线
Fig. 5 SOC estimation curves

图 6 为两种方法对 SOC 估计误差的比较曲线.




图 6 SOC 估计误差比较曲线
Fig. 6 Comparative curves of SOC estimation errors

由图 6 可以看出: 平方根高阶容积卡尔曼滤波策略估计值与设定值的误差维持在 0.16 上下, 本文所

提方法估计值与设定值的误差保持在 0.14 左右, 误差较前一种方法小, 表明对锂离子电池的 SOC 估计精度较高, 进而证明深度强化学习卡尔曼滤波可以提升锂离子电池的 SOC 估计精度.

为了进一步验证所提方法的有效性, 本文通过设定工况 (采用美国联邦城市运行工况 (federal urban driving schedule, FUDS)) 对锂离子电池的充放电进行实验, 并对两种方法 (SRUKF 和 RLKF) 的估计结果进行了对比. 采用安时积分法获得锂离子电池 SOC 的实际值, 和仿真一样 SOC 真实的初始值设置为 1, 初始值设定为 0.9. 图 7 和图 8 分别为 SOC 估计比较曲线和 SOC 估计误差比较曲线.




图 7 FUDS 工况下 SOC 估计曲线
Fig. 7 SOC estimation curves of FUDS test




图 8 FUDS 工况下 SOC 估计误差比较曲线
Fig. 8 Comparative curves of SOC estimation errors in FUDS test

由图 7 可知: 两种方法均可快速准确地跟踪到锂离子电池 SOC 的设置值, 符合工程锂离子电池 SOC 的变化特性. 由图 8 可知: RLKF 算法对锂离子电池 SOC 估计精度更高, 且自适应能力更强. 在开始的 200 min 内, 估计值与真实值之间的差值基本保持在 0.14 以下; 在 200 min 之后, 误差值持续降低, 原因是 RLKF 具有在线修正 SOC 估计误差的特性. 反观 SRUKF 算法锂离子电池 SOC 估计误差曲线, 在有效的工况时间内, 其估计误差已超过了 0.16. 进一步验证了 RLKF 算法对锂离子电池 SOC 估计的有效性.

4 结 语

针对锂离子电池的荷电状态(state of charge, SOC)估算精度问题,结合传统的卡尔曼滤波算法和深度强化学习思想,论文提出了一种新的深度强化学习卡尔曼滤波锂离子电池SOC估计方法,并进行了仿真验证。仿真及实验结果表明,该估算方法在利用两种算法优点的基础上,通过贝叶斯规则可以确保系统的最佳协方差,有效降低了估算过程的计算量,进而提升SOC估算的精度,具有较好的实用性。

参考文献:

- [1] 沈佳妮,贺益君,马紫峰. 基于模型的锂离子电池SOC及SOH估计方法研究进展[J]. 化工学报, 2018, 69(1): 309-316.
- [2] Zhang Y, Xiong R, He H, et al. Lithium-ion battery pack state of charge and state of energy estimation algorithms using a hardware-in-the-loop validation[J]. IEEE Transactions on Power Electronics, 2017, 32(6): 4421-4431.
- [3] Yu Q, Xiong R, Lin C. Online estimation of state-of-charge based on the H infinity and unscented Kalman filters for lithium ion batteries[J]. Energy Procedia, 2017, 105: 2791-2796.
- [4] Hannan M A, Lipu M S H, Hussain A, et al. A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations[J]. Renewable and Sustainable Energy Reviews, 2017, 78: 834-854.
- [5] Jiang Z Y, Qu Z G, Zhou L, et al. A microscopic investigation of ion and electron transport in lithium-ion battery porous electrodes using the lattice Boltzmann method[J]. Applied Energy, 2017, 194: 530-539.
- [6] 葛云龙,陈自强. 基于STF&LM算法的串联锂离子电池组不一致性辨识与状态估计[J]. 中国电机工程学报, 2018, 38(14): 4271-4280.
- [7] 程泽,杨磊,孙幸勉. 基于自适应平方根无迹卡尔曼滤波算法的锂离子电池SOC和SOH估计[J]. 中国电机工程学报, 2018, 38(8): 2384-2394.
- [8] Wang S, Shang L, Li Z, et al. Online dynamic equalization adjustment of high-power lithium-ion battery packs based on the state of balance estimation[J]. Applied Energy, 2016, 166: 44-58.
- [9] Sun F, Xiong R, He H. A systematic state-of-charge estimation framework for multi-cell battery pack in electric vehicles using bias correction technique[J]. Applied Energy, 2016, 162: 1399-1409.
- [10] Zhang C, Jiang Y, Jiang J, et al. Study on battery pack consistency evolutions and equilibrium diagnosis for serial-connected lithium-ion batteries[J]. Applied Energy, 2017, 207: 510-519.
- [11] Kim M, Kim K, Kim J, et al. State of charge of Li-ion batteries based on reinforcement learning[J]. IFAC International Federation of Automatic Control, 2018, 51(28): 404-408.
- [12] Sbarufatti C, Corbetta M, Giglio M, et al. Adaptive prognosis of lithium-ion batteries based on the combination of particle filters and radial basis function neural networks[J]. Journal of Power Sources, 2017, 344: 128-140.
- [13] Dang X J, Yan L, Xu K, et al. Open-circuit voltage-based state of charge estimation of lithium-ion battery using dual neural network fusion battery model[J]. Electrochimica Acta, 2016, 188: 356-366.
- [14] 赵明,陈石, Yuen D. 基于深度学习卷积神经网络的地震波形自动分类与识别[J]. 地球物理学报, 2019, 62(1): 374-382.
- [15] 廖晓闽,严少虎,石嘉,等. 基于深度强化学习的蜂窝网资源分配算法[J]. 通信学报, 2019, 40(2): 11-18.

责任编辑: 郎婧