

基于 CNN-LSTM 的锂离子 SOC 估计

刘娟^{1,2}, 雷辉³, 吕金^{1,2}, 王洋⁴, 徐德树^{1,2}

(1. 天津电气科学研究院有限公司, 天津 300180; 2. 电气传动国家工程研究中心, 天津 300180; 3. 陕西龙门钢铁有限责任公司, 陕西 韩城 715400; 4. 天津天传电气传动有限公司, 天津 300301)

摘要: 电池荷电状态(SOC)是锂离子电池管理技术中最重要的参数之一, 高精度的SOC估计有利于储能电站的并网和控制。电池充放电数据不仅具有时序性, 特征变量之间也存在一定空间关系, 为提高估算方法的准确性和通用性, 提出一种基于CNN-LSTM联合网络结构的锂离子电池SOC估计方法, 先通过CNN特征提取获取了锂离子电池不同维度数据间的特征关系, 然后经过LSTM网络结构提取其中的时间序列关系, 联合网络充分获取了电池数据集的空间时间特性。实验结果表明, 基于CNN-LSTM联合网络模型预测电池SOC平均误差控制在0.65%, 较单独的CNN网络预测平均误差降低4.4%左右, 较单独的LSTM网络预测的平均误差降低0.2%左右, 具有较好的应用前景。

关键词: 锂离子电池; 电池荷电状态; 卷积神经网络; 长短期记忆网络

中图分类号: TM28 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqcd25099

SOC Estimation of Lithium-ion Batteries Based on CNN-LSTM

LIU Juan^{1,2}, LEI Hui³, LÜ Jin^{1,2}, WANG Yang⁴, Xu Deshu^{1,2}

(1. Tianjin Reseach Institute of Electric Science Co., Ltd., Tianjin 300180, China; 2. National Engineering Research Center of Electric Drive, Tianjin 300180, China; 3. Shaanxi Longmen Iron & Steel Co., Ltd., Hancheng 715400, Shaanxi, China; 4. Tianjin Tianchuan Electric Drive Co., Ltd., Tianjin 300301, China)

Abstract: The state of charge (SOC) of batteries is one of the most important parameters in lithium-ion battery management technology, and high-precision SOC estimation is beneficial for the grid connection and control of energy storage stations. Battery charge and discharge data are not only time-series in nature, but also have certain spatial relationships between feature variables. To improve the accuracy and generality of the estimation method, a SOC estimation method was proposed for lithium-ion batteries based on a joint convolutional neural networks-long short term memory networks (CNN-LSTM) network structure. Firstly, the feature relationships between different dimensions of lithium-ion battery data were obtained through CNN feature extraction, and then the time series relationships were extracted through the LSTM network structure. The joint network fully captures the spatial and temporal characteristics of the battery dataset. The experimental results show that the average error of predicting battery SOC based on the CNN-LSTM joint network model is controlled at 0.65%, which is about 4.4% lower than the average error predicted by a single CNN network and about 0.2% lower than the average error predicted by a single LSTM network. It has good application prospects.

Key words: lithium-ion battery; battery state of charge (SOC); convolutional neural networks (CNN); long short term memory networks (LSTM)

锂离子电池是储能领域中的研究热点, 作为能量单元, 锂离子电池的荷电状态 (state of charge, SOC) 估计非常关键, 其精度的提高会带来更好的使用效率^[1-2]。现在常用的SOC估计方法有: 安时积分法、开路电压法、卡尔曼滤波算

法、内阻法、深度学习法等。安时积分法应用中传感器的精度受各种因素的影响, 且随着传感器的使用年限, 最终的累计误差会逐渐增大^[3]。通过添加修正因子的方法可以解决初始值以及电池老化因素等问题^[4], 但是该方法的原始误差无

法进行修正,原始累计误差依旧无法得到解决。卡尔曼滤波算法可以较为准确地估计电池SOC。这种算法的弊端在于需要准确的等效电路模型。该方法基于对电池建立的模型,并且计算过程中含有大量的递推过程,在该过程中,会将系统噪声设定为高斯白噪声,但是实际上的系统噪声并不能得到,因此会导致一定的误差^[5-7]。

神经网络可以拟合非线性数据之间的关系^[8]。文献[9]使用神经网络通过输入电流和电压来估算电池SOC,为提高精确度在网络后增加无迹卡尔曼滤波。文献[10]使用遗传算法来提高SOC估计精确度。深度学习算法(RNN)中的循环神经网络也被证明可用于电池SOC估计。文献[11]使用RNN估算电池的荷电状态,最终实验表明循环神经网络对电池老化、非线性动态特性及参数的不确定性具有很好的鲁棒性。但需要注意的是,RNN会产生梯度消失以及梯度爆炸等^[12-13]。据此,文献[14]引入了长短期记忆网络(LSTM)估计锂电池SOC,网络适应不同温度条件下的预测,平均绝对误差(MAE)低至1.6%。卷积神经网络(CNN)由Lecun等人^[15]提出,它通过卷积和池化操作可以提取数据内部的隐藏特征,卷积神经网络通常用于处理二维图像数据,具备的强大的空间特征捕获能力使得研究者将其也应用在一维数据中^[16-20],例如SOC的估计等。实际中,锂电池SOC估计需要通过电压、电流、温度等参数进行推断^[21-22],当放电量比较大时,锂电池电压较低,只靠LSTM提取关键参数的时序关系不够全面,而CNN可以有效弥补LSTM的不足。

考虑到电池充放电数据不仅具有时序性,特征变量之间也存在一定空间关系,采取CNN-LSTM联合网络获得更好的拟合效果。实验结果表明,所提出网络相比单一的LSTM网络取得的效果更好,也更加稳定。此外,使用更丰富的数据集对网络进行训练,预测性能得以提升。

1 基于LSTM的电池SOC估计

1.1 LSTM网络结构

LSTM是RNN网络的一种变体,相比RNN它多了三个门结构用于判断是否要保存当前信息。其结构图如图1所示。

LSTM三个门的计算式和功能如下:

1)遗忘门用于选择是否丢失历史信息,网络

关系式为

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

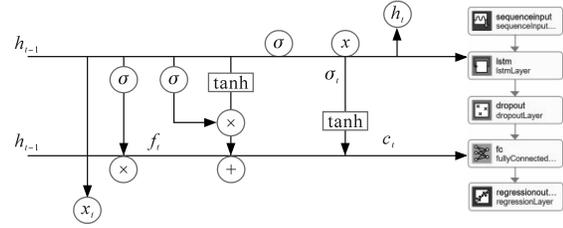


图1 LSTM结构图与设计图

Fig.1 LSTM structure and design drawings

式中: f_t 为遗忘门 t 时刻状态; W_f, b_f 分别为遗忘门的权值和偏置; h_{t-1} 为 $t-1$ 时刻隐藏层的信息; x_t 为 t 时刻的输入信息; σ 为激活函数,是sigmoid函数。

2)输入门用于选择性地更新信息状态,网络关系式如下所示:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$c'_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot c'_t \quad (4)$$

式中: i_t 为输入门 t 时刻状态; W_i, b_i 分别为输入门的权重和偏置; c'_t 为候选细胞状态; c_t 为 t 时刻细胞单元状态; c_{t-1} 为在 $t-1$ 时刻的细胞状态信息。

3)输出门根据当前状态判断是否输出信息,网络关系式如下所示:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (6)$$

式中: o_t 为 t 时刻输出门状态; W_o, b_o 分别为输出门的权重和偏置; h_t 为 t 时刻隐藏层的信息。

1.2 LSTM网络模型设计

网络模型的建立是很重要的一步,选择合适的网络可以加快网络结果的收敛,促使预测结构更加准确。LSTM网络在输入层重要的参数有输入数据维度以及时间步长,在训练时的重要参数有学习率和损失函数等。根据以上参数影响因素的实验,建立LSTM时将神经元个数定为300,同时使用Adam优化算法,选取学习率为0.025,批处理设置为10。表1为LSTM网络参数含义。

表1 LSTM网络参数含义

Tab.1 Meaning of LSTM network parameters

	名称	类型	激活	状态
1	sequenceinput	序列输入	6	-
2	lstm	LSTM	16	HiddenState: 16*1 CellState: 16*1
3	dropout50% 丢弃	丢弃	116	-
4	fc	全连接	11	-
5	regressionoutput	回归输出	11	-

电池SOC估计是一个非线性回归预测问

题,目标是预测值尽可能地贴近真实值,因此,LSTM网络的训练优化算法采用Adam算法,该算法可以动态跟随参数做出改变,适当调节学习率,从而能够降低内存需求,提高运算效率。但是,单一LSTM网络只能捕捉数据的时序关系,并未考虑到已知参数的空间特征。

2 基于CNN-LSTM的电池SOC估计

2.1 CNN网络结构

SOC估计要应用到电压、电流、温度等相关的一些参数,它们之间具有空间关系,仅仅使用LSTM网络是不满足要求的,加入CNN可以准确提取数据不同维度间的空间特征。图2是卷积神经网络结构简图。

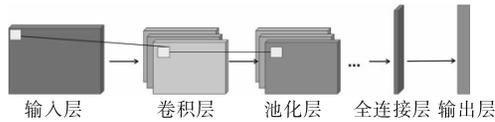


图2 CNN结构简图

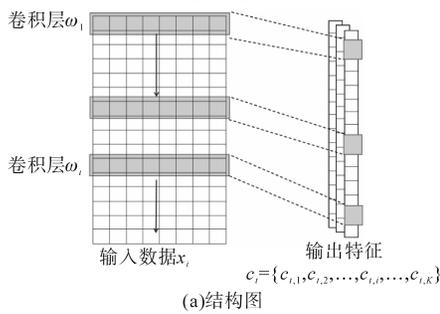
Fig.2 CNN structure diagram

图3是一维卷积神经网络结构与网络设计图,由于CNN在图像特征提取上有很好的效果,研究者们在此基础上提出用于处理时间序列数据的一维卷积神经网络。图中卷积核 $\omega_i \in R^{1 \times d}$ 作用在数据 $x_i \in R^{r \times d}$ 上会得到一个特征向量 $c_{i,j}$:

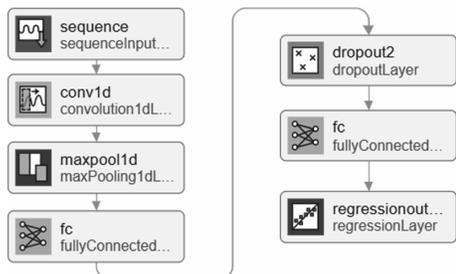
$$c_{i,j} = \omega_i \times x_i + b_i \quad (7)$$

式中: b_i 为偏置量。

用于将 K 个卷积核得到的特征向量进行组合得到输出特征: $c_i = \{c_{i,1}, c_{i,2}, \dots, c_{i,K}\} \in R^{r \times K}$ 。



(a)结构图



(b)网络设计图

图3 一维CNN结构图与网络设计图

Fig.3 One-dimensional CNN structure diagram and network design diagram

本文是对序列化数据进行卷积池化操作,所以在卷积层进行的是一维卷积,选用的卷积核是 1×1 大小,通道选择128,该卷积核可以起到升维的作用。 1×1 卷积核在改变维度的同时进行了通道间的信息交互,实现了跨通道间的信息传递。卷积池化层之后还有个dropout层,该层可以在网络训练过程中,将神经元按一定的比例从网络中丢弃,本文设置0.5,该过程可以使得每批数据都是在训练不同的网络,防止训练过拟合进而提高准确度。

2.2 CNN-LSTM原理与流程

卷积神经网络在图像特征提取领域表现非常优秀^[20]。本文将CNN和LSTM结合用于电池SOC估计。如图4所示,模型中显示通过一维的卷积神经网络提取到电池数据中的空间高级特征,而后进入到长短记忆网络作为它的输入。在LSTM网络中可以学习到特征之间的非线性关系和数据间的依赖性。这种网络结构兼顾了CNN能捕捉数据间的空间关系特性和LSTM的时间序列关系,图5为网络流程图与设计图。

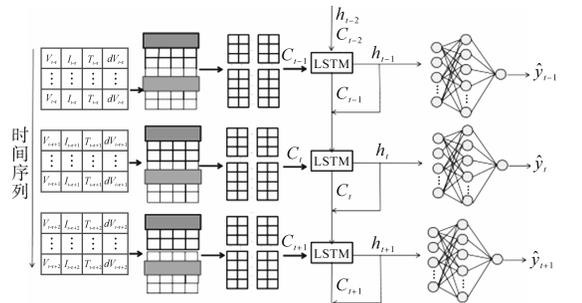


图4 CNN-LSTM结构图

Fig.4 CNN-LSTM structure diagram

如图5所示,先将训练数据输入到CNN网络中,一维卷积提取输入数据中的复杂空间特征。卷积神经网络可以接受输入数据的温度、电压、电流等数据。

CNN卷积层使用128个长度为3的滤波器,步长设置为 $b_{cnn}=1$,最大池化层PoolSize设置为2,步长设置为1。从输入层经过前向传播到卷积层输出后的向量 h_{cnn} :

$$h_{cnn} = \sigma(X_i \times W_{cnn} + b_{cnn}) \quad (8)$$

式中: X_i 为输入向量; W_{cnn} 为权重; b_{cnn} 为偏置量。

长短记忆网络位于循环神经网络之后,LSTM主要用于记忆由CNN经过卷积提取的SOC数据间的时间上的相关信息,通过在LSTM之前进行CNN卷积操作提前捕捉空间上的关联性。

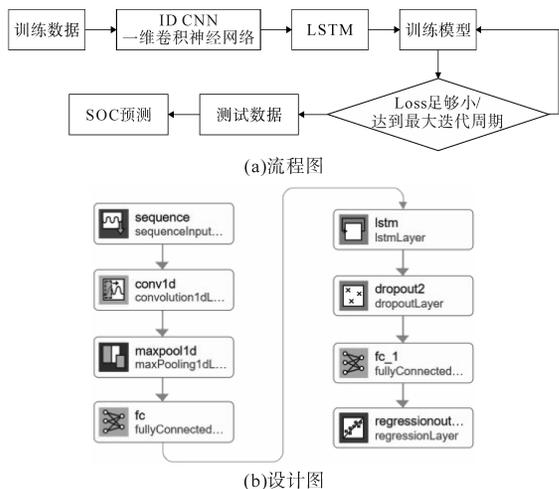


图5 CNN-LSTM网络流程图和设计图

Fig5 CNN-LSTM network flowchart and design diagram

3 实验分析和验证

3.1 实验环境及数据数据数据

3.1.1 实验环境

算法实现的平台基于 Matlab2021b。处理器使用的是锐龙 R5 2600x, 显卡是 GeForce GTX 1050ti。算法实现上, 在选好数据集后, 将数据集按照 8:2 的比例进行随机划分, 其中 80% 部分用于训练网络, 剩余 20% 用于测试和预测。

3.1.2 数据集的选取和数据处理

深度学习之所以能对非线性数据有着很好的识别和拟合效果, 其中更重要的是有海量数据做支撑, 在图像识别领域, 对海量数据提取特征, 最后得到的模型往往准确度很高。为了达到预期效果, 实验选用了两份数据集: 第一份数据集数据量较少, 对于性能较弱的设备较为友好; 第二份数据集基于美国马里兰大学公开数据集, 适用于设备条件较好的情况。在该数据集中, 由于数据信息较多, 部分数据对实验没有太大的影响, 为提高实验准确度, 将数据进行一定的处理, 保留其中重要的参数, 过滤掉无用信息, 提高训练速度。在实验开始前, 需要选取电池 SOC 最重要的影响因素, 实验数据是随机选取的不同温度的数据。这样做的好处是网络训练后得到的模型更具泛化性, 也能适应不同的应用场景。在数据预处理阶段需要将数据预设好一个区间, 从而满足权重分配的要求。

3.2 实验结果

分别使用单独的 CNN, LSTM 以及本文所提 CNN-LSTM 进行 SOC 预测, 预测结果如图 6、图 7

所示。

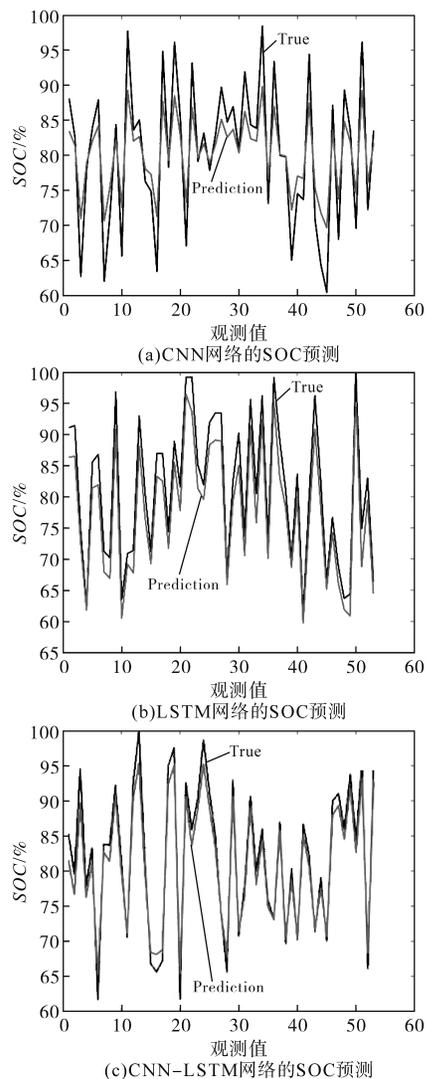


图6 基于数据集1的SOC预测图

Fig.6 SOC prediction graph based on dataset 1

分析上面的预测结果图, 为了更直观地对比, 选取了 RMSE (均方根误差)、MAE (平均绝对误差) 和 R 三个具有代表意义的评价指标。其中 R^2 越接近 1 说明模型准确度越高。在样本数量较少的情况下得到的评价指标表如表 2 所示, CNN-LSTM 网络结构相比单独的 CNN 和 LSTM 得到的预测精度要更高。从平均误差来看, 一维 CNN 训练后 SOC 预测平均误差高达 5%, 单独的 LSTM 预测 SOC 平均误差为 2.8%。而两者结合后得到的联合神经网络预测精度有明显提升, 平均误差降到 1.7%。相比较单独的 LSTM 网络预测结果, 其误差降低了近 40%。在样本数量增加到 30 000 条后得到的评价指标表如表 3 所示, 单独的 CNN 网络进行预测其平均误差仍然高达 5%, 而在数据量提升后, LSTM 网络结构进行预测其平均误

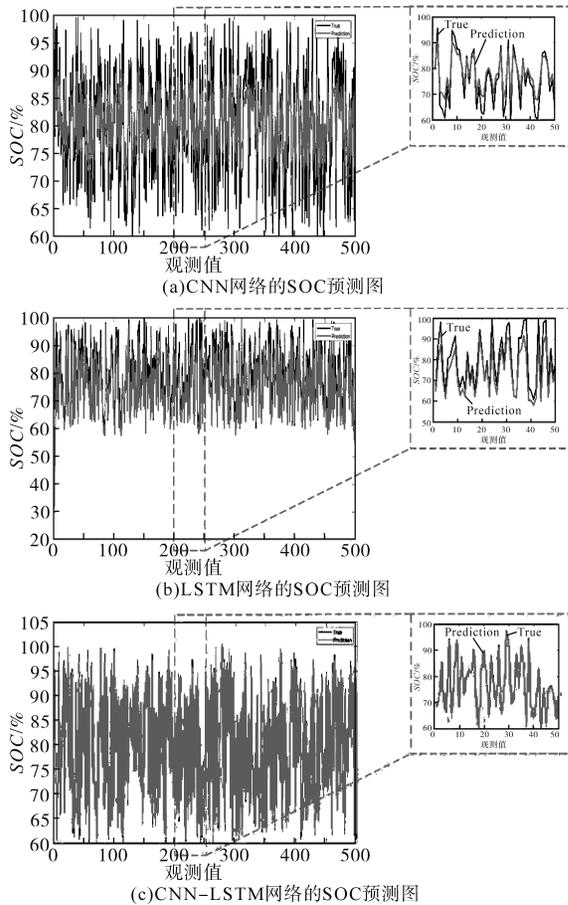


图7 基于数据集2的SOC预测

Fig7 SOC prediction graph based on dataset 2

差降到0.65%,而CNN-LSTM网络结构进行预测平均误差仅仅只有0.41%。

综合2份数据,共6轮实验结果,数据量的提升显著提高了LSTM和CNN-LSTM网络的预测精度。文献[23]中运用粒子群优化算法对长短时记忆神经网络的超参数进行调优,有效解决了手动寻优的时耗问题,PSO-LSTM估计均方根误差为0.295 0%,本文所提出的CNN-LSTM网络的预测精度相比单独的LSTM,以及PSO-LSTM估计SOC都有一定的提升。虽然CNN-LSTM联合增加了网络训练时间,但单个数据点的预测时间仍小于0.5 ms,因此可以满足实时估计,适用于车载电池管理系统,具有很好的应用价值。

表2 基于数据集1三种网络训练下的评价指标

Tab.2 Evaluation indicators under three types of network training based on dataset 1

	RMSE	MAE	R ²
CNN	0.050 9	0.042 2	0.025 9
LSTM	0.034 2	0.028 1	0.017 3
CNN-LSTM	0.025 9	0.021 7	0.835 3

表3 基于数据集2三种网络训练下的评价指标

Tab.3 Evaluation indicators under three types of network training based on dataset 2

	RMSE	MAE	R ²
CNN	0.058 9	0.050 6	0.730 8
LSTM	0.007 2	0.006 5	0.004 1
CNN-LSTM	0.004 9	0.004 1	0.998 2

4 结论

1) 针对LSTM网络存在的问题,考虑到不同维度数据之间可能存在一定的空间特征,由于CNN的体征提取能力比较强,在数据输入到LSTM网络之前先经过CNN的特征提取,将提取后的数据再经LSTM获取时序上的关系。实验最终结果显示网络预测效果在稳定性和误差上均小于单独的LSTM网络。

2) 使用大数据集与使用较小数据集训练的网络相比,预测误差效果有所提升。说明了丰富的数据有助于网络性能的改善,在大数据时代的背景下,所提出的网络有进一步提升效果的潜力。

3) 电池老化会导致电池内部化学物质活性降低,会导致电池特性发生改变,模型未考虑电池老化因素,未来将进一步完善模型。

参考文献

- [1] 吴建鑫,杨丽君,肖滢琳,等. 基于电流激励的储能电池电化学阻抗谱快速检测方法[J]. 电工技术学报, 2023, 38(21): 5889-5899.
WU Jianxin, YANG Lijun, XIAO Yanlin, et al. Fast detection method of electrochemical impedance spectroscopy for energy storage battery based on current excitation[J]. Transactions of China Electrotechnical Society, 2023, 38(21): 5889-5899.
- [2] 谢臻杰,林琼斌,詹银,等. 一种在线高精度车用锂电池SOC估计的方案研究[J]. 电气开关, 2022, 60(6): 36-40.
XIE Zhenjie, LIN Qiongbai, ZHAN Yin, et al. Research on an online high-precision vehicle lithium battery SOC estimation scheme[J]. Electric Switchgear, 2022, 60(6): 36-40.
- [3] CHEMALI E, KOLLMEYER P J, PREINDL M, et al. Long short-term memory networks for accurate state-of-charge estimation of li-ion batteries[J]. IEEE Transactions on Industrial Electronics, 2018, 65(8): 6730-6739.
- [4] 刘东,黄碧雄,王一全,等. 锂电池SOC拐点修正安时积分实时估算方法[J]. 储能科学与技术. 2019, 8(5): 850-855.
LIU Dong, HUANG Bixiong, WANG Yiquan, et al. Inflection point Ah-total integration method for real-time integration to correct lithium battery SOC[J]. Energy Storage Science and Technology, 2019, 8(5): 850-855.
- [5] 顾钟凡,陈玉伟,李承澳,等. 基于DFRLLS和神经网络-AS-

- RUKF算法的蓄电池SOC估计[J]. 电气传动, 2022, 52(17): 59-65, 80.
- GU Zhongfan, CHEN Yuwei, LI Cheng'ao, et al. SOC estimation of battery based on DFFRLS and neural network-ASRUKF algorithm[J]. Electric Drive, 2022, 52(17): 59-65, 80.
- [6] 段林超, 张旭刚, 张华, 等. 基于二阶近似扩展卡尔曼滤波算法的锂离子电池SOC估计[J]. 中国机械工程, 2023, 34(15): 1797-1804.
- DUAN Linchao, ZHANG Xugang, ZHANG Hua, et al. SOC estimation of lithium-ion battery based on second-order approximate extended kalman filter[J]. China Mechanical Engineering, 2023, 34(15): 1797-1804.
- [7] 王桥, 叶敏, 魏孟, 等. 基于ELM和MCCKF的锂离子电池SOC估计[J]. 工程科学学报, 2023, 45(6): 995-1002.
- WANG Qiao, YE Min, WEI Meng, et al. ELM and MCCKF based state of charge estimation for lithium-ion batteries[J]. Chinese Journal of Engineering, 2023, 45(6): 995-1002.
- [8] 黎冲, 王成辉, 王高, 等. 锂电池SOC估计的实现方法分析与性能对比[J]. 储能科学与技术, 2022, 11(10): 3328-3344.
- LI Chong, WANG Chenghui, WANG Gao, et al. Review on implementation method analysis and performance comparison of lithium battery state of charge estimation[J]. Energy Storage Science and Technology, 2022, 11(10): 3328-3344.
- [9] HE W, WILLIARD N, CHEN C, et al. State of charge estimation for Li-ion batteries using neuralnetwork modeling and unscented Kalman filter-based error cancellation. International Journal of Electrical Power and Energy Systems[J]. 2014, 62: 783-791.
- [10] 于仲安, 卢健, 王先敏. 基于GA-BP神经网络的锂离子电池SOC估计[J]. 电源技术, 2020, 44(3): 337-340.
- YU Zhong'an, LU Jian, WANG Xianmin. SOC estimation of Li-ion battery based on GA-BP neural network[J]. Journal of Power Supply, 2020, 44(3): 337-340.
- [11] CHAOUI H, IBE-EKEOCHA C C. State of charge and state of health estimation for lithium batteries using recurrent neural networks[J]. IEEE Transactions on Vehicular Technology, 2017, 66(10): 8773-8783.
- [12] RAI A, UPADHYAY S H. The use of MD-CUMSUM and NARX neural network for anticipating the remaining useful life of bearings[J]. Measurement, 2017, 111: 397-410.
- [13] 闫志远, 孙桓五, 刘世闯, 等. 一种基于GRU的氢燃料重卡汽车工况下锂离子电池温度预测模型[J/OL]. 中国电机工程学报: (2023-03-23)[2023-04-21]. <https://doi.org/10.13334/j.0258-8013.pcsee.221789>.
- YAN Zhiyuan, SUN Hengwu, LIU Shichuang, et al. A GRU based temperature prediction model of lithium-ion battery for hydrogen fuel heavy truck under operating conditions[J/OL]. Proceedings of the CSEE: (2023-03-23) [2023-04-21]. <https://doi.org/10.13334/j.0258-8013.pcsee.221789>.
- [14] CHEMALI E, KOLLMEYER P J, PREINDL M, et al. Long short-term memory networks for accurate state-of-charge estimation of li-ion batteries[J]. IEEE Transactions on Industrial Electronics, 2018, 65(8): 6730-6739.
- [15] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Processing of the IEEE, 1998, 86(11): 2278-2323.
- [16] 张娜, 包梓群, 罗源, 等. 基于改进 Cascade R-CNN算法在目标检测上的应用[J]. 电子学报, 2023, 51(4): 896-906.
- ZHANG Na, BAO Ziqun, LUO Yuan, et al. Application of improved cascade R-CNN algorithm in target detection[J]. Acta Electronica Sinica, 2023, 51(4): 896-906.
- [17] 贾俊青, 吕超, 刘丁华, 等. 适于深层次CNN的配电网过电压数据集建立方法[J]. 电气传动, 2022, 52(9): 57-62, 73.
- JIA Junqing, LÜ Chao, LIU Dinghua, et al. A method for establishing distribution network overvoltage data set for deep CNN [J]. Electric Drive, 2022, 52(9): 57-62, 73.
- [18] 蔡国庆, 刘玲, 张冲, 等. 基于GNN-LSTM-CNN网络的6G车辆轨迹预测算法[J]. 西安电子科技大学学报, 2013, 50(3): 50-60.
- CAI Guoqing, LIU Ling, ZHANG Chong, et al. Algorithm for prediction of the 6G vehicle trajectory based on the GNN-LSTM-CNN network[J]. Journal of Xidian University, 2013, 50(3): 50-60.
- [19] 吴进, 钱雪忠. 紧凑型深度卷积神经网络在图像识别中的应用[J]. 计算机科学与探索, 2019, 13(2): 275-284.
- WU Jin, QIAN Xuezhong. Compact deep convolutional neural network in image recognition[J]. Journal of Frontiers of Computer Science and Technology, 2019, 13(2): 275-284.
- [20] DONAHUE J, HENDRICKS L A, ROHRBACH M, et al. Long-term recurrent convolutional networks for visual recognition and description[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 677-691.
- [21] 刘志聪, 张彦会, 王君琦. 锂离子电池SOC估算技术进展综述[J]. 汽车零部件, 2022(12): 91-95.
- LIU Zhicong, ZHANG Yanhui, WANG Junqi. Review on SOC estimation techniques for lithium-ion battery[J]. Automobile Parts, 2022(12): 91-95.
- [22] 黄彦博, 冯忠楠, 随权, 等. 考虑实时SOC与动态循环效率的电池损耗评估及储能定容策略[J]. 太阳能学报, 2022, 43(11): 413-423.
- HUANG Yanbo, FENG Zhongnan, SUI Quan, et al. Battery loss assessment and energy storage capacity configuration strategy considering real-time SOC and dynamic cycling efficiency[J]. Acta Energetica Solaris Sinica, 2022, 43(11): 413-423.

收稿日期: 2023-04-21

修改稿日期: 2023-07-17