

DOI:10.13364/j.issn.1672-6510.20210297

## 基于双 DQN 和扩展卡尔曼滤波的锂离子电池 荷电状态估计

高洪森<sup>1</sup>, 王雪<sup>2</sup>, 魏宏博<sup>2</sup>, 游国栋<sup>2</sup>, 侯晓鑫<sup>2</sup>, 赵双乐<sup>2</sup>

(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:** 为了提高锂离子电池荷电状态(SOC)的估计精度,设计了一种基于双深度 Q 网络(双 DQN)和扩展卡尔曼滤波(EKF)的锂离子电池 SOC 估计算法. 选择锂离子电池二阶 RC 等效电路为研究对象,采用 EKF 算法重构了锂离子电池的离散系统数学模型;结合深度强化学习思想,构造了一种深度强化学习扩展卡尔曼滤波算法. 该算法设计了双 DQN,并对 EKF 参数进行优化. 仿真结果表明,与 DQN 扩展卡尔曼滤波算法相比,双 DQN 扩展卡尔曼滤波算法具有更好的收敛性、自适应能力以及估计精度.

**关键词:** 锂离子电池; 双 DQN; 荷电状态; 扩展卡尔曼滤波

中图分类号: TM912 文献标志码: A 文章编号: 1672-6510(2022)04-0049-06

## State of Charge Estimation of Li-ion Batteries Based on Double DQN and Extended Kalman Filters

GAO Hongsen<sup>1</sup>, WANG Xue<sup>2</sup>, WEI Hongbo<sup>2</sup>, YOU Guodong<sup>2</sup>, HOU Xiaoxin<sup>2</sup>, ZHAO Shuangle<sup>2</sup>

(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 accuracy of the state of charge(SOC) estimation of the Li-ion battery, a Li-ion batteries state of charge estimation algorithm based on double depth Q network(double DQN)and extended Kalman filters(EKF)is proposed in this article. The second-order RC equivalent circuit model was selected as the research object, state-space model of coefficient of variation of the Li-ion battery was structured by EKF algorithm. Moreover, combined with the idea of deep reinforcement learning, a reinforcement learning extended Kalman filters algorithm was structured, which designed a double DQN and optimized the EKF parameters. Compared with DQN extended Kalman filter algorithm, double DQN extended Kalman filters has better convergence, adaptive ability and better estimation accuracy through simulation.

**Key words:** Li-ion battery; double DQN; state of charge; extended Kalman filter

与铅酸电池以及碱性电池相比,锂离子电池具有能量密度高、自放电率低、无记忆效应以及热效应小等优点<sup>[1]</sup>. 但是,单节锂离子电池只能够产生 1.5 ~ 4.5 V 的输出电压,在实际应用中为了获得满足需求的输出电压,通常要把多个锂离子电池串联起来使用<sup>[2]</sup>. 在电池管理系统(BMS)中,荷电状态(state of charge, SOC)是一个用于表示电池状态的重要参数,它不仅给出电池组当前的剩余容量,而且能指示

电池组的可用寿命. 作为 BMS 的一个重要参数, SOC 一般用于评估电池的运行状态和健康状况<sup>[3]</sup>, SOC 的准确估计对锂离子电池的高效利用和能量管理具有重要意义.

卡尔曼滤波(Kalman filters, KF)算法是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,所以也可以把最优估计当作一个滤波

收稿日期: 2021-12-29; 修回日期: 2022-04-06

基金项目: 天津市科技支撑重点项目(17YFZCNC00230); 天津市自然科学基金重点资助项目(13JCZDJC29100)

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,教授, yougdong@sina.com

过程,卡尔曼滤波算法是一种常见的锂离子电池 SOC 估计算法<sup>[4-5]</sup>. 锂离子电池在工作时,其运行状态复杂而且容易受很多因素的干扰. 为了解决串联锂离子电池组不一致性的辨识与 SOC 估计等问题,葛云龙等<sup>[6]</sup>提出一种 STF&LM 算法,该算法能将各单体电池的 SOC、内阻估计误差控制在合理的范围内,从而更好地辨识电池组内电池的不一致性以及进行 SOC 的估计. 范文杰等<sup>[7]</sup>在分析锂离子电池二阶 RC 等效电路的基础上,采用电化学阻抗谱对锂离子电池的内部温度进行了估计,该方法提高了电池欧姆电阻和容量估计的精度. 上述算法大都把系统的噪声特性设置为已知的量,然而在系统运行时,它的过程噪声方差阵或观测噪声方差阵并不是已知的,并且还具有很强的不确定性和时变性,因此如果错误估计了参数,常常会造成滤波的发散.

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,可以直接根据输入图像进行输出控制,是一种更加接近人类思维方式的人工智能方法<sup>[8-10]</sup>. 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 SOC 估计算法,该方法的优点在于能够更加准确且灵活地估计锂离子电池的 SOC,缺点是更改参数存在困难. 文献[12]和文献[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,实验均验证了算法能够提高锂离子电池 SOC 估计的精度. 但是在上述算法中,初始学习参数的选择主要依靠经验,如果参数选择不当,很容易产生局部最优解. 廖晓闽等<sup>[14]</sup>构建了一种深度强化学习的蜂窝网资源分配算法,用于解决蜂窝网资源分配多目标优化问题. 作者通过 Q-learning 机制设计了误差函数,利用梯度下降法训练深度神经网络的权值,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,本文通过构建锂离子电池的二阶 RC 等效电路模型,建立了离散系统数学模型,设计了一种新的基于深度强化学习扩展卡尔曼滤波锂离子电池 SOC 估计算法. 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 SOC 空间模型,并利用扩展卡尔曼滤波(extended Kalman filter, EKF)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扩展卡尔曼滤波锂离子电池 SOC 估计算法,该算法设计了双深度 Q 网络(双 DQN, DDQN),并对 EKF 参数进行优化. 仿真结果表明该算法能够较好

地提高 SOC 的估计精度.

## 1 锂离子电池等效电路模型

针对锂离子电池 SOC 估计的模型主要有等效电路模型、电化学模型和人工神经网络模型. 相比后两者,前者能准确表达电池的动态特性,故本文选择锂离子电池二阶 RC 等效电路模型作为研究对象,锂离子电池二阶 RC 等效电路模型如图 1 所示. 二阶 RC 等效电路模型是由两组 RC 网络、串联的电阻器和电压源组成的电路. 图 1 中:  $U_t$  为输出端电压;  $U_{oc}$  为电池开路电压;  $R_c$  为电池欧姆电阻;  $I_c$  为电池的工作电流;  $R_1$ 、 $C_1$  分别为电池电化学极化电阻和极化电容;  $R_2$ 、 $C_2$  分别为电池浓度极化电阻和极化电容;  $U_1$  为  $R_1$ 、 $C_1$  的端电压;  $U_2$  为  $R_2$ 、 $C_2$  的端电压.




图 1 锂离子电池二阶 RC 等效电路模型

Fig. 1 Second-order RC equivalent circuit model of Li-ion battery

根据图 1 的二阶 RC 等效电路模型可得到电路的基本方程

$$\begin{cases} U_t = U_{oc} - U_1 - U_2 - I_c R_c \\ I_c = \frac{U_1}{R_1} + C_1 \frac{dU_1}{dt} = \frac{U_2}{R_2} + C_2 \frac{dU_2}{dt} \end{cases} \quad (1)$$

$$\begin{cases} \frac{dU_1}{dt} = -\frac{1}{C_1 R_1} U_1 + \frac{I_c}{C_1} \\ \frac{dU_2}{dt} = -\frac{1}{C_2 R_2} U_2 + \frac{I_c}{C_2} \end{cases} \quad (2)$$

根据美国先进电池联合会的定义, SOC 的计算公式为

$$\begin{cases} S(t) = S(t_0) - \frac{1}{C_N} \int_{t_0}^t \eta I_c(t) dt \\ \frac{dS}{dt} = \frac{I_c}{C_N} \end{cases} \quad (3)$$

式中:  $S$  为电池的 SOC;  $S(t)$  为  $t$  时刻的 SOC;  $S(t_0)$  为  $t_0$  时刻的 SOC;  $C_N$  为标称容量;  $\eta$  为库仑效率,即实际充电电流与实际电池电流之比.

$I_c > 0$  时, 电池正在进行放电;  $I_c < 0$  时, 电池正在

进行充电.

根据开路电压法, 可知等效电路模型中的开路电压与电池的 SOC 存在线性关系. 即

$$U_{oc} = f(S) \quad (4)$$

## 2 本文算法

### 2.1 基本知识

EKF 是在 KF 基础上, 将非线性环节线性化, 对状态方程和观测方程的系数矩阵进行泰勒级数展开, 并忽略或逼近二次及以上的高次项, 以此来解决非线性问题. 锂离子电池充放电是一种典型的非线性过程, 采用 EKF 对其二阶 RC 等效电路模型电气基本方程进行离散化, 得到

$$\begin{cases} \begin{bmatrix} U_{1,k} \\ U_{2,k} \\ S_k \end{bmatrix} = \begin{bmatrix} e^{-\frac{\Delta t}{R_1 C_1}} & 0 & 0 \\ 0 & e^{-\frac{\Delta t}{R_2 C_2}} & 0 \\ 0 & 0 & 1 \end{bmatrix} \times \begin{bmatrix} U_{1,k-1} \\ U_{2,k-1} \\ S_{k-1} \end{bmatrix} + \\ \begin{bmatrix} R_1 \left(1 - e^{-\frac{\Delta t}{R_1 C_1}}\right) \\ R_2 \left(1 - e^{-\frac{\Delta t}{R_2 C_2}}\right) \\ \eta \frac{\Delta t}{Q_1} \end{bmatrix} \times I_c(k) + \begin{bmatrix} 0 \\ 0 \\ w_k \end{bmatrix} \\ U_t(k) = U_{oc}(k) - R_c I_c(k) - U_{1,k} - U_{2,k} + v_k \end{cases} \quad (5)$$

式中:  $\Delta t$  为采样时间,  $Q_1$  为电池额定容量,  $w_k$  为系统噪声,  $v_k$  为观测噪声.

双 DQN 通过使用两个 Q 网络解决算法在学习过程中产生的过估计问题<sup>[14]</sup>. 双 DQN 利用当前 Q 网络  $Q(s_t, a_t, \theta)$  负责动作的选择, 利用目标 Q 网络  $Q'(s_t, a_t, \theta)$  负责计算目标 Q 值, 减少因为 Q 值的最大值计算带来的偏差所导致的值函数过估计问题, 关系如式 (6) 所示.

$$Q(s_t, a_t, \theta) \leftrightarrow \gamma + Q'[s_{t+1}, \arg \max_{a_{t+1}} Q(s_{t+1}, a_{t+1}, \theta)] \quad (6)$$

式中:  $a_t$  为当前 Q 网络选择的动作变量,  $s_t$  为当前 Q 网络的状态变量,  $\theta$  为当前 Q 网络的参数,  $\gamma$  为当前 Q 网络的折扣因子.

基于双 DQN 的目标 Q 值计算如下

$$Y_t^{\text{DDQN}} = r_{t+1} + \gamma Q \left[ s_{t+1}, \max_{a_{t+1}} Q(s_{t+1}, a_{t+1}, \theta), \theta \right] \quad (7)$$

式中:  $r_{t+1}$  为目标 Q 网络的奖励变量;  $\theta$  为目标 Q 网

络的参数.

### 2.2 运行流程

利用控制动作执行的实时情况, 对强化学习控制进行优化训练, 通过学习对 EKF 的参数进行持续优化. 为了避免学习陷入局部最优, 同时保证算法的收敛速度, 本文引入了贪婪策略 ( $\epsilon$ -policy). 在双 DQN 模块中, 通过在每次迭代中优化目标函数, 实现损失函数  $[Y_i - Q(s_i, a_i, \theta)]^2$  的最小化. 优化储能预测的 EKF 中参数的双 DQN 流程图如图 2 所示.

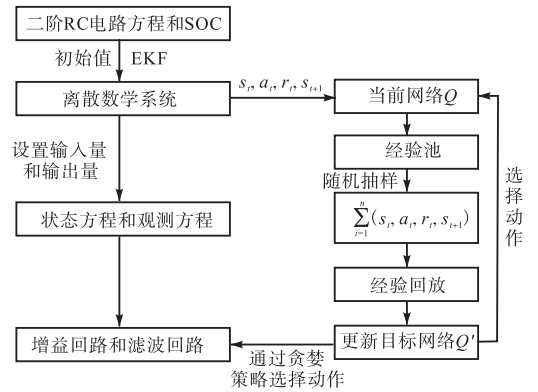


图 2 优化储能预测的 EKF 中参数的双 DQN 流程图  
Fig. 2 Double DQN flow chart for optimizing parameters in EKF for energy storage prediction

基于双 DQN 和 EKF 的锂离子电池 SOC 估计的运行流程由两部分组成, 分别为环境和智能体.

第一部分为环境, 它由等效电路模块和 EKF 模块组成. 首先, 构建锂离子电池二阶 RC 等效电路模型, 建立锂离子电池动态特性电气方程; 然后, 将电气方程离散化, 获得状态方程和观测方程; 最后, 代入 EKF 模块中, 进行循环迭代, 对锂离子电池的 SOC 进行估计. 作为环境, 需要为智能体提供状态变量  $s_t$ 、动作变量  $a_t$  和奖励变量  $r_t$ , 并且需要对它们的参数进行设置.

状态变量类型的选择对控制性能有重要影响. 为了防止训练后的深度神经网络陷入局部最优, 一般需要观察和训练的状态变量较少. 然而, 双 DQN 算法在缺少关键状态变量的情况下, 可能无法充分理解状态转换过程与环境之间的相互作用关系, 导致迭代和收敛困难. 因此, 选取等效电路模型的状态函数和 EKF 中导致 SOC 估计造成误差的函数作为状态变量, 即  $s_k = \{Q_k, R_k, x_k, P_k, U_t(k), U_{1,k}, U_{2,k}\}$ .

由于所研究的锂离子电池二阶 RC 等效电路已通过 EKF 转换为离散数学系统, 需要将动作离散化, 并且将离散化步长设置适中. 如果离散化步长过小,

则增加算法训练时间;如果离散化步长过大,会造成算法的局部最优. 根据假设, EKF 为双 DQN 模块提供 EKF 中的观测方差  $R$ , 动作参数为

Action = {increasing  $R$  10 times, increasing  $R$  5 times, maintaining  $R$ , decreasing  $R$  5 times, decreasing  $R$  10 times}

奖励函数用于评估给定状态下动作值的质量, 主要依赖于 SOC 的估计误差 ( $e_{soc}$ ), 其定义为

$$R_e = \frac{10}{|e_{soc}| + L_r} \quad (8)$$

式中:  $R_e$  表示奖励函数,  $L_r$  表示学习因子.

第二部分为智能体, 即双 DQN 模块, 它利用由 EKF 模块提供的状态  $s_t$ 、动作  $a_t$  和奖励  $r_t$ , 采用贪婪策略选择动作, 改变 EKF 中的观测方差  $R$ , 将产生的经验样本 ( $r_t, s_{t+1}$ ) 存储到经验池中, 然后每隔  $D$  步对随机抽取的经验样本进行经验回放, 更新网络参数. 该部分的核心是采用贪婪策略选择动作对 EKF 模块的参数进行优化, 随着迭代次数的增加, 动作的输出逐渐稳定, 奖励函数获得最优值. 该模块的算法框架如图 3 所示.

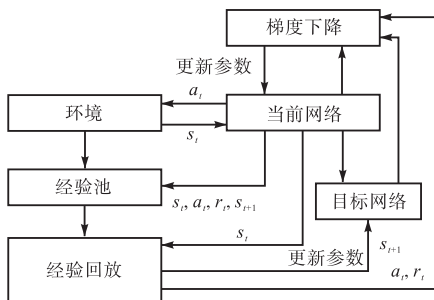


图3 双 DQN 模块的训练算法框架

Fig.3 Training algorithm framework of double DQN

根据仿真需求与人工经验对双 DQN 算法的超参数进行设置. 超参数是在算法开始学习过程之前设置的参数, 包括学习率  $\alpha$ 、折扣因子  $\gamma$ 、存储样本最大值  $N$ 、贪婪策略的初始概率  $\epsilon$  和经验回放大小  $n$ , 超参数设置见表 1.

表 1 双 DQN 算法的超参数设置

Tab.1 Super parameters setting of double DQN algorithm

超参数	数值
学习率 $\alpha$	0.001
折扣因子 $\gamma$	0.99
贪婪策略的初始概率 $\epsilon$	0.4
经验回放大小 $n$	500
存储样本最大值 $N$	1 000

### 3 仿真实验

#### 3.1 参数设置

##### 3.1.1 电池基本参数

文中选取的研究对象为天津力神电池股份有限公司生产的 18650EC 型锂离子电池, 该电池的额定容量为 1.3 A·h, 标称电压为 3.2 V, 充电截止电压为 3.6 V, 放电截止电压为 2.8 V.

##### 3.1.2 测量步骤

使用电池测量装置, 不断地进行充放电实验, 测量电池的开路电压, 测量时按照如下步骤进行操作:

第一步: 将待测电池测试环境的温度设定在常温 ( $20 \sim 25 \text{ }^\circ\text{C}$ ).

第二步:  $0.02 I_t$  ( $I_t$  为参考电流) 恒流充电至 3.6 V, 然后恒压充电, 至电流小于  $0.02 I_t$ , 静置 1 h. SOC 标记为 100%, 记录放电开路电压.

第三步:  $0.02 I_t$  恒流放电, 放电时间为 10 min, 静置 1 h. SOC 标记为 90%, 记录放电开路电压.

第四步: 重复第三步, 分别将电池的 SOC 标记为 80%、70%……10%、0.

第五步: 静置 1 h,  $0.02 I_t$  恒流充电, 操作过程与放电过程相同, 每次充电后静置 1 h, 记录充电开路电压.

##### 3.1.3 拟合 $U_{oc}-S$ 特性曲线

经过以上的测量步骤, 可以得到电池不同 SOC 时对应的开路电压, 拟合后得到的  $U_{oc}-S$  特性曲线如图 4 所示.




图4  $U_{oc}-S$  特性曲线

Fig.4  $U_{oc}-S$  characteristic curve

#### 3.2 仿真

基于 DQN 和双 DQN 算法的训练迭代中累计奖励的均值如图 5 所示. 在学习的初始阶段, 智能体更倾向于选择“探索”策略, 目的是找到更多有关环境的信息(即尝试各种控制动作), 导致累计奖励的均值



在相对较低的水平.随着训练迭代的进行,两种智能体都逐渐倾向于选择累计奖励较高的动作,即奖励函数值随着SOC的估计误差的减小而单调增加,最终趋于稳定.但由于探索的波动,累计奖励并不是严格连续递增的.与DQN相比,基于双DQN的策略在收敛速度上显示出更好的性能和更高的累计奖励的均值,表明双DQN可以同时产生更准确的价值估计和更好的策略.




图5 累计奖励的均值

Fig. 5 Average value of cumulative awards

基于EKF的锂离子电池SOC的估计误差观测图如图6所示.在仿真初始阶段,误差较小;但是,随着时间的推移,误差逐渐变大,最后逐渐变小,趋于平稳.基于EKF的锂离子电池SOC估计虽然具有较好的准确度,但是仍旧存在误差偏大和收敛时间较长的缺点.




图6 基于EKF的锂离子电池SOC的估计误差观测图

Fig. 6 Observation diagram of state of charge estimation error of Li-ion battery based on EKF parameters

基于DQN和双DQN算法优化EKF参数的锂离子电池SOC的估计误差观测图如图7所示.在仿真初期,基于DQN和双DQN算法的SOC的估计误差均偏大;但是随着迭代训练的增加,两者SOC的估计误差均逐渐变小.对比图5—图7可知,双DQN算法得到的锂离子电池SOC的估计误差比另外两种算法得到的要小,双DQN算法的性能高于另外两种算法.

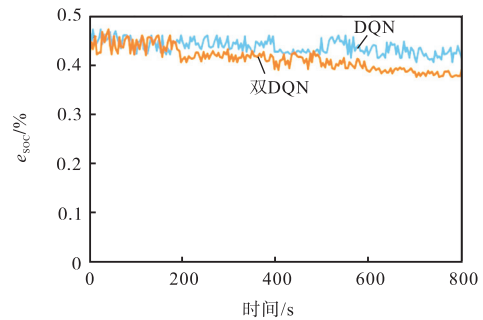


图7 基于DQN和双DQN算法优化EKF参数的锂离子电池SOC的估计误差观测图

Fig. 7 Observation diagram of state of charge estimation error of Li-ion battery based on DQN and double DQN algorithm to optimize EKF parameters

## 4 结 语

针对锂离子电池的SOC估计精度问题,结合传统的EKF算法和深度强化学习思想,设计一种新的双DQN扩展卡尔曼滤波锂离子电池SOC估计方法.该方法采用深度强化学习对EKF的参数进行优化,对原有的SOC估计方法进行改进,提高了SOC的估计性能.通过实验测试与数据拟合,构建锂离子电池开路电压与SOC特性曲线模型,设计关于优化储能预测的EKF中参数的双DQN的框架图,选择等效电路模型的状态函数和EKF中导致SOC估计产生误差的函数作为状态变量,对控制动作EKF中的观测方差进行改变,从而对SOC进行估计.仿真结果表明,该估计方法在利用两种算法优点的基础上,有效降低了估计过程的计算量,进而提升了SOC估计的精度,具有较好的实用性.

## 参考文献:

- [1] WANG Y J, TIAN J Q, SUN Z D, et al. A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems[J]. Renewable and sustainable energy reviews, 2020, 131: 110015.
- [2] WANG D F, HUANG H Q, TANG Z H, et al. A lithium-ion battery electrochemical-thermal model for a wide temperature range applications[J]. Electrochimica acta, 2020, 362: 137118.
- [3] HE L, HU M K, WEI Y J, et al. State of charge estimation by finite difference extended Kalman filter with HPPC parameters identification[J]. Science China technological sciences, 2020, 63 (3) : 410-421.

- [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] 范文杰, 徐广昊, 于泊宁, 等. 基于电化学阻抗谱的锂离子电池内部温度在线估计方法研究[J]. *中国电机工程学报*, 2021, 41(9): 3283–3293.
- [8] LI W H, FAN Y, RINGBECK F, et al. Electrochemical model-based state estimation for lithium-ion batteries with adaptive unscented Kalman filter[J]. *Journal of power sources*, 2020, 476: 228534.
- [9] TRAN M K, MEVAWALA A, PANCHAL S, et al. Effect of integrating the hysteresis component to the equivalent circuit model of lithium-ion battery for dynamic and non-dynamic applications[J]. *Journal of energy storage*, 2020, 32: 101785.
- [10] ZHANG C P, JIANG Y, JIANG J C, 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 estimation for lithium ion battery based on reinforcement learning[J]. *IFAC Papers on line*, 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] SHEN J N, SHEN J J, HE Y J, et al. Accurate state of charge estimation with model mismatch for Li-ion batteries: a joint moving horizon estimation approach[J]. *IEEE Transactions on power electronics*, 2018, 34(5): 4329–4342.
- [14] 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: 周建军

(上接第 48 页)

- Proceedings of the Seventh International Symposium on Instrumentation and Control Technology. Beijing: International Society for Optics and Photonics, 2008.
- [14] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. *计算机学报*, 2017, 40(6): 1229–1251.
- [15] 牛妞王洁, 程君霞, 程瑛璠, 等. 指静脉识别技术的应用前景研究[J]. *电脑知识与技术*, 2021, 17(12): 190–191.
- [16] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]//Proceedings of the 26th Annual Conference on Neural Information Processing Systems 2012. Nevada: NIPS, 2012.
- [17] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]//Proceedings of the 3rd International Conference on Learning Representations. San Diego: Computational and Biological Learning Society, 2015.
- [18] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City: IEEE, 2018: 4510–4520.
- [19] YIN Y L, LIU L L, SUN X W. SDUMLA-HMT: a multimodal biometric database[C]//Proceedings of the Chinese Conference on Biometric Recognition. Heidelberg: Springer, 2011: 260–268.
- [20] ASAARI M S M, SUANDI S A, ROSDI B A. Fusion of band limited phase only correlation and width centroid contour distance for finger based biometrics[J]. *Expert systems with applications*, 2014, 41(7): 3367–3382.
- [21] ZHOU J C, JIA X, SHEN L L, et al. Improved softmax loss for deep learning-based face and expression recognition[J]. *Cognitive computation and systems*, 2019, 1(4): 97–102.
- [22] ALAY N, AL-BAITY H H. Deep learning approach for multimodal biometric recognition system based on fusion of iris, face, and finger vein traits[J]. *Sensors*, 2020, 20(19): 5523.

责任编辑: 周建军