DOI: 10.3901/JME.2021.20.161

功率需求驱动的电动载运装备用动力电池 充放电能力预测方法*

熊 瑞 闫良基 王 隼
(北京理工大学机械与车辆学院 北京 100081)

摘要: 充放电功率能力的准确评估是动力电池及电动载运装备安全、高效运行的基础。针对电动载运装备,建立以输入/输出功率为控制目标的动力电池模型,描述功率需求驱动的动力电池充放电行为;通过动态优化电池截止电压,提出多步功率预测方法,建立动力电池恒功率需求时的充放电能力预测策略;考虑荷电状态、温度、持续时间等的影响,采用长短期记忆神经网络建立功率修正模型,提升了动力电池充放电功率能力预测性能。结果表明,多步功率预测法能兼顾预测精度和计算效率,最大误差小于3%;全电量区间和宽温度范围内应用效果表明:采用功率修正的功率预测最大误差小于3%,均方根误差低于1%。

关键词: 电动载运装备; 动力电池; 充放电能力; 多步预测法; 长短期记忆神经网络; 功率修正
中图分类号: TM912

Power Demand-driven Battery Charging and Discharging Capability Prediction Method for Electric Vehicles

XIONG Rui YAN Liangji WANG Ju
(School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100081)

Abstract: The accurate evaluation of charging and discharging power capability is the basis of safe and efficient operation of the batteries and electric vehicles. Aims at electric transport equipment, the main works are as follow. A battery model with input/output power as the control target is established, and the charging and discharging behaviour of battery-driven by power demand is described. A multi-step power prediction method has been proposed through setting a fixed charge-discharge cut-off control voltage to a dynamic control objective, and the detailed prediction strategy for the charging and discharging power capacity has been established. Considering the influence of the state of charge, temperature, and duration, etc, the power update model is established with the long- and short-term memory neural network to improve the prediction performance of battery charge and discharge power capability. The results show that the proposed method can take into account the prediction accuracy and calculation efficiency, and the maximum error is less than 3%; the power correction method can reasonably predict the power capacity under the full state of charge range, wide temperature, and long duration. The error is less than 3%, and the root mean square error is less than 1%.

Key words: electric vehicles; battery; charge and discharge capacity; multi-step prediction method; long and short-term memory neural network; power correction

0 前言

“碳中和”和“碳达峰”攻坚目标驱动载运装备

全面深度电动化,充放电能力亦或功率状态(State-of-power, SOP)水平的实时精准预测是动力电池系统替代内燃机、全面装配载运装备的基础^[1]。动力电池作为电动载运装备的能量源,其产业规模迅速扩张。SOP是动力电池的综合能力,无法精确测试,常以截止电压或其他指标为终止条件对一个时间段的充放电峰值功率进行预测, SOP用来反映

* 国家自然科学基金优秀青年基金资助项目(51922006)。20210112收到初稿,20210507收到修改稿

当前的功率水平, 评估该动力电池系统是否满足载运装备的加速和爬坡需求, 以及能否发挥能量回收潜力^[2]。然而, 载运装备的行驶工况复杂, 充放电能力受荷电状态(State-of-charge, SOC)、温度、寿命、输出功率持续时间等影响, 预测难度大。保守预测方法难以充分发挥动力电池充放电能力, 影响电动载运装备的动力性、经济性和安全性; 激进预测会导致过充、过放等现象^[3], 诱发严重的安全事故。

当前, 主要有三类功率测试/计算/预测方法: 查表法, (等效电路)模型法和机器学习法: ① **查表法**通过功率能力和电池参数、状态之间的映射关系实现预测, 通常使用 SOC 和温度建立映射关系。GB/T 38661—2020 文件^[4]附录 D 提出一套 SOP 测试方法, 获得不同温度的 SOC-持续时间-功率关系。北京航空航天大学金鑫娜^[5]使用以容量和温度为变量的峰值功率二维表预测 SOP。五菱汽车李燕斌^[6]介绍了三种不同模式下, 由温度、SOC 两个变量决定的功率 MAP 表。② **模型法**通过动力电池的等效电路模型预测 SOP。美国科罗拉多大学 Plett 教授^[7]提出了系列模型、电压和 SOC 约束法, 北京交通大学张彩萍^[8]开展了预测方法性能的比较分析, 她指出 SOC 约束法方法简单, 适用于两端 SOC 处, 常与其他方法结合使用。北京理工大学孙逢春院士、熊瑞教授团队^[9-11]提出了基于模型的多约束动态峰值功率预测方法, 在线更新模型参数的方法, 保障了预测算法的实时性和精准性。极限功率会引起电池温度急剧升高, 改变电池的性能^[12-13]。为此, 山东大学王春雨等^[14-16]将温度约束引入预测, 提升了热安全性。③ **机器学习法**则是通过机器学习算法建立功率预测模型。北京交通大学孙丙香^[17]和郑方丹^[18]分别采用自适应神经模糊推理系统和支持向量机预测峰值功率, 平均误差分别在 10% 及 3.65% 以内。

查表法具有操作简单, 容易实现的优点。但受控制器存储量的制约, 一般只能考虑 SOC 和温度两个因素, 忽略了持续时间等其他因素。机器学习法有着较高的预测精度, 但需要大量的数据作为支撑。模型法基于恒流的假设, 设置电压、电流、SOC、温度等约束, 求得各约束共同作用下的峰值电流, 将其与过程中某一时刻的电压的乘积作为峰值功率, 是最普遍的解决思路。但是, 当载运装备处于功率需求驱动时, 模型法预测结果会遇到三类挑战: ① 持续恒功率需求受限于模型电压误差引起预测不稳定, 甚至偏差较大, 电压的长时间预测能力有待增强; ② 在 SOC 中间段, 模型预测值过于激进, 容易超出安全约束, 潜在加速电池老化和其他安全

隐患; ③ 基于恒电流需求的控制目标, 受电压变化影响, 预测的充放电功率非恒定值, 而是随电压变化的动态结果。载运装备工作中存在多类恒功率输入/出需求^[19-20], 电流随电压变化无法保持恒定。恒流假设的充放电能力预测难以保障动力电池及载运装备需求, 甚至诱发安全事故。因此, 面向功率需求驱动的动力电池充放电能力预测具有十分重要的研究意义。

本文首先建立以功率为输入/出的动力电池模型, 建立了模型电压在恒功率工作时的表达, 并搭建电量-温度-模型参数表, 精准描述功率需求驱动的动力电池充放电行为。然后, 以动态化确定的截止控制电压为作为终止条件, 提出了多步功率预测法, 确定了功率需求驱动的动力电池充放电能力。进一步考虑 SOC、温度、持续时间等对充放电能力的影响, 使用长短期记忆(Long short-term memory, LSTM)神经网络算法搭建功率修正模型。最后, 通过测试数据, 验证了所提方法在全电量区间、宽温度范围、长持续时间的预测效果。

1 动力电池建模

1.1 以功率为控制目标的电池模型

动力电池模型是功率能力预测的基础。Thevenin 模型结构简单, 具有较高的电压预测精度和较少的计算量, 广泛用于动力电池的建模及状态估计领域^[21], 其电路原理如图 1 所示。

图 1 Thevenin 模型结构

该模型由开路电压(Open circuit voltage, OCV)、欧姆内阻 R_i 、极化内阻 R_D 和极化电容 C_D 组成, 其离散化控制方程为

$$\begin{cases} U_{D,k} = U_{D,k-1} \exp\left(\frac{-\Delta t}{\tau}\right) + R_D \left(1 - \exp\left(\frac{-\Delta t}{\tau}\right)\right) I_k \\ U_k = OCV - R_i I_k - U_{D,k} \end{cases} \quad (1)$$

式中, U_k 、 $U_{D,k}$ 、 I_k 分别是端电压、极化电压和电流;

Δt 是采样间隔; τ 是时间常数, $\tau = R_D \times C_D$ 。

为实现功率需求驱动的动力电池充放电能力预测, 本文将输入/输出功率引入到模型中, 使其作为的控制目标。设电池从 k 时刻以恒功率 P 开始充放电。若已知 k 时刻的模型参数、端电压、极化电压, 则可通过电功率公式, 由 k 时刻的电压表达 $k+x \times \Delta t$ 时刻的电流。进一步, 可获得 $k+x \times \Delta t$ 时刻的极化电压、端电压。逐步推导模型的电流、极化电压和端电压, 实现动力电池恒功率工作时的仿真, 流程见表 1。

表 1 以功率为输入/出的动力电池模型

初始化参数: OCV, R_1 , R_D , τ , P	
递推过程: $x=1, 2, \dots$	
$k+x \times \Delta t$ 时刻的电流	$I_{k+(x-1) \times \Delta t} = \frac{P}{U_{k+(x-1) \times \Delta t}} \quad (2)$
$k+x \times \Delta t$ 时刻的极化电压	$U_{D,k+x \times \Delta t} = U_{D,k+(x-1) \times \Delta t} \exp\left(\frac{-\Delta t}{\tau}\right) + R_D \left(1 - \exp\left(\frac{-\Delta t}{\tau}\right)\right) \frac{P}{U_{k+(x-1) \times \Delta t}} \quad (3)$
$k+x \times \Delta t$ 时刻的端电压	$U_{k+x \times \Delta t} = \text{OCV} - \frac{P}{U_{k+(x-1) \times \Delta t}} R_1 - U_{D,k+x \times \Delta t} \quad (4)$

已知 k 时刻的模型参数、端电压、极化电压, 在恒功率工作中没有新的变量进入到模型, 则 $k+x \times \Delta t$ 时刻的模型端电压只与功率值 P 有关。

1.2 模型参数标定

搭建如图 2 所示的动力电池测试台架, 包括充放电测试设备、可控式温度箱、可编程的上位机等。其中, 充放电测试设备用于对电池进行充放电, 恒温箱用于控制电池的环境温度, 上位机用于控制充放电测试设备的工作模式, 并记录测试数据。

图 2 动力电池测试台架

以一款参数如表 2 所示的动力电池作为研究对象, 采用图 3 的流程进行测试。其中, 容量测试能够获取电池的最大可用容量; HPPC-OCV 测试选择

90%、80%、...、10%等 9 个 SOC 点, 获得电池在不同 SOC 下的动态特性, 从而建立 SOC-温度-模型参数的映射关系; 动态工况测试选择美国城市循环工况 (Urban Dynamometer Driving Schedule, UDDS); 功率能力测试选择 HPPC-OCV 测试得到的 9 个 SOC 点, 采用恒定功率脉冲对动力电池进行充放电, 每段脉冲的持续时间为 60 s, 恒定功率值为 200 W, 获取电池在一定条件下的充放电能力。图 4 为 25 °C 的功率能力测试。

表 2 动力电池参数表

项目	动力电池参数
材料体系	磷酸铁锂
标称容量/(A·h)	50
标称电压/V	3.2
截止电压/V	2.5/3.65
充放电最大电流/A	100/150

图 3 动力电池测试流程

图 4 功率能力测试

使用遗传算法 (Genetic algorithm, GA) 辨识 5 °C、25 °C、45 °C 的 HPPC-OCV 数据, 获得不同温度、SOC 点下的开路电压 OCV、欧姆内阻 R_1 、极化内阻 R_D 和时间常数 τ , 通过拟合构建动力电池的电量-温度-模型参数表, 见图 5。

图 5 电量-温度-模型参数表

2 功率需求驱动的多步功率预测法

传统的模型法以电池手册中设定的充放电截止电压作为重要的终止条件,将预测的峰值功率视为 SOP。考虑到 SOP 的实际应用,本文将预测方法的终止条件设置为动态的目标电压(包含截止电压在内),以更好地管理电池。

电动载运装备实际使用中,存在大量恒功率输入/出的需求,动力电池 SOP 测试也是以恒功率的形式进行^[4]。设恒功率工作的初始时刻为 k 、持续时间为 $x \times \Delta t$,则 $k+x \times \Delta t$ 时刻为终止时刻,其电压为电池管理系统设置的目标电压。其中, x 为恒功率工作阶段模型的递推步数,每一步的持续时间为 Δt ,即将整个阶段 x 等分。此时,认为算法从初始时刻经过 x 步递推至持续时间后的目标电压。在已知 k 时刻的模型参数、端电压、极化电压的情况下,根据模型电压在终止时刻的 x 步表达式,便可计算出恒功率工作阶段的功率值 P 。后文以恒功率输入/出的持续时间是 60 s 为例,介绍多步功率预测法。

步数 $x=1$ 时,步长 $\Delta t=60$ s。 $k+1 \times \Delta t$ 时的动态电压

$$U_{k+\Delta t} = \text{OCV} - \frac{P}{U_k} R_i - U_{D,k} \exp\left(\frac{-\Delta t}{\tau}\right) - R_D \left(1 - \exp\left(\frac{-\Delta t}{\tau}\right)\right) \frac{P}{U_k} \quad (5)$$

则有关于功率值 P 的一元一次方程为

$$P = U_k \times \frac{\text{OCV} - U_{k+\Delta t} - U_{D,k} \exp\left(\frac{-\Delta t}{\tau}\right)}{R_i + R_D \left(1 - \exp\left(\frac{-\Delta t}{\tau}\right)\right)} \quad (6)$$

步数 $x=1$ 时,多步功率预测法视整个过程的电流为定值,方法退化为恒流需求驱动的功率预测法。

步数 $x=2$ 时,步长 $\Delta t=30$ s。 $k+2 \times \Delta t$ 时的动态电压为

$$U_{k+2 \times \Delta t} = \text{OCV} - \frac{P}{U_k} \times \left[R_i + R_D \left(1 - \exp\left(\frac{-\Delta t}{\tau}\right)\right) \right] - \frac{P}{U_k} \exp\left(\frac{-\Delta t}{\tau}\right) + R_D \left(1 - \exp\left(\frac{-\Delta t}{\tau}\right)\right) \frac{P}{U_k} \exp\left(\frac{-\Delta t}{\tau}\right) \quad (7)$$

则有关于功率值 P 的一元二次方程

$$\frac{R_D}{U_k^2} \exp\left(\frac{-\Delta t}{\tau}\right) \left(1 - \exp\left(\frac{-\Delta t}{\tau}\right)\right) (R_i + R_D \left(1 - \exp\left(\frac{-\Delta t}{\tau}\right)\right)) P^2 - \left[\frac{R_D \left(1 - \exp\left(\frac{-\Delta t}{\tau}\right)\right)}{U_k} \exp\left(\frac{-\Delta t}{\tau}\right) + \frac{R_i + R_D \left(1 - \exp\left(\frac{-\Delta t}{\tau}\right)\right)}{U_k} \right] P + \text{OCV} - U_{k+\Delta t} - U_{D,k} \exp\left(\frac{-\Delta t}{\tau}\right) = 0$$

$$\begin{aligned}
 & \left(\text{OCV} \left(1 + \exp \left(-\frac{\Delta t}{\tau} \right) \right) - 2U_{D,k} \exp \left(-\frac{\Delta t}{\tau} \right)^2 - \right. \\
 & \quad \left. U_{k+2 \times \Delta t} + U_k \right) + \\
 & R_1 \left[\frac{\text{OCV} - U_{k+2 \times \Delta t} - U_{D,k} \exp \left(-\frac{\Delta t}{\tau} \right)^2}{U_k} + 1 \right] P + \\
 & \left(\text{OCV} - U_{k+2 \times \Delta t} - U_{D,k} \exp \left(-\frac{\Delta t}{\tau} \right)^2 \right) \times \\
 & \left(\text{OCV} - U_{D,k} \exp \left(-\frac{\Delta t}{\tau} \right) \right) = 0 \quad (8)
 \end{aligned}$$

步数 $x=2$ 时, 多步功率预测法将整个过程分割成两段数值不同的恒流段。同样, 当步数 $x>2$ 时, 也能通过终止时刻模型电压的 x 步表达, 得到关于功率值 P 的一元 x 次方程, 从而使用动态目标终止电压预测动力电池的充放电能力。

步数 x 越大, 方法将恒功率段分割的越多, 预测精度越高, 但随之出现计算复杂、运算量大的问题。因此选择合适的步数, 适当拓宽每步的步长, 即增大每步的持续时间, 可以兼顾预测精度和运算量, 加快计算速度。

3 功率需求驱动功率修正法

动力电池充放电能力的预测效果依赖于模型、参数及预测方法的准确性^[22]。模型误差、参数误差和预测方法误差共同影响预测结果。将动力电池复杂的电化学反应简化为电路元件, 这导致模型误差的产生; 动力电池不一致性及参数的时变导致了参数误差的产生; 多步功率预测法将恒功率输入/出需求阶段分割成若干恒流段来处理, 不可避免地引入预测误差。为了能更准确地预测动力电池在恒功率输入/出需求驱动时的充放电能力, 本文在多步功率预测法的步数 $x=2$ 的基础上, 利用 LSTM 神经网络搭建功率修正模型, 降低上述误差对预测效果的影响^[23]。修正方法为

$$P_a = P_{x=2} + \Delta P \quad (9)$$

式中, P_a 是功率修正值; $P_{x=2}$ 是两步功率预测法预测的功率值; ΔP 是功率修正量, 由修正模型输出, 以 SOC、温度、持续时间、终止电压和多步功率预测法的预测值作为输入。

LSTM 由于能更好地发现长期依赖关系而被广泛应用于处理长时间序列的信息^[24]。因此, 可以使

用 LSTM 搭建动力电池的功率修正模型。LSTM 的每个细胞由三种门结构组成, 分别是输入门、遗忘门、输出门, 由一个 σ 函数和矩阵点乘实现, 如图 6 所示。其中, σ 函数输出 0-1 之间的数字, 代表每个信息通过门限的程度, 0 表示拒绝一切信息通过, 1 表示允许一切信息通过。 $\tanh$ 是双曲线正切激活函数。

图 6 LSTM 细胞结构

设 t 时刻输入门、遗忘门、输出门和细胞状态分别是 i_t 、 f_t 、 o_t 和 c_t , 权值矩阵分别是 W_i 、 W_f 、 W_o 和 W_c , 偏置分别是 b_i 、 b_f 、 b_o 和 b_c , 其正向传播流程见表 3。

表 3 LSTM 正向传播流程

计算输入门 i_t 的输出
$i_t = \sigma(W_i h_{t-1} + W_{i_x} x_t + b_i)$
计算遗忘门 f_t 的激活值
$f_t = \sigma(W_f h_{t-1} + W_{f_x} x_t + b_f)$
计算细胞状态 c_t
$c_t = f_t c_{t-1} + i_t \tanh(W_c h_{t-1} + W_{c_x} x_t + b_c)$
计算输出门 o_t 的输出
$o_t = \sigma(W_o h_{t-1} + W_{o_x} x_t + b_o)$
计算输出信号
$h_t = o_t \tanh(c_t)$

基于 LSTM 的功率修正模型由输入层、隐藏层、输出层组成, 框架如图 7 所示。输入层的输入数据包含 5 个特征(SOC、温度、持续时间、终止电压和多步功率预测法的预测值); 隐藏层将上一时刻的信息以记忆流的形式正向传播, 包含 200 个细胞。其中, SOC 由 Ah 积分法确定; 输出层则输出 $x=2$ 的多步功率预测法的功率修正量。适应性动量估计

(Adaptive moment estimation, ADAM)算法通过计算梯度的一阶矩估计和二阶矩估计来自动调整学习速率,简单易实现,计算效率高^[25],用来训练模型。

图7 基于LSTM的功率修正框架

本文使用 Dropout 技术来增强功率修正模型的泛化能力。Dropout 在模型训练时随机使一定比例的隐含节点暂时丢失,这些节点对应的权值在这次训练中就不会更新,防止模型过拟合^[26]。为拓宽模型的数据支撑,以动力电池在 3 个温度、9 个 SOC 点、持续时间为 1~60 s 的功率测试数据作为训练集。设模型的隐含层有 200 个细胞,最大迭代次数为 20,Dropout 层的丢失概率为 0.9,学习速率为 0.01。

本文的整体框架见图 8,可分为数据训练、数据验证两部分,具体如下。

(1) 数据训练。

1) 算法启动,初始化算法并准备开始。

2) 提取训练数据。以若干块参数如表 2 的动力电池作为训练用电池,按图 3 的测试流程进行测试,提取训练数据。

3) 建立电池模型。见第 1.1 节。

4) 搭建电量-温度-模型参数表。见第 1.2 节。

5) 训练多步功率预测法。见第 2 节。

6) 训练功率修正法。见本节。

(2) 数据验证。

7) 提取验证数据。以一块参数如表 2 的动力电

池作为验证用电池,按图 3 的测试流程进行测试,提取验证数据。

8) 验证电池模型。

9) 验证电量-温度-模型参数表。分别使用动态工况测试和功率能力两种测试数据,验证模型及电量-温度-模型参数表。

10) 验证多步预测法预测的功率值。从温度、SOC、步数的角度,评价该方法的预测效果和计算时间。

11) 验证功率修正法修正的功率值。通过修正后的功率值,评价该方法的修正效果。

图8 文章整体框架

4 验证与讨论

4.1 动力电池模型验证

使用验证电池的动态工况数据(数据 A)和功率能力数据(数据 B),验证模型及电量-温度-模型参数表的准确性。3 个温度点的数据 A 的验证结果见图 9。3 个温度点、9 个 SOC 点的数据 B 的验证结果见图 10。模型预测电压误差见表 4。

表4 模型预测电压误差

温度/℃	最大误差/mV		RMSE/mV	
	数据 A	数据 B	数据 A	数据 B
5	93.1	-42.3	10.3	1.3
25	63.7	-24.4	7.7	1.2
45	-61.1	-17.0	14.7	1.2

动态工况数据中, 模型预测电压的最大误差为 93.1 mV, 均方根误差(Root mean square deviation, RMSE)最大为 14.7 mV。功率能力数据中, 模型预测电压的最大误差为 42.3 mV, 均方根误差最大为 1.3 mV。在两种不同数据的验证中, 使用电量-温度-模型参数表预测的模型电压最大误差均不超过 100 mV, 均方根误差在 20 mV 以内, 能够为功率能力预测提供模型支撑。

图 9 模型电压误差(动态工况测试)

4.2 功率预测及修正方法验证

首先, 使用验证电池的功率能力测试数据, 验证基于动态目标终止电压的多步功率预测法。考虑到计算成本, 仅对步数 $x < 9$ 时的多步功率预测法进行对比验证。以每个 SOC 测试点下, 恒功率放电 60 s 时刻作为终止时刻, 其电压为目标电压。3 个

温度、9 个 SOC 点的放电功率预测误差见图 11, 每一列代表不同温度的预测误差, 第一行和第二行分别以 SOC 和步数 x 作为横坐标, 评价 SOC、步数对功率预测误差的影响。

可见: 当步数 $x=2$ 时, 多步功率预测法较 $x=1$ 时取得了较大的性能提升。当步数 $x \geq 2$ 时, 多步功率预测法预测结果比较接近, 最大误差在 6 W 以内, 不超过真实值 200 W 的 3%。运行设备的硬件配置包括个人计算机和相应网络设置, 软件配置为基于 Windows 10 操作系统的 MATLAB R2019a。表 5 为多步功率预测法在不同步数的平均计算时间, 为兼顾方法的预测精度和计算速度, 建议步数取 2~4。

表 5 多步功率预测法计算时间

步数 x	计算时间/s		
	45 °C	25 °C	5 °C
1	0.076	0.061	0.065
2	0.080	0.074	0.079
3	0.104	0.101	0.101
4	0.129	0.137	0.132
5	0.204	0.210	0.318
6	0.448	0.455	0.425
7	1.249	1.199	1.209
8	5.668	5.295	5.143

然后, 进行功率修正模型的验证, 功率修正结果见图 12, 修正前后的功率误差对比见图 13 和表 6。

图 10 模型电压误差(功率能力测试)

图 11 不同步数、不同 SOC 的功率预测误差

图 12 功率修正值

图 13 修正前后的功率误差

表 6 功率误差

温度/℃	最大误差/W		RMSE/W	
	修正前	修正后	修正前	修正后
5	11.32	3.81	4.05	1.26
25	15.87	4.78	3.77	1.74
45	15.62	5.38	4.36	1.82

功率修正法在全 SOC 区间、宽温度范围、长持续时间内的最大误差为 5.38 W, 较修正前误差降低了 66%; 均方根误差最大为 1.82 W, 较修正前误差降低了 58%。

5 结论

本文针对电动载运装备用动力电池, 提出了充放电功率能力预测和修正方法, 主要进展如下。

(1) 以输入/输出功率为控制目标完善了动力电池充放电行为描述模型, 应用电量-温度-模型参数表, 刻画了功率需求驱动的动力电池充放电行为, 两类不同类型数据验证结果表明, 模型的电压预测误差小于 100 mV, 均根误差小于 20 mV, 为功率预测提供了精确的模型基础。

(2) 步数为 2~4 可以兼顾预测算法的复杂性和预测精度, 步数为 1 时预测性能明显降低, 步数大于 4 后预测性能提升不明显, 反而计算成本显著增加。

(3) 当多步功率预测法的步数为 2 时, 在全电量区间、宽温度范围、长持续时间内, 基于 LSTM 的功率修正法能够将多步功率预测法的预测结果修正到真实值附近, 最大误差小于 3%, 较修正前误差减少了 66%; 方均根误差小于 1%, 较修正前误差减少了 58%, 实现了功率输入/出需求驱动的电动载运装备用动力电池充放电能力预测。

参 考 文 献

- [1] 国务院办公厅. 国务院办公厅关于印发新能源汽车产业发展规划(2021—2035 年)的通知[EB/OL]. [2020-11-02]. http://www.gov.cn/zhengce/content/2020-11/02/content_5556716.htm.
General Office of the State Council of the People's Republic of China. Notice of the general office of the State Council on printing and distributing the development plan (2021-2035) of new energy automobile industry[EB/OL]. [2020-11-02]. <http://www.gov.cn/>

zhengce/content/2020-11/02/content_5556716.htm.

- [2] 熊瑞. 动力电池管理系统核心算法[M]. 北京: 机械工业出版社, 2018.
XIONG Rui. Core algorithm of battery management system for EVs[M]. Beijing: China Machine Press, 2018.
- [3] 熊瑞, 马骥骁, 杨瑞鑫, 等. 动力电池外部短路故障热-力影响与分析[J]. 机械工程学报, 2019, 55(2): 115-125.
XIONG Rui, MA Suxiao, YANG Ruixin, et al. Thermo-mechanical influence and analysis of external short circuit faults in lithium-ion battery[J]. Journal of Mechanical Engineering, 2019, 55(2): 115-125.
- [4] 中国国家标准化管理委员会. GB/T 38661—2020 电动汽车用电池管理系统技术条件[S]. 北京: 中国标准出版社, 2020.
National Standardization Administration of China. GB/T 38661 — 2020 Technical specification of battery management system for electric vehicles[S]. Beijing: Standards Press of China, 2020.
- [5] 金鑫娜, 顾启蒙, 潘宇巍, 等. 锂离子动力电池 SOP 在线估计方法研究[J]. 电源技术, 2019, 43(9): 1448-1452.
JIN Xinna, GU Qimeng, PAN Yuwei, et al. Online state of power estimation methods for lithium-ion batteries in EV[J]. Chinese Journal of Power Sources, 2019, 43(9): 1448-1452.
- [6] 李燕斌. 电动汽车电池的放电功率控制方法、装置和存储介质: 中国, 201811143809.4[P]. 2012-01-18.
LI Yanbin. Discharge power control method and device for battery of electric vehicle, and storage medium: China, 201811143809.4[P]. 2012-01-18.
- [7] PLETT G L. High-performance battery-pack power estimation using a dynamic cell model[J]. IEEE Transactions on Vehicular Technology, 2004, 53(5): 1586-1593.
- [8] 张彩萍, 张承宁, 李军求. 动力电池组峰值功率估计算法研究[J]. 系统仿真学报, 2010, 22(6): 202-205.
ZHANG Caiping, ZHANG Chengning, LI Junqiu. Research on peak power estimation for traction battery pack[J]. Journal of System Simulation, 2010, 22(6): 202-205.
- [9] SUN F, XIONG R, HE H, et al. Model-based dynamic multi-parameter method for peak power estimation of

- lithium-ion batteries[J]. Applied Energy, 2012, 96: 378-386.
- [10] XIONG R, HE H, SUN F, et al. Model-based state of charge and peak power capability joint estimation of lithium-ion battery in plug-in hybrid electric vehicles[J]. Journal of Power Sources, 2013, 229: 159-169.
- [11] XIONG R, HE H, SUN F, et al. A data-driven adaptive state of charge and power capability joint estimator of lithium-ion polymer battery used in electric vehicles[J]. Energy, 2013, 63(1): 295-308.
- [12] 熊瑞, 李幸港. 基于双卡尔曼滤波算法的动力电池内部温度估计[J]. 机械工程学报, 2020, 56(14): 146-151.
- XIONG Rui, LI Xinggang. Battery internal temperature estimation method through double extended kalman filtering algorithm[J]. Journal of Mechanical Engineering, 2020, 56(14): 146-151.
- [13] 熊瑞, 马骥骁, 陈泽宇, 等. 锂离子电池极速自加热中的电-热耦合特性及建模[J]. 机械工程学报, 2020, 57(2): 179-189.
- XIONG Rui, MA Suxiao, CHEN Zeyu, et al. Electric-thermal coupling characteristics and modeling of Lithium ion battery self-heating at high speed[J]. Journal of Mechanical Engineering, 2020, 57(2): 179-189.
- [14] 王春雨, 崔纳新, 李长龙, 等. 基于热电耦合模型和多参数约束的动力电池峰值功率预测[J]. 机械工程学报, 2019, 48(15): 28-35.
- WANG Chunyu, CUI Naxin, LI Changlong, et al. State of power prediction based on electro-thermal battery model and multi-parameter constraints for lithium-ion battery[J]. Journal of Mechanical Engineering, 2012, 48(15): 90-95.
- [15] WU J, ZHANG N, LI P, et al. A temperature-based peak power capability estimation method for lithium-ion batteries[J]. Procedia Engineering, 2017, 187: 249-256.
- [16] ZOU C, KLINTBERG A, WEI Z, et al. Power capability prediction for lithium-ion batteries using economic nonlinear model predictive control[J]. Journal of Power Sources, 2018, 396: 580-589.
- [17] 孙丙香, 高科, 姜久春, 等. 基于 ANFIS 和减法聚类的动力电池放电峰值功率预测[J]. 电工技术学报, 2015, 30(4): 272-280.
- SUN Bingxiang, GAO Ke, JIANG Jiuchun, et al. Research on discharge peak power prediction of battery based on anfis and subtraction clustering[J]. Transactions of China Electrotechnical Society, 2015, 30(4): 272-280.
- [18] 郑方丹, 姜久春, 陈坤龙, 等. 基于数据统计特性的 GS-SVM 电池峰值功率预测模型[J]. 电力自动化设备, 2017(9): 56-61.
- ZHENG Fangdan, JIANG Jiuchun, CHEN Kunlong, et al. Peak power prediction model for batteries based on data statistical characteristic and GS-SVM[J]. Electric Power Automatic Equipment, 2017(9): 56-61.
- [19] 赵硕, 张缓缓, 王庆年. 混合动力汽车电机恒功率特性研究[J]. 微电机, 2005(3): 75-77, 55.
- ZHAO Shuo, ZHANG Huanhuan, WANG Qingnian. Investigation constant power of motor characteristics on electric vehicles[J]. Micromotors, 2005(3): 75-77, 55.
- [20] 周步祥, 何飞宇, 魏金萧, 等. 基于实时最优恒定功率的电动汽车有序充电策略[J/OL]. 电测与仪表, 2020[2020-11-24].<https://kns.cnki.net/kcms/detail/23.1202.TH.20201124.1437.046.html>.
- ZHOU Buxiang, HE Feiyu, WEI Jinxiao, et al. Ordered charging strategy of electric vehicles based on real-time optimal constant power[J/OL]. Electrical Measurement & Instrumentation, 2020[2020-11-24].<https://kns.cnki.net/kcms/detail/23.1202.TH.20201124.1437.046.html>.
- [21] 王桀, 熊瑞, 穆浩. 温度和老化意识融合驱动的电动车辆锂离子动力电池电量和容量协同估计[J]. 电工技术学报, 2020, 35(23): 4980-4987.
- WANG Ju, XIONG Rui, MU Hao. Co-Estimation of lithium-ion battery state-of-charge and capacity through the temperature and aging awareness model for electric vehicles[J]. Transactions of China Electrotechnical Society, 2020, 35(23): 4980-4987.
- [22] 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.
- [23] CHEN X, LEI H, XIONG R. A bias correction based state-of-charge estimation method for multi-cell battery pack under different working conditions[J]. IEEE Access, 2018, 6(1): 78184-78192.
- [24] 王鑫, 吴际, 刘超, 等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. 北京航空航天大学学报, 2018, 44(4): 772-784.
- WANG Xin, WU Ji, LIU Chao, et al. Exploring LSTM

- based recurrent neural network for failure time series prediction[J]. Journal of Beijing University of Aeronautics and Astronautics, 2018, 44(4): 772-784.
- [25] KINGMA D P, BA J. Adam: A method for stochastic optimization[C]//International Conference on Learning Representations 2015, 2015: 1-15.
- [26] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research,

2014, 15(1): 1929-1958.

作者简介: 熊瑞(通信作者), 男, 1985 年出生, 博士, 教授, IET Fellow, 博士研究生导师。主要研究方向为电动载运装备和储能系统。

E-mail: rxiong@bit.edu.cn

闫良基, 男, 1996 年出生。主要研究方向为动力电池功率能力预测。

E-mail: minnowyan@163.com

王渠, 男, 1991 年出生, 博士研究生。主要研究方向为新能源汽车动力电池系统管理。

E-mail: wang_ju@bit.edu.cn