

基于改进型区间电池容量 计算与 GRU 结合的 SOH 预测

陈子标, 章忌, 方卫东

(福建理工大学 电子电气与物理学院, 福建 福州 350118)

摘要: 电动汽车的电池健康状态 (state of health, SOH) 监测系统对电池的回收和再利用具有重要意义。为了提高电动汽车电池的回收利用率、确保电池性能的最大化和安全性, 提出了一种改进的电池容量计算区间及相关特征提取方法。通过密度聚类、Z-score (标准分数) 和高斯滤波方法, 对电池 SOH 数据去噪和规范化处理。采用门控循环单元 (gated recurrent unit, GRU) 模型进行训练和测试。实验结果表明, SOH 预测的均方根误差在 3.5% 以内, 平均值误差在 2.5% 以内。该模型由于神经元个数较少, 预测速度较快, 对边缘部署有一定的参考价值。

关键词: 锂离子电池; 电动汽车; 门控循环单元; 边缘计算; 电池健康度

中图分类号: TM912.9

文献标志码: A

文章编号: 2097-3853(2025)01-0086-09

SOH prediction based on improved interval battery capacity calculation combined with GRU

CHEN Zibiao, ZHANG Ji, FANG Weidong

(School of Electronic, Electrical Engineering and Physics, Fujian University of Technology, Fuzhou 350118, China)

Abstract: The battery state of health (SOH) monitoring system of electric vehicles is important for the recovery and reuse of batteries. In order to improve the recycling rate of electric vehicle batteries and ensure the maximization of battery performance and safety, an improved battery capacity calculation interval and related feature extraction method are proposed. The battery SOH data are denoised and normalized by density clustering, Z-score (standard score) and Gaussian filtering methods. The gated recurrent unit (GRU) model is used for training and testing. Experimental results show that the root mean square error of SOH prediction is within 3.5% and the mean error is within 2.5%. This model is a good reference for edge deployment due to the smaller number of neurons and faster prediction speed.

Keywords: lithium-ion batteries; electric vehicles; gated recurrent unit (GRU); edge computing; battery health

目前, 电池健康状态 (SOH) 预测的主流方法可以分为基于模型的估计方法和基于数据驱动的估计方法^[1]。基于模型的估计方法依赖先验知识和领域专家的理论模型或假设, 对系统进行数学建模来估计^[2]。基于数据驱动的估计方法侧重于利用大量数据进行模式识别和预测, 通常依赖机器学习和统计学技术, 直接从数据中学习复

杂关系。

对于实际运行车辆, 每辆车运行环境、温度和湿度都不同, 难以使用建立模型的方法预测 SOH。在数据驱动方法中, 基于大量电池充放电数据提取电池老化特征和 SOH 参数的方法, 操作简便、短期估计精度高、泛化能力强^[3]。相关研究在近几年也取得了一些进展。文献[4]利用循

收稿日期: 2024-05-20

基金项目: 福州市科技计划项目 (2022-Q-009); 福建理工大学科研项目 (GY-Z20066)

第一作者简介: 陈子标 (1978—), 男, 广东肇庆人, 实验师, 研究方向: 嵌入式系统 (软硬件) 和汽车电子。

神经网络 (RNN) 提取电池电压曲线特征,输入支持向量回归模型得到容量估计,但存在梯度问题。文献[5]提出基于双向长短期记忆网络 (BiLSTM) 算法考虑容量、阻抗和温度进行 SOH 估计,但精度有待提高。文献[6]采用鲸鱼优化算法 (WOA) 优化长短期记忆网络 (LSTM) 进行 SOH 估计,数据集来源于 NASA 实验室,而非实时运行的车辆数据。

本研究采用改进型区间容量计算的方法获取每个充电周期的 SOH 值,通过对模型输入数据应用 3 种组合滤波方式进行去噪和规范化处理,可有效提升特征提取的准确性和稳定性。

1 数据分析

1.1 电池数据集

本研究采用的数据集来源于福建某汽车厂,电池数据重要字段如表 1 所示。分析接收到的每辆车的发现 1、3、4 号车的数据特性较好,SOH 的下降趋势比较大,故本研究基于这 3 辆车进行分析。记录 3 辆车 2023 年 10 月~2024 年 3 月共计 6 个月的数据,每辆车约有 155 万条数据。数据的采集时间间隔为 10 s/次,平均充电次数约 300 次。

表 1 电动汽车电池数据集重要字段
Tab.1 Important fields of electric vehicle battery dataset

变量名称	单位	变量名称	单位
数据时间	\	总电压	V
充电状态	\	总电流	A
累计里程	km	最高温度值	℃
SOC	%	最低温度值	℃

1.2 数据集问题

良好的数据特性和特征提取方法可以显著提升模型的训练效果。在收集的汽车厂数据中,常出现数据漏采、错采。所给的数据中,有的特征值缺失,在采集表格中呈现为非数字 (NAN) 或者无穷大 (INF),但其占比只有 0.5%,对数据的整体影响不大,故直接将缺失的特征值数据删除。

1.3 数据特征提取

为了减小数据处理的负担,本研究只提取比较有用的数据字段作为特征提取对象。包括充电

状态、SOC (当前剩余电量)、总电压、总电流、最高温度值。为有效评判每个充放电周期的 SOH,将从一次充电过程的起始点至随后一次充电过程起始点之间的时间段界定为一个充放电周期。

恒压充电时间和恒流充电时间是衡量电池健康状态的重要指标^[7],本研究以恒压充电时间和恒流充电时间作为重点特征。恒压充电期间,电压保持稳定,电流逐渐减小,以避免过充。恒流充电期间电流保持不变,电池快速吸收电能。若恒流充电的时间长度下降,说明电池的健康度下降。充电过程的电流变化如图 1(b) 所示,横轴表示时间,每个时间点代表一个采样点 10 s,在大约 950 s 前是恒流充电过程,电流恒定不变。从图 1(a) 所示的充电过程电压变化图,可以看到开始阶段的电压变化率很大,1 000~3 000 s 阶段的变化相对较小,可以看作恒压充电过程。

为了从一段变化的充电过程曲线中获取恒流充电和恒压充电的时长,使用求导方式获取恒流充电时长。

$$L_c = \sum_{n=S_c}^E \left(S \left\| \frac{i_n - i_{n-1}}{\Delta t} \right\| \leq C \right) \quad (1)$$

式中, S 为采样时间, C 为波动范围,其值为 0.1^[8]。 i_n 、 i_{n-1} 分别表示 n 时刻和 $n-1$ 时刻电流 Δt 为 n 时刻和 $n-1$ 时刻时间差。 L_c 则是恒流时间的求和结果, S_c 表示满足条件 C 的列表开始索引, E 则是不满足条件 C 的列表结束索引。式(1)要求当且仅当充电电流波动小于波动范围且时间连续,才能作为充电时长累加条件。

通过式(1)在一个充电周期中得到多段 L_c ,将 L_c 中最大值作为一个充电周期的恒流充电时长 ($L_c^{\max}$)。

$$L_c^{\max} = \max(L_{c_1}, L_{c_2}, \dots, L_{c_m}) \quad (2)$$

如图 1(c) 所示,恒压充电过程电压不断波动。为了减少波动的影响,对波动段的数据使用滑动窗口的最大值滤波法滤波,根据滤波效果,最终确定滤波窗口长度为 9。滤波效果如图 1(d) 所示。从图中可见波动的部分基本都被去除。


在恒压充电时长的提取中,需要确定恒压充电数据序列的起始位置。首先设置步长为 7 的滑动窗口 l_w ,在窗口滑动过程中,依次将窗口最右侧的一个数据取出并记录其位置 N_p ,组成一个新序列 N_s ,并对其处理,如式(3)。

$$L_{vf} = \sum \frac{v_n - v_{n-1}}{l_w} \quad (n = 2, 3, \dots, N) \quad (3)$$


式中, v 为 N_s 中的电压值。 L_{vf} 为差值序列。

在 L_{vf} 中, 将连续且相同的数据分为一段, 从分段中找到最小值所在的最长一段数据 $l_{\max}$ 。

通过 $l_{\max}$ 起始位置和终止位置 N_p 定位恒压



(a) 充电电压




(c) 充电电压波动


充电时长数据段。利用式(4)求恒压充电时长。

$$L_v = \sum_{n=S_p}^{N=E} \left(S \left| \frac{v_n - v_{n-1}}{\Delta t} \right| \leq C \right) \quad (4)$$

式中, v_n 、 v_{n-1} 分别表示 n 时刻和 $n-1$ 时刻电压, S_p 数据序列起始位置, L_v 则是以 S_p 为起始位置的恒压时间求和结果。



(b) 充电电流



(d) 滑动窗口滤波后

图 1 单周期充电电压和电流图

Fig.1 Single-cycle charging voltage and current diagram

温度特征和平均电流特征提取的方法都是在一个充放电周期中求平均值获得。放电深度特征则是在充电周期中求其极差所得。

2 数据处理

2.1 改进型区间容量计算

电池 SOH 是衡量电池使用寿命的一种方式。它代表当前电池健康状况与出厂电池健康状况的比值^[9]。传统的 SOH 衡量一般使用容量或阻抗来定义。本研究也基于容量的方式来衡量 SOH, 其公式可以表示为:

$$SOH = \frac{C_{\text{aged}}}{C_{\text{fresh}}} \times 100\% \quad (5)$$

式中, C_{aged} 表示当前容量状况, C_{fresh} 表示出厂容量状况。

车厂提供的数据中, 没有电池容量字段。在每一次充放电周期中, 放电深度也不是 100%, 所以充电的起始和终止电池剩余电量(SOC)也不是固定的。综合两种情况, 提出一种区间容量计算方式, 计算一定 SOC 区间内的电池容量, 可表示为:

$$C_n(\tau) = \frac{\int_{t_1}^{t_2} I(t) dt}{SOC_2 - SOC_1} \quad (6)$$

式中, t_1 和 t_2 分别代表充电区间的起始和结束时刻。SOC₁、SOC₂ 分别为 t_1 、 t_2 时刻的电池电量剩余百分比。

由于存在错误数据, 通过充电状态属性判断充电区间的方法, 会将一个充电区间分为多个区间, 如图 2 所示。图中充电状态为 1 表示车辆在充电,

用充电状态来划分充电 SOC,会将这次充电数据分为 11 段,而从 SOC 的变化图中可以看出这实际上是 4 段充电区间,如图 2 所示,矩形框部分表示正确划分的结果。所以本研究对区间容量计算进行改进,为了去除充电状态图中较为尖锐的部分,使用充电状态宽度检测法,设置一个长度 L 为 12 的检测宽度,依次读取数据的充电状态。若检测到充电状态有变化,则从变化的位置开始连续读取 L 长度的充电状态数据 C_w ,若 C_w 中的数据一致时,则确定为新充电状态,否则,充电状态将与上一个充电状态保持一致。该方法提升了充电区间划分的准确性。

2.2 数据滤波

通过充电状态宽度检测法得到一个如图 3(a) 所示的 SOH 数据(图中数据都经过归一化处理)。

由图 3 可见,数据的离散点很多,也看不出数据的整体趋势,需要去除离散点和平滑处理。




图 2 充电区间划分
Fig.2 Charging interval division




图 3 电池健康度数据滤波
Fig.3 Battery health data filtering

本研究使用密度聚类和 Z-score 两种方法滤波。密度聚类去除较为分散的点,领域半径为 120,最小领域点数为 3。去除效果如图 3(b) 所示,密度聚类并不能完全去除离散点。为了进一步过滤离散点,根据数据的正太分布情况,用 Z-score 方法去

除距离均值较远的数据,效果如图 3(c) 所示,随着充电次数增加,电池 SOH 变化趋势逐渐呈现出下降趋势。然而,数据较为发散,通过最小二乘法拟合得到的直线下降幅度并不大。因此,在前面滤波基础上加入高斯滤波方法,滤除高频部分,使得整

体曲线更加平滑,进而使 SOH 的下降趋势更为明显,具体的效果如图 3(d) 所示。为了得到更好效果,Z-score 方法和高斯滤波参数最好联调。高斯核函数使用的是正太分布函数,高斯核大小设置为 7,高斯标准差设置为 4;Z-score 方法的上下限分别为 2.5 和 1.8。

3 GRU 模型结构

选择网络模型要充分考虑模型使用环境和车辆数据特性,车辆的 SOH 下降是多种因素导致的。首先,电池的充放电次数和强度都会影响其健康状况,频繁的高强度使用可能导致 SOH 下降。其次,环境因素,如温度、湿度等可能影响电池的 SOH。此外,电池的制造过程和材料质量也可能导致 SOH 下降。最后,电池管理系统的算法和精度也会影响到 SOH。所以 SOH 的变化曲线是一条与车辆所处环境有关的波动曲线,其数据的变化与数据的上下文有关。在一个电池生命周期中,电池 SOH 值与车之前所处的环境、驾驶员的充电习惯都有关系,属于典型的长期依赖特点。尽管大多数时间序列预测都使用 LSTM 模型,但若数据特征选取合适,相同神经元个数的门控循环单元(GRU)和 LSTM 相比,预测均方根误差要比 LSTM 小,计算量比 LSTM 更小,模型也更小,更适合部署在边缘设备上,所以本研究使用 GRU 作为预测模型。

GRU 神经元结构如图 4 所示,主要由两个门构成:更新门 Z_t 和重置门 R_t 。这两个门由当前的输入和前一时刻的隐藏状态共同决定,通过 sigmoid 函数将其值限制在 0 和 1 之间,表示信息通过的程度。更新门决定何时更新过去的隐藏状态,选择性保留长期信息;重置门控制过去的隐藏状态在当前时间步的重要性,捕捉序列中的短期依赖关系。每个时间步(序列处理中的单个步骤或阶段),GRU 先计算更新门和重置门的值,然后基于这两个门的值计算新的记忆内容。新的记忆内容是当前输入和重置门调整过的过去隐藏状态的函数。GRU 整合了 LSTM 中的遗忘门和输出门,形成了更新门 Z_t ,并将网络记忆集成到隐藏状态的输出中。图 4 中, σ 和 $\tanh$ 是模型的激活函数, X_t 为当前时刻输入数据, h_{t-1} 、 h_t 分别为系统前一时刻状态、系统当前时刻状态。




图 4 GRU 模型结构
Fig.4 GRU model structure

4 结果与分析

4.1 特征选择

为了解决皮尔逊系数对异常值敏感和灰色关联度主观性强、数据量需求大等问题,本研究综合灰色关联度和皮尔逊系数法进行数据特征相关性分析,可在一定程度上减少分析的主观性和增强鲁棒性,提升分析的深度和广度^[10]。实验模型特征从可测量的间接参数入手,通过第 2 章节的方法提取特征,利用式(7)得出相关性。

$$R=k\times\text{GRA}+(1-k)\mid\text{PCR}\mid \tag{7}$$

式中, GRA 和 PCR 表示灰色关联度和皮尔逊相关系数计算结果。 k 表示喜好权重,设为 0.4。 R 表示最终相关度。

在近年的 SOH 预测的相关文献中,常用的模型输入特征包括电流、电压、温度、恒压充电时间、恒流充电时间和起始电压等。结合车厂的数据特点,选取 5 种特征属性做特征相关性分析,分析结果如表 2 所示。从中选取两次特征系数都大于 0.300 的特征作为模型的输入特征,包括:放电深度、平均温度、恒流时间和恒压时间。

表 2 特征相关系数

特征	特征系数		
	1 号车	3 号车	4 号车
平均电流	0.254	0.333	0.279
放电深度	0.388	0.359	0.346
平均温度	0.308	0.326	0.361
恒流时间	0.338	0.331	0.318
恒压时间	0.299	0.359	0.301

由于数据变化的复杂性,在选取的特征中不加入上一轮的计算结果会导致模型的预测偏差大,如图 5 所示。所以也将上一轮运算出的 SOH 作为特征输入,以提高模型预测的准确度。




图 5 SOH 预测曲线
Fig.5 SOH prediction curves

4.2 评估指标

评估模型的常见指标包括平均绝对误差 (MAE)和根均方误差(RMSE)。由于输出的比较数据差异较小,本研究在评估指标中加入决定系数 (R^2)作为额外的评估指标进行对比分析。

$$R^2 = 1 - \frac{\sum_i (y_i - p_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (8)$$

式中, p_i 为预测值, y_i 为实际值, $\bar{y}$ 为真实值均值。当 R^2 接近 1 时,说明模型解释数据变动能力强,拟合效果好。

4.3 模型参数

为了检验模型的泛化能力,使用 1 号车作为训练数据,3 号车和 4 号车分别作为测试数据。在训练过程中,为了减小模型过拟合,当连续 10 个 epoch 小于 0.001 即可停止训练。训练过程中的损失函数如图 6 所示。在超参数的选取上,使用控制变量法将参数带入模型,以模型输出的 RMSE 最小值所对应的模型参数作为最终参数。要确定的参数有:神经元数量、激活函数、优化器、输入时间步长和提前预测周期。

如图 7 所示,神经元数量为 100 时,模型的 RMSE 降至 0.1 以下,随着神经元数量的进一步增加,曲线趋于平缓。因此,最终确定神经元数量为 128 个。本研究的 SOH 数值范围为 0~1,选择 Sigmoid 作为激活函数,其输出范围适配于 SOH 的区间。实验结果显示,使用 Sigmoid 激活函数的 GRU




图 6 Loss 曲线
Fig.6 Loss curve




图 7 RMSE 曲线
Fig.7 RMSE curve

模型在预测电池 SOH 时,RMSE 为0.033 4,比使用其他激活函数的模型低 3.6%左右。优化器选择了 Adam,实验验证表明,使用 Adam 优化器的模型收敛速度比 SGD 快约 10%,RMSE 低约 3%。将时间步长 1~15 分别输入模型进行预测,结果表明,当时间步长为 11 时,模型的 RMSE 最低,为 0.023 6。随着提前预测周期的增加,RMSE 也随之增大。当提前预测周期为 1 时,RMSE 最小,为 0.023 5。

综上,最终确定的神经元数量为 128,激活函数为 Sigmoid,优化器为 Adam,输入时间步长为 11,提前预测周期为 1。

4.4 消融实验

为了排除在研究所提滤波方法可能对模型的预测起副作用的情况,设计针对滤波方案可能组合的消融实验。从密度聚类、Z-score 方法和高斯滤波 3 种方法中选择任意组合测试。分析数据经过每一种组合方法后在 GRU 中预测结果的 RMSE、MAE 和 R^2 ,结果如表 3 所示。

表 3 中, M_1 、 M_2 和 M_3 分别对应密度聚类、Z-score 和高斯滤波方法, M_0 表示数据仅归一化, M_1+

M_2+M_3 为本实验方法。由表可见, M_2 方法的 RMSE 比较接近本研究所提方法, MAE 指标已经超过了所提方法, 但其 R^2 却是为负数, 说明该方法应对数据变动性的能力较差。在 RMSE、MAE、 R^2 中, 最差的组合是 M_1 、 M_1+M_2 , 这两种方案只是将数据离散点去除, 未将数据滤波, 噪声点较大, 模型捕捉数据规律不准确。汽车运行在复杂环境下, 其数据主要的特点就是噪声水平高、离散性大, 因此, 处理数据时要用降噪和平滑滤波方式, 不然预测误差较大。综合表 3 的参数, 本研究所提方案组合最佳。

表 3 滤波方法消融实验结果

Tab.3 Experimental results of ablation by filtering method

滤波方法	RMSE	MAE	R^2
M_1	0.189 8	0.147 3	-0.008 7
M_2	0.031 6	0.019 1	-1.118 6
M_3	0.074 4	0.043 2	-0.071 3
M_1+M_2	0.169 8	0.134 6	-0.028 0
M_1+M_3	0.062 2	0.027 4	0.118 8
M_2+M_3	0.047 2	0.030 8	-0.013 9
M_0	0.057 7	0.025 3	-0.101 6
$M_1+M_2+M_3$	0.023 9	0.018 9	0.460 5

4.4 模型评估

模型对比了 BP、BiLSTM 和 LSTM 模型, 表 4 的评价指标表明, GRU 的 MAE 不超过 2.5%, RMSE 不超过 3.5%, R^2 总能保持在 0~1, 有一定的数据变动能力。从表 4 中可以看出, LSTM、BiLSTM 的预测能力是比较接近 GRU, 说明其对时序序列的预测能力较强, 但对有长期依赖数据的预测能力不如 GRU。BP 网络的 R^2 值都在 -1 000 以下, 说明其不能捕捉时序数据的规律特性, 不能用来预测时序数据。综上, GRU 明显优于其他模型。

在图 8 中, 实线表示真实 SOH 数据的波动, 点划线表示 GRU 模型的预测结果, 其余线段为其它模型的预测结果。图 8(a) 和图 8(b) 中, 用 1 号车训练好的模型分别预测 3、4 号车的电池 SOH 数据, 从图中看出 GRU 的预测值更接近原始特征计算的电池 SOH 结果。在图 8(c) 和图 8(d) 中,

测试和训练数据都是来自同一辆车, 与同一幅图的其它模型相比, GRU 模型预测更准确。

表 4 各算法评价指标对比

Tab.4 Comparison of evaluation indexes of each algorithm

型号	模型	评价指标		
		MAE	RMSE	R^2
1 号车	LSTM	0.022 4	0.027 5	0.268 7
	BP	0.045 5	0.072 9	-1 736
	BiLSTM	0.023 3	0.029 2	0.176 5
	GRU	0.019 4	0.023 9	0.451 2
3 号车	LSTM	0.025 1	0.033 1	-0.136 5
	BP	0.050 5	0.084 6	-2 296
	BiLSTM	0.025 0	0.032 5	-0.094 3
	GRU	0.021 3	0.027 9	0.191 2
4 号车	LSTM	0.030 3	0.041 0	0.311 9
	BP	0.055 1	0.075 9	-1 068
	BiLSTM	0.031 3	0.043 1	0.239 3
	GRU	0.022 4	0.033 4	0.542 9

由于从车厂获得的数据仅覆盖了 6 个月, 无法观察到完整的 SOH 变化趋势, 再加上其 SOH 是通过计算得出的。为了证实模型的可行性, 使用西安交通大学实验室数据集对模型测试。该数据集由两个标称值为 27 Ah 的锂电池包组成, 电池包在 1C 充电速率下充电至 4.2 V, 之后保持恒压充电, 当充电电流降低到电池额定容量的 0.1 倍时, 停止充电。两个电池包分别进行 100 次充电实验。此数据集采集的特征有: 电压(V), 电流(A), 充电电容量(Ah), 测量时间(s)和能量(Wh)。为了适应数据特征, 仅提取恒压充电时长、恒流充电时长和充电电容量预测电池 SOH, 保持其他模型参数不变。电池 SOH 以充满电时的充电电容量替代。电池包 1 训练数据, 电池包 2 预测数据。预测结果见图 9, 数据归一化。80 次充电后电池容量约 25 Ah。训练 MAE 为 0.008 4, RMSE 为 0.010 6, R^2 为 0.997 1。从预测结果上看, 由于数据的变化较为简单, 预测效果比上述预测效果好。侧面证实了该模型对于实际的 SOH 预测有一定的应用意义。




图 8 各模型预测对比
Fig.8 Comparison of model predictions




图 9 西安交通大学数据预测结果
Fig.9 Prediction results of data from Xi'an Jiaotong University

使用 Jetson Nano P3450 的硬件环境测试模型,测试的方式是将预测模型移植到该硬件平台上,建立一个 WebSocket 通信在网页端实时显示预测结果。测试结果表明,CPU 的平均占用率达到 28.3%,模型的平均预测时长为 1.4 s,网页端能实时接收到模型预测数据并绘制成折线

图。该模型具有轻量级的特性,适合部署在边缘设备上。

5 结论

本研究提出的改进型区间电池容量计算以及相关特征的提取方法,能够使得特征提取的过程中有一定的数据容错性,即便充电时电池数据的小段数据错误也对最终的特征提取结果影响不大。由于提取出的电池 SOH 中存在噪声以及数据规律不明显问题,本研究先后采用了密度聚类、Z-score 和高斯滤波的方法将 SOH 数据去噪以及规范化处理。利用 GRU 模型进行训练和测试实验的结果表明,该方法能有效预测电动汽车电池 SOH,相对于 LSTM、BiLSTM 等模型,本研究所使用的 GRU 模型的矩阵参数量较少,预测速度更快,更有利于边缘计算的部署。然而,本研究使用的车辆数据只有 6 个月,尚无法体现出电池 SOH 整个生命周期。

参考文献:

- [1] LIU C, WANG Y J, CHEN Z H. Degradation model and cycle life prediction for lithium-ion battery used in hybrid energy storage system[J]. Energy, 2019,166:796–806.
- [2] 陈琳,陈静,王惠民,等. 基于小波包能量熵的电池剩余寿命预测[J]. 电工技术学报,2020,35(8):1827–1835.
- [3] 郑永飞,文怀兴,韩昉,等. 基于电池外特征的粒子群神经网络电池健康状态预测[J]. 科学技术与工程,2019,19(36):184–189.
- [4] 郭邦军,李家琦,马小乐,等. 基于深度学习的动力锂离子电池容量估计[J]. 电池,2022,52(5):517–521.
- [5] 张浩,胡昌华,杜党波,等. 多状态影响下基于 Bi-LSTM 网络的锂电池剩余寿命预测方法[J]. 电子学报,2022,50(3):619–624.
- [6] 郝可青,吕志刚,邸若海,等. 基于鲸鱼算法优化长短时记忆神经网络的锂电池剩余寿命预测[J]. 科学技术与工程,2022,22(29):12900–12908.
- [7] 方斯顿,刘龙真,孔赖强,等. 基于双向长短期记忆网络含间接健康指标的锂电池 SOH 估计[J]. 电力系统自动化,2024,48(04):160–168.
- [8] 李峥,张泽恒,杨斌,等. 混合钳位式感应电能传输系统抗偏移恒流–恒压充电研究[J/OL]. 中国电机工程学报,1–10 [2024-05-20]. <https://doi.org/10.13334/j.0258-8013.pcsee.231898>.
- [9] PRADHAN S K, CHAKRABORTY B. Battery management strategies: an essential review for battery state of health monitoring techniques[J]. Journal of Energy Storage, 2022, 51: 104427.
- [10] TRITHAM C, LEKAWAT L, ARRAYANGKOOL A, et al. A comparison between correlation and grey relational for big data and analytics [C]//2018 International Electrical Engineering Congress. Krabi: IEEE, 2018, pp. 1–4.

(责任编辑:方素华)

(上接第 85 页)

- [4] 张立伟,李行,宋佩佩,等. 基于新型滑模观测器的永磁同步电机无传感器矢量控制系统[J]. 电工技术学报,2019,34(S1):70–78.
- [5] 鲁文其,胡育文,杜栩杨,等. 永磁同步电机新型滑模观测器无传感器矢量控制调速系统[J]. 中国电机工程学报,2010,30(33):78–83.
- [6] 孙庆国,朱晓磊,牛峰,等. 基于改进型积分滑模观测器的 PMSM 无位置传感器控制[J]. 中国电机工程学报,2024,44(8):3269–3278.
- [7] LIANG D L, LI J, QU R H, et al. Adaptive second-order sliding-mode observer for PMSM sensorless control considering VSI nonlinearity[J]. IEEE Transactions on Power Electronics, 2018, 33(10):8994–9004.
- [8] 王孝洪,连维钊,翟名扬. 基于改进型滑模观测器的永磁同步电机无位置传感器控制[J]. 控制理论与应用,2023,40(7):1243–1251.
- [9] FAN Y, ZHANG L, CHENG M, et al. Sensorless SVPWM–FADTC of a new flux-modulated permanent-magnet wheel motor based on a wide-speed sliding mode observer[J]. IEEE Transactions on Industrial Electronics, 2015, 62(5):3143–3151.
- [10] AN Q T, ZHANG J Q, AN Q, et al. Frequency-adaptive complex-coefficient filter-based enhanced sliding mode observer for sensorless control of permanent magnet synchronous motor drives[J]. IEEE Transactions on Industry Applications, 2020, 56(1):335–343.
- [11] JIANG T, NI R, GU S, et al. A study on position estimation error in sensorless control of PMSM based on back EMF observation method[C]//24th International Conference on Electrical Machines and Systems (ICEMS). Gyeongju: IEEE, 2021: 1999–2003.
- [12] 李宁,郝成,姚征,等. 改进滑模观测器的永磁同步电机无传感器控制[J]. 组合机床与自动化加工技术,2023(3):82–85,90.
- [13] 赵希梅,孙洪潇,金鸿雁. 永磁直线伺服系统终端互补滑模位置控制[J]. 电机与控制学报,2023,27(6):182–190.
- [14] 李长明,王传奎,魏利胜,等. 基于卡尔曼滤波的永磁同步电机转子位置估算方法研究[J]. 绥化学院学报,2019,39(9):143–147.
- [15] 康尔良,陈健. 永磁同步电机改进滑模无位置传感器控制[J]. 电机与控制学报,2022,26(10):88–97.

(责任编辑:方素华)