

DOI: 10.19650/j.cnki.cjsi.J2514758

面向异构锂电池组的自适应充电策略^{*}

王龙军, 郭 强, 赵光焱, 闫旻旻

(重庆理工大学电气与电子工程学院 重庆 400054)

摘 要:军用便携式装备电源常采用多个 18650 型锂离子电池组成,不同设备存在串并环节数、电池类型等异构性,面对未来日益复杂且严苛的战场环境,能够实现对异构锂电池组准确识别与自适应充电具有重要意义。传统误差反向传播神经网络识别锂电池,存在收敛速度慢、识别精度差以及局部最优等问题。针对上述不足,提出一种基于思维进化算法优化反向传播(BP)神经网络的系统辨识模型,以应对军用便携式装备电源自适应充电带来的挑战。首先,该方法以便携式装备电源广泛采用的 18650 型锂电池为研究对象,测试其在不同充电倍率下的充电数据,通过深入分析锂电池的充电特性曲线,确定了构建模型的关键特征量;其次,在网络的训练阶段中,利用思维进化算法(MEA)对 BP 神经网络的初始权值与阈值进行全局优化,且将锂电池类型与荷电状态(SOC)作为输出特征,构建系统辨识模型;最后,研制了一款基于四开关 Buck-Boost 变换器的实验样机,结合前述自适应充电策略,协同实现对异构锂电池组的预测识别且自适应充电控制,并将 MEA-BP 神经网络构建的系统辨识模型与 BP 模型和粒子群优化 BP 神经网络(PSO-BP)模型的识别精度进行对比分析。实验表明,所提算法提升了锂电池类型与 SOC 的识别与预测精度,其预测误差均控制在 1% 以内,能够有效辨识不同节数及 SOC 状态的锂电池组,并据此实现自适应充电控制,展现出优越的估计精度与鲁棒性。

关键词: 异构锂电池组;系统辨识模型;MEA-BP 神经网络;自适应充电控制

中图分类号: TH7 TM93 **文献标识码:** A **国家标准学科分类代码:** 480.40

Adaptive charging strategy for heterogeneous lithium battery packs

Wang Longjun, Guo Qiang, Zhao Guangyan, Yan Minyang

(School of Electrical and Electronic Engineering, Chongqing University of Technology, Chongqing 400054, China)

Abstract: The military portable equipment power sources often employ multiple 18650-type lithium-ion batteries in series-parallel configurations, which possesses the different number of serially or parallel connected cells and heterogeneous battery types across different devices. Thus achieving the accurate identification and adaptive charging of heterogeneous lithium battery packs is significant in the increasingly complex and demanding battlefield environments. The traditional back propagation (BP) neural networks utilized for identifying lithium batteries suffer from the slow convergence, poor identification accuracy and local optima issues. To address these shortcomings, a system identification model based on the mind evolutionary algorithm optimized BP neural network is proposed to tackle the challenges posed by adaptive charging of military portable equipment power sources. This method first takes the widely used 18650-type lithium battery in portable equipment power sources as the research object, tests its charging data under different charging rates, and determines the key features of model construction through in-depth analysis of the lithium battery charging characteristic curve; Additionally in order to construct the system identification model, the mind evolutionary algorithm (MEA) algorithm is used to globally optimize the initial weights and thresholds of the BP neural network with battery type and state of charge (SOC) as output features during the network training period; Finally an experimental prototype based on a four switch Buck-Boost converter is developed, which collaboratively achieves the predictive identification and adaptive charging control of heterogeneous lithium battery packs by combing with the aforementioned adaptive charging strategy. The identification accuracy of the system identification model constructed by the MEA-BP neural network is compared with those of the BP model and the particle swarm optimization (PSO)-BP model. Experiments show that the

收稿日期: 2025-12-08 Received Date: 2025-12-08

^{*} 基金项目: 重庆市自然科学基金面上项目 (CSTB2022NSCQ-MSX0997) 资助

proposed algorithm improves the identification and prediction accuracy of lithium battery type and SOC with the prediction errors controlled within 1%. It can effectively identify the lithium battery packs with different numbers of cells and SOC states, and achieve the adaptive charging control, demonstrating the superior estimation accuracy and robustness.

Keywords: heterogeneous lithium battery packs; system identification model; MEA-BP neural network; adaptive charging control

0 引言

在全球政治格局持续紧张化的背景下,高性能储能系统已逐渐成为推动军事科技迭代升级的重要战略支撑技术。锂离子电池因其高能量密度、功率密度高、充电速度快、无记忆效应和循环寿命特性^[1-4],在现代军用便携式装备电源中呈现出多维度的应用背景,且随着锂离子电池在作战系统应用的持续提升,其充电系统正面临复杂战场环境下的动态适配性挑战,从而催生了基于动态参数自适应的智能充电策略的技术需求^[5-6]。军事便携式装备电源中,不同设备存在串并环节数、电池类型等异构性,其性能指标与充电阈值要求各不相同,因此,自适应充电策略需根据锂电池的组类、充放电特性及使用环境等因素进行动态调整,这需要充电系统具备自适应能力,能够基于实时反馈数据和设备需求,优化充电过程,以确保电池的安全性、寿命和性能最大化,进而提升整个自适应充电系统的可靠性与作战效能。

为实现异构锂电池组的自适应充电,系统需在线辨识锂电池类型与充电电压,而鉴于电池充电电压随荷电状态(state of charge, SOC)呈现非线性变化,可通过预测锂电池的 SOC,并结合实际充电电压信息,构建预测模型,从而确定锂电池需要的最优充电电压设定值。

目前,锂电池 SOC 估计方法主要有开路电压法、安时积分法、卡尔曼滤波法等。其中,开路电压法需要提前对电池进行静置放电一段时间,获取稳定的电压值,难以满足锂电池 SOC 的在线实时估计^[7]。安时积分法原理简单、便于实现,但积分运算存在一定的累积误差^[8]。卡尔曼滤波及其改进算法是目前锂电池 SOC 估计中应用最广泛的方法^[9-12],主要利用估计误差的协方差阵提高安时积分法的精度,但是观测方程能否有效地对其进行矫正,很大程度上依赖于所建立锂电池模型的准确性。文献[13]提出自适应无迹卡尔曼滤波算法,简化滞回开路电压模型,利用分阶段变换测量协方差及构建自适应因子方法对无迹卡尔曼滤波算法改进,来提升电池等效模型精度及估计精度,可是基于模型的方法估计,需要考虑电池的模型质量,普遍适用性较差。

上述方法的动态或者嘈杂工作环境中的锂电池参数测量误差会对 SOC 估计产生较大影响,这些限制推动了数据驱动的方法应用,不考虑锂电池内部复杂的电化学反应,其中机械学习算法也具有更广泛的适用性,模型训

练过程更简单,训练数据的选择范围更广,计算成本更低,通常将锂离子电池端口电压、充放电电流与温度等特征量作为模型的输入,将 SOC 作为模型的输出,基于输入/输出数据进行预测^[14-15],但算法基于训练数据所构建的模型,直接影响预测精度。文献[16]提出基于支持向量回归的数据驱动模型,独立于应用程序的 SOC 估计方法,但是只适用于单输入单输出的情况。文献[17]提出局部模型网络预测锂电池的 SOC,将复杂模型表示为多个特定子区间的局部简单模型,提高全局寻优能力,进一步提高了锂电池预测的准确率。文献[18-19]提出相关的模型与算法集成,降低了控制算法的复杂性,用于锂电池的充电状态估计,可是存在模型的不确定性的鲁棒性以及模型噪声的影响。

人工神经网络作为一种机器学习算法,避免了模型的不确定性和过程噪声的影响,估计精度取决于特征参数与神经网络结构的设计,还拥有极强的非线性映射能力,被广泛应用于锂电池的估计,其基础方法为误差反向传播(back propagation, BP)神经网络^[20-21],但 BP 神经网络在实际过程中与测量参数有关,过于依赖训练数据,会造成 SOC 估计精度下降。文献[22]提出温度补偿和长短期记忆网络的组合,从电流、电压、温度、参考开路电压(open circuit voltage, OCV)等可测量数据推断电池 SOC,将温度补偿引入模型训练,其可以在不同的温度下比适于 SOC 测量的温度更精确地估计。文献[23]提出了一种卷积神经网络,使用时域频谱图来提取电池信息特征,减少参数的使用,减小误差,但由于捕捉数据中的局部模式和空间层次结构,意味着对输入中的微小变化敏感,计算负担重。递归神经网络,虽可以提高 BP 神经网络的估算精度^[24-26],但网络初始权值参数的分布特性对模型鲁棒性及估计精度具有显著影响,随机初始化策略也可能导致网络陷入局部极小值域,所以需要采用智能优化算法对 BP 初始参数进行优化,提高 BP 神经网络模型的估计精度。文献[27]采用改进粒子群(particle swarm optimization, PSO)优化 BP 神经网络预测煤层瓦斯,预测精度由 BP 神经网络 7.50%~14.50%,提高至 PSO-BP 神经网络的 2.40%~4.80%。文献[28]采用加入鸽子启发式遗传算法对双向门控循环神经网络参数进行优化,提高 SOC 的估计精度,鲁棒性也更强。

基于上述分析,提出一种思维进化算法优化 BP (mind evolutionary algorithm optimize BP, MEA-BP)神经网络的锂电池辨识方法,以实现异构锂电池组的自适应

充电控制。首先,开展 18650 型锂电池的充电实验测试,分析其充电动态特性,并据此确定构建算法模型的特征量;然后,详细介绍 MEA-BP 神经网络的结构设计与训练过程,构建高精度的充电系统辨识模型,进一步结合实际充电电压-SOC 拟合数据,构建自适应充电策略;最后,研制了基于四开关 Buck-Boost 变换器的实验样机平台,结合所提出的自适应充电策略,协同实现对异构锂电池组的在线识别与自适应充电控制,验证所提方法的有效性与鲁棒性,并进行总结。

1 锂电池的充电特性

在锂电池实际充电过程的状态监测与参数辨识中,鉴于其内部电化学状态变量难以直接获取,需构建基于可检测外部电信号的系统辨识模型。针对军用便携式装备电源广泛应用的 18650 型磷酸铁锂与镍钴锰三元锂两类主流锂电池,采用实验数据驱动的方法,系统研究其充电动态特性,为高精度建模提供数据依据。两类锂电池的关键参数如表 1 所示。

表 1 电池的关键参数
Table 1 Key battery parameters

参数	三元锂电池	磷酸铁锂电池
型号	远阳 18650	远阳 18650
标称电压/V	3.65	3.20
标称容量/mAh	1 500	1 500
充电截止电压/V	4.20	3.65
放电截止电压/V	3.00	2.00

基于搭建的锂电池测试平台,获得锂电池不同充电倍率的恒流-恒压(constant current-constant voltage, CC-CV)充电曲线,如图 1 所示,由测试主机、电池测试设备 ITS5300、待测锂电池组成,其最高采样速率达 1 ms,测试精度小于 0.05%。实验设置采样周期 10 s,三元锂电池和磷酸铁锂电池截止电压分别设为 4.20 和 3.65 V,获得充电倍率分别为 1、1.5 与 2 C 下的充电数据,并分析其充电特性。

两类锂电池在不同充电倍率下的 CC-CV 充电测试结果如图 2 所示。图 2(a)中的三元锂电池在 1 C 恒流充电(constant current, CC)模式下,其恒压充电(constant voltage, CV)阶段起始于 SOC = 87%,而充电倍率分别提升到 1.5 和 2 C 时,CV 阶段起始点显著提前,分别降到 SOC = 54% 和 SOC = 53%;同理图 2(b)中的磷酸铁锂电池在 1.5 和 2 C 恒流充电时,CV 阶段起始点同样明显前移。






图 1 锂电池测试平台

Fig. 1 Lithium battery testing platform



(a) 三元锂电池拟合效果

(a) Fitting effect of ternary lithium batteries



(b) 磷酸铁锂电池拟合效果

(b) Fitting effect of lithium iron phosphate batteries

图 2 锂电池电压-SOC 曲线拟合效果


Fig. 2 The fitting effect of voltage-SOC curve for lithium battery

分析表明,由过早进入 CV 阶段所构成的充电数据样本,其表征的充电动态特性存在较大局限性,基于此类数据训练的系统辨识模型,难以充分捕捉电池完整的充电动态特征,导致预测精度显著下降。因此,选择锂电池 1 C 恒流充电倍率的实验数据作为模型训练与验证的样本数据。

基于 1 C 倍率下的实验数据拟合分析,磷酸铁锂与三元锂电池在不同 SOC 区间呈现显著的电压增量差异,


为提升系统辨识模型的预测精度,需要将锂电池充电过程定量分析的电压增量数据作为其特征量。

锂电池电压增量数据,如图3所示。磷酸铁锂电池在CC充电阶段(40~90 min)的电压增量(ΔV)变化平缓,直至120 min切换CV模式;而三元锂电池的 ΔV 变化较为迅速,表明其具有更高的电压变化率。基于此动态响应差异,提取2 min的 ΔV 作为特征量,以提升模型的预测精度。



(a) 三元锂电池电压增量

(a) Voltage increment of ternary lithium batteries



(b) 磷酸铁锂电池电压增量

(b) Voltage increment of lithium iron phosphate batteries

图3 锂电池电压增量

Fig. 3 Lithium battery voltage increment

鉴于两类锂电池在电压增量变化速率上的本质差异及上述分析,创新性地提出将2 min的电压增量、1 C充电倍率、实际充电电压、电池类型与SOC作为模型特征量,构建系统辨识模型,从而实现对异构锂电池组的高精度辨识,为自适应充电策略的精准动态调控提供了关键理论支撑。

2 基于MEA-BP的系统辨识模型

为解决传统BP神经网络在动态环境下锂电池状态预测中的收敛速度慢、识别精度差以及局部最优等问题,提出基于MEA算法优化BP神经网络的增量式MEA-BP神经网络模型。该模型通过融合2 min的 ΔV 、实际充电电压等特征量,构建系统辨识模型,显著提升对异构锂电池组在线估计能力,相较于传统BP神经网络模型,其在SOC和锂电池类型等关键参数上均展现出更优的估计精度。

2.1 BP神经网络算法

BP神经网络拓扑示意图如图4所示,在对锂电池进行识别的过程中,输入层主要输入特征,隐含层主要将输入的特征与电池识别类型相对应,输出层主要是输出特征的判别结果。




图4 BP神经网络的网络结构

Fig. 4 Network structure of BP neural network

其中输出数学模型如式(1)所示。

$$\lambda_k = f_m \left(\sum_{j=1}^m w_j I_j + \eta_k \right) \quad (1)$$

式中: f_m 为激活的函数; I_j 为前一层第j个神经元的输入值; w_j 为神经元与前一层第j个神经元之间的权值; η_k 为神经元的偏置项。

基于梯度下降法的优化机制,BP算法通过反向传播路径计算误差对各层参数的偏导数,据此建立权值修正量当前位置的梯度的线性映射关系如式(2)所示。

$$\begin{cases} E_i = \frac{1}{2} \sum_{i=1}^n (T_i - y_i)^2 \\ \Delta W_j = -\eta \frac{\partial E_i}{\partial W_j} \\ \Delta \gamma_k = -\eta \frac{\partial E_i}{\partial \gamma_k} \end{cases} \quad (2)$$

式中: E_i 为网络误差; y_i 为训练输出; T_i 为实际预期输出;比例系数 η 表征学习率参数; n 表示样本数量。该优化策略本质上沿误差曲面的最速下降方向迭代调整网络参数,从而实现对误差函数极小值点的渐进逼近。

2.2 MEA优化算法

针对BP神经网络模型在梯度下降训练中易陷于局部最优且收敛效率不足的问题,常采用群体智能算法优化其权值与阈值以增强全局寻优能力。MEA算法创新性地设计了趋同与异化双阶段协同进化机制,趋同通过子群体个体间的定向竞争机制与精英驱动策略进行局部优化。

将种群划分为 k 个独立子群体 $G_1, G_2, \dots, G_k$,每个子群体占据空间的一个子区域 $\Omega_i \subseteq \Omega$;

$$G = \{G_1, G_2, \dots, G_k\}, \Omega_i \subseteq \Omega \quad (3)$$

计算子群体 G_i 内所有个适应度 $f(x_j)$, $\forall x_j \in G_i$, 选择适应度最高的前 m 个个体构成优胜子群体:

$$E_i = \{x_j^* | f(x_j^*) \geq f(x_1), \forall x_1 \in G_i\}$$

(4)

对非优胜个体施加局部扰动(定向探索与多样性平衡):

$$x_j^{(t+1)} = x_j^{(t)} + \alpha(x_i^* - x_j^{(t)}) + \varepsilon$$

(5)

式中: α 为学习率; ε 为随机扰动因子, 维持种群多样性。

若满足以下任一条件, 则标记 G_i 局部收敛。

$$\begin{cases} \text{Var}(f(G_i)) < \delta \\ t \geq T_{\max} \end{cases}$$

(6)

式中: δ 为适应度方差阈值; $T_{\max}$ 为最大局部迭代次数。

异化是针对布局空间内的全体子群体, 各子群体通过不断相互竞争, 最终成为空间内全局胜者的过程, 全局适应度排序, 计算各子群体的平均适应度:

$$\bar{f}(G_i) = \frac{1}{|G_i|} \sum_{x_j \in G_i} f(x_j)$$

(7)

低适应度子群体淘汰, 释放其占据的空间区域 Ω_{free} , 在其中随机初始化或克隆高适应度子群体生成新群体, 保持种群的多样性。

$$G_{\text{new}} = \{x_j \in u(\Omega_{\text{free}}) | j = 1, \dots, N_{\text{new}}\}$$

(8)

将优胜个体 x_i^* 迁移到相邻子群体 G_j , 引入跨区域扰动:

$$G_j^{(t+1)} = G_j^{(t)} \cup \{x_i^* + \varepsilon\}$$

(9)

如式(5)所示, 趋同阶段的局部扰动策略平衡了精英引导与多样性维持, 而式(9)的跨群体迁移机制有效促进了全局信息交互, 规避了传统进化算法的早熟收敛问题。

2.3 MEA 优化 BP 神经网络

MEA 优化 BP 神经网络初始权值与阈值的核心机制在于, 以网络训练误差的倒数定义为个体及种群的适应度评价函数, 通过双阶段协同演化实现全局优化, 显著降低训练误差并提升网络泛化性能, 有效规避早熟收敛现象, 进而增强算法收敛效率与稳定性。最后经迭代优化, MEA 最终输出适应度最高的最优个体, 作为 BP 神经网络的初始化参数配置。基于 MEA 优化 BP 神经网络的流程图, 如图 5 所示。

- 1) 提取 MEA-BP 模型的训练样本与测试样本, 打乱数据, 并且对数据进行归一化处理;
- 2) MEA 参数设置, 随机生成初始种群;
- 3) 利用 score 得分函数计算个体得分, 进行排序, 产生优胜个体和临时个体, 作为中心, 构成优胜子种群和临时子种群;

$$\text{score} = \frac{1}{\sqrt{\frac{1}{N} \sum_{i=1}^N (T_i - y_i)^2}}$$

(10)




图 5 MEA-BP 神经网络流程
Fig. 5 Flowchart of MEA-BP neural network

- 4) 子种群趋同操作和子种群之间异化操作, 利用ismature()判定子种群是否成熟;
- 5) 最小的误差或者迭代次数到达设定值, 则结束, 将 Q_{ij} 、 W_{jk} 、 θ_j 、 γ_k 分别编码得到神经网络的最优权值和阈值;
- 6) 训练 BP 网络, 开展预测分析。基于实测数据, 在 MATLAB 中搭建算法模型, MEA-BP 神经网络参数设置如表 2 所示。

表 2 MEA-BP 神经网络参数

Table 2 Parameters of MEA-BP neural network

类别	参数名称	数值
MEA	种群大小/个	300
	迭代次数/次	100
	优胜子种群个数/个	5
	临时子种群个数/个	5
	输入层神经元/层	5
	输出层神经元/层	2
BP	最大迭代次数/次	200
	训练误差	1×10^{-6}
	学习率	0.01

经过上述分析, 为增强锂电池系统辨识模型的鲁棒性, 采用 MEA 优化 BP 神经网络的初始权值与阈值, 通过 BP 网络拓扑(5-11-2 结构)将解空间映射至编码空间, 其中每个编码向量对应一组可解的权值-阈值参数, 输入特征为 1 C 充电倍率、电压增量、实际充电电压、电池类型及 SOC, 输出特征为 SOC 与电池类型辨识结果。

进一步,该模型基于实际充电电压-SOC 的拟合数据,可自适应确定 CC-CV 充电模式的电压切换阈值,构建自适应充电策略。

3 实验验证

为验证 MEA-BP 系统辨识模型的准确性,构建了锂电池自适应充电系统,如图 6 所示。其中控制策略采用 MEA-BP 神经网络识别算法,可精准辨识锂电池类型与 SOC,并据此动态调节 CC-CV 充电模式切换阈值,进一步结合四开关 Buck-Boost 变换器 (four switch Buck-Boost, FSBB) 的四模式控制策略^[29],通过状态识别与控制策略的协同优化,实现对异构锂电池组的兼容性充电。





图 6 锂电池自适应充电系统框图


Fig. 6 Block diagram of adaptive charging system for the lithium battery

在 MEA 参数优化过程中,首先采用随机置换算法对原始数据集进行无序化处理,并按预设比例划分为训练集与测试集,全局趋同操作的迭代竞争阶段如图 7 所示。图 7(b)临时子种群 3 的适应度评分超越图 7(a)优胜子种群 5,从而触发异化操作机制以规避局部最优。异化阶段,依据 MEA 种群动态更新准则,实施精英保留策略与动态种群重组,将临时子种群 3 纳入优胜子种群集合,同步淘汰低适应度子种群。



(a) 优胜子种群趋同过程

(a) Convergence process of superior subpopulation




(b) 临时子种群趋同过程

(b) Process of temporary subpopulation convergence

图 7 MEA 算法趋同过程


Fig. 7 Convergence process of the MEA algorithm

异化操作完成后,算法进入二次趋同优化阶段,如图 8 所示。图 8(a)中异化后的优胜子种群集合适度评分均超越图 8(b)临时子种群,验证了该算法达成种群动态平衡且满足收敛准则。通过多维参数空间映射机制,获得全局最优解作为 BP 神经网络的初始权值与阈值。随后执行网络训练,当训练集均方误差低于 1×10^{-6} 时终止训练,最终完成系统辨识模型的构建。



(a) 异化后的优胜子种群趋同过程

(a) The convergence process of the winner population after alienation



(b) 异化后的临时子种群趋同过程

(b) The convergence process of temporary subpopulations after alienation

图 8 MEA 算法异化后的趋同过程

Fig. 8 The convergence process of the MEA algorithm after alienation

为了验证所提出 MEA-BP 神经网络构建的系统辨识

模型的训练性能,比较不同网络模型训练集、验证集和测试集的收敛过程,如图 9 所示。




图 9 锂电池预测网络的最佳验证性能

Fig. 9 Optimal validation performance of the lithium battery prediction network

两种神经网络模型经训练后,其训练集均方根误差均收敛至最佳性能 1×10^{-6} ,但 MEA-BP 模型训练集、验证集、测试集的收敛速度比 BP 模型更快,最佳迭代次数也更早出现,并在第 59 次训练周期达到了最佳验证和测试性能。最终通过理论分析和实验结果表明,MEA-BP 模型在有限迭代次数内具有更好的学习速率和鲁棒收敛性。

评估回归模型的预测输出与目标之间的统计相关性,采用相关系数(R)作为关键评价指标,如图 10 所示,训练集的回归响应为理论最优 1。根据图 10(b)~(d)可知,数据点沿函数线 $y=x$ 密集分布,从而证明 BP 神经网络训练集拟合关系良好。MEA-BP 神经网络算法模型在锂电池状态测试性能中达成 $R=0.99$ 的相关系数,表明该模型具有极佳的预测精度。




图 10 锂电池预测网络的回归

Fig. 10 Regression of lithium battery prediction network

为了验证 MEA-BP 神经网络算法对锂电池类型的辨识能力,设计了二元分类预测任务,分别将三元锂电池和磷酸铁锂电池两个样本标记为标签 1 和标签 2,对预测结果如图 11 所示,该模型通过特征提取与非线性映射机制的协同作用,实现对两种电池类型的高精度辨识,分类预测准确率大于 99%,为锂电池自适应充电系统提供了可靠的类别判别基础,保障了自适应充电策略的精准匹配。

基于 MEA-BP 神经网络算法构建的系统辨识模型,实现了对异构锂电池组 SOC 的高精度预测,其结果如

图 12 所示,模型预测值与实验实际值高度拟合,验证了其在电池状态估计中的可靠性。此外通过 SOC 与实际充电电压的函数映射关系,使系统自适应计算出 CC-CV 充电模式切换的电压阈值。

为了量化评估 MEA-BP 神经网络算法在锂电池状态估计的预测性能,选择平均绝对百分比误差 (mean absolute percentage error, MAPE)、相对误差 (relative error, RE) 与预测误差 (prediction error, PE) 进行评估。

MAPE 预测结果可定义为:




图 11 锂电池类型的预测

Fig. 11 Prediction of lithium battery types




图 12 锂电池 SOC 的预测

Fig. 12 SOC prediction of lithium batteries

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (11)$$

RE 可定义为:

$$RE = \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (12)$$


PE 可定义为:

$$PE = y_i - \hat{y}_i \quad (13)$$

式中: $\hat{y}_i$ 和 y_i 分别为锂电池状态估计的预测值和真实值。


锂电池预测的相对误差模型对比结果,如图 13 所示,MEA-BP 神经网络算法构建的系统辨识模型相对误差小,具有较高的估计精度。图 13(a) 中锂电池类型预测的 RE 低于 0.30%, $MAPE = 0.03\%$, 分类准确率达到 99.97%。图 13(b) 为异构锂电池组 SOC 的预测结果,同样具有较高的估计精度,其中 RE 低于 0.50%, $MAPE = 0.06\%$, 模型的预测准确率达到 99.94%。以上结果验证了 MEA-BP 神经网络算法在锂电池预测中的优越性和可靠性。

锂电池的预测误差对比结果如图 14 所示。由图 14(a) 可知,在电池类型预测中,MEA-BP 神经网络模型的平均误差为 0.04%,最大误差为 0.17%;此外,MEA-BP 模型的平均误差相对于 PSO-BP、BP 模型分别下降了 29% 和 56%。由图 14(b) 可知,在锂电池 SOC 预测中,MEA-BP



(a) 锂电池类型预测的相对误差

(a) Relative error of lithium battery type prediction




(b) 锂电池 SOC 预测的相对误差

(b) Relative error of SOC prediction for lithium batteries


图 13 锂电池预测的相对误差

Fig. 13 Relative error of lithium battery prediction



(a) 电池类型预测误差

(a) The type prediction error of battery



(b) 电池 SOC 预测误差

(b) The SOC prediction error of battery

图 14 锂电池的预测误差

Fig. 14 Prediction error of lithium batteries

神经网络模型的平均误差为 0.03%,最大误差为 0.12%,其平均误差相对于 PSO-BP、BP 模型分别下降了 38% 和 66%;以上结果验证了所提算法在估计精度及鲁棒性的

有效性。

为验证所提 MEA-BP 神经网络算法,对异构锂电池组自适应充电的可行性与鲁棒性,搭建了四开关 Buck-Boost 变换器的实验样机,如图 15 所示,其中样机参数如

表 3 所示,控制系统以 DSP TMS320F28335 作为核心控制芯片,Code Composer Studio 用于 C 代码编写、编译,在 MATLAB/Simulink 中完成 MEA-BP 神经网络训练与参数优化,并生成 C 代码嵌入 DSP。




图 15 实验样机


Fig. 15 Diagram of the experimental prototype

表 3 实验样机参数及选型

Table 3 Parameters of experimental prototype	
样机参数	数值
输入电压/V	5~20
输出电压/V	2~20
开关频率/kHz	100
电感/ μH	33
输入电容/ μF	150
输出电容/ μF	150
功率开关管	MOSFET IPP045N10N3G
门极驱动芯片	UCC27624-Q1
控制器芯片	TMS320F28335


基于系统辨识模型对异构锂电池组 CC-CV 充电的实验结果,如图 16 所示,其中 PWM1、PWM2 为 MOSFET 管信号; I_{bat} 为充电电流; U_{bat} 为锂电池 CV 充电稳态电压;图 16(a)对单节磷酸铁锂电池进行识别后,确定的稳态 CV 充电电压为 3.65 V;图 16(b)对两节串联磷酸铁锂电池组进行识别充电,稳态 CV 充电电压为 7.30 V;图 16(c)、(d)分别对三元锂电池进行充电识别,均获得了对应的 CV 稳态充电电压。以上结果

表明所提算法能准确识别不同节数的异构锂电池组,并获得 CV 充电电压,从而驱动 FSBB 变换器自动切换至相应的工作模式,实现对异构锂电池组的自适应充电控制。




(a) 单节磷酸铁锂电池充电稳态波形

(a) Steady-state waveform of a lithium iron phosphate battery during charging




(b) 两节磷酸铁锂电池充电稳态波形


(b) Steady-state waveforms of two lithium iron phosphate batteries during charging




(c) 单节三元锂电池充电稳态波形
(c) Steady-state waveform of a ternary lithium battery during charging



(b) 单节磷酸铁锂电池60% SOC的充电波形
(b) The charging waveform of a lithium iron phosphate battery at 60% SOC



(d) 两节三元锂电池充电稳态波形
(d) Steady-state waveforms of two ternary lithium batteries during charging




(c) 两节三元锂电池20% SOC的充电波形
(c) Charging waveforms of two ternary lithium batteries at 20% SOC

图 16 锂电池的自适应充电实验波形

Fig. 16 The waveform of the adaptive charging experiment of the lithium battery

对不同初始 SOC 状态锂电池自适应充电的实验结果,如图 17 所示。其中图 17(a)、(b)分别为单节磷酸铁锂电池 $SOC = 20\%$ 、 $SOC = 60\%$ 初始充电阶段波形,所提算法均识别出了锂电池的类型,并驱动 FSBB 变换器稳定工作在降压模式;此外,图 17(c)、(d)进一步给出了对不同 SOC 状态的三元锂电池的测试结果,算法同样实现了准确识别与模式适配。以上结果表明,所构建的模型与控制系统,能够有效辨识不同 SOC 状态(涵盖磷酸铁锂和三元锂两种类型)的锂电池组。


为验证所设计样机在宽输入电压范围内的适应性,如图 18 所示,对两节串联三元锂电池组进行了不同输入电压下的自适应充电实验。由图 18(a)可知,当输入电压为 15.00 V,变换器工作在 Buck 模式;由图 18(b)可




(d) 两节三元锂电池60% SOC的充电波形
(d) Charging waveforms of two ternary lithium batteries at 60% SOC

图 17 锂电池的不同 SOC 的自适应充电实验波形
Fig. 17 The experimental waveforms of adaptive charging

知,当输入电压为 8.50 V,变换器工作在 Buck-T 模式;由图 18(c)可知,当输入电压为 8.00 V,变换器工作在 Boost-T 模式;由图 18(d)可知,当输入电压为 5.00 V,变换器工作在 Boost 模式。



(a) 单节磷酸铁锂电池20% SOC的充电波形
(a) The charging waveform of a lithium iron phosphate battery at 20% SOC



(a) $V_{in}=15.00\text{ V}$, Buck模式
(a) $V_{in}=15.00\text{ V}$, Buck mode




图18 宽范围自适应充电的实验波形

Fig. 18 Experimental waveform of wide-range adaptive charging

实验结果表明,所提出的系统辨识模型与样机能够有效适应宽范围输入电压变换,切换工作模式对锂电池自适应充电,验证了实验样机具备宽输入电压范围和宽输出电压的调节能力。

综合以上实验结果,基于 MEA-BP 神经网络算法构建的系统辨识模型,对异构锂电池组的预测误差低于 1%,验证了该模型在复杂场景下的鲁棒性与准确性,最后结合 FSBB 变换器与自适应充电控制策略,为异构锂电池组的自适应充电需求提供了有效技术解决方案。

4 结 论

针对军用便携式装备电源的异构性识别充电问题,提出一种基于 MEA-BP 神经网络的辨识方法,设计自适应充电策略,并结合四开关 Buck-Boost 变换器实验样机,

得到了有效解决。

1) 通过电池测试系统,分析两类主流 18650 型锂电池不同充电倍率下的充电数据,提取并确定了构建系统辨识模型的关键特征量,为构建模型精确识别提供了基础。

2) 针对 BP 神经网络存在收敛速度慢、识别精度差以及局部最优等问题,引用 MEA 算法对其初始权值与阈值进行全局优化,有效提升了模型的预测精度、收敛速度与鲁棒性,克服了传统方法的固有缺陷。

3) 基于实验表明,所提算法显著提升了锂电池类型与 SOC 的识别预测精度,最大识别误差控制在 1% 以内,且能够准确识别不同节数及不同初始 SOC 状态的异构锂电池组,并据此驱动 FSBB 变换器自动切换至对应的工作模式,实现自适应充电控制。

本研究内容对异构锂电池组识别充电问题具有重要意义。未来的研究将不同容量与容量老化等因素融入到建模过程,进一步提高算法的精度与适用性。

参考文献

- [1] FU Y M, XU J, SHI M J, et al. A fast impedance calculation-based battery state-of-health estimation method[J]. IEEE Transactions on Industrial Electronics, 2022, 69(7): 7019-7028.
- [2] MEJDOUBI A E, CHAOUI H, GUALOUS H, et al. Lithium-ion batteries health prognosis considering aging conditions[J]. IEEE Transactions on Power Electronics, 2019, 34(7): 6834-6844.
- [3] HUANG X R, MENG J H, LIU W J, et al. Lithium-ion battery lifetime extension with positive pulsed current charging[J]. IEEE Transactions on Industrial Electronics, 2024, 71(1): 484-492.
- [4] 王冉, 后麒麟, 石如玉, 等. 基于变分模态分解与集成深度模型的锂电池剩余寿命预测方法[J]. 仪器仪表学报, 2021, 42(4): 111-120.
WANG R, HOU Q L, SHI R Y, et al. Remaining useful life prediction method of lithium battery based on variational mode decomposition and integrated deep model[J]. Chinese Journal of Scientific Instrument, 2021, 42(4): 111-120.
- [5] 王超君, 陈翔, 彭思侃, 等. 锂离子电池发展现状及其在航空领域的应用分析[J]. 航空材料学报, 2021, 41(3): 83-95.
WANG CH J, CHEN X, PENG S K, et al. Analysis of the development status of lithium-ion batteries and their applications in the aviation field[J]. Journal of Aeronautical Materials, 2021, 41(3): 83-95.
- [6] MAMUN A A, LIU Z F, RIZZO D M, et al. An integrated design and control optimization framework for

- hybrid military vehicle using lithium-ion battery and supercapacitor as energy storage devices [J]. IEEE Transactions on Transportation Electrification, 2019, 5(1): 239-251.
- [7] 王新栋, 董政, 王书华, 等. 基于改进开路电压模型和自适应平方根无迹卡尔曼滤波的锂离子电池宽温度多工况 SOC 估计[J]. 电工技术学报, 2024, 39(24): 7950-7964.
- WANG X D, DONG ZH, WANG SH H, et al. State-of-charge estimation for lithium-ion batteries across wide temperature range and multiple working conditions based on improved open-circuit voltage model and adaptive square root unscented kalman filter algorithm [J]. Transactions of China Electrotechnical Society, 2024, 39(24): 7950-7964.
- [8] 梁叶, 蔡孟冶, 姜岩峰, 等. 基于修正安时积分法的锂电池荷电状态估算[J/OL]. 电源学报, 1-13[2026-03-14].
- LIANG Y, CAI M Y, JIANG Y F, et al. State of charge estimation of lithium battery based on modified ampere-hour in-tegral method[J/OL]. Journal of Power Supply, 1-13[2026-03-14].
- [9] WANG SH Q, OU K, ZHANG W, et al. A state-of-charge and state-of-health joint estimation method of lithium-ion battery based on temperature-dependent extended kalman filter and deep learning [J]. IEEE Transactions on Industrial Electronics, 2025, 72(1): 570-579.
- [10] LI Y, WEI ZH B, XIONG B Y, et al. Adaptive ensemble-based electrochemical-thermal degradation state estimation of lithium-ion batteries[J]. IEEE Transactions on Industrial Electronics, 2022, 69(7): 6984-6996.
- [11] 崔智昊, 王立国, 韦鑫, 等. 考虑采样失准的卡尔曼滤波改进神经网络锌溴液流电池状态估计策略[J]. 中国电机工程学报, 2024, 44(20): 8126-8136.
- CUI ZH H, WANG L G, WEI X, et al. Kalman filter improved neural network state of charge estimation strategy of zinc bromine flow battery considering sampling inaccuracy [J]. Proceedings of the CSEE, 2024, 44(20): 8126-8136.
- [12] 张小成, 郭强, 赵光焱, 等. 高寒环境下便携式移动电源多模态协同充电系统设计[J]. 仪器仪表学报, 2025, 46(6): 83-95.
- ZHANG X CH, GUO Q, ZHAO G Y, et al. Multiphysics-coupled synergistic charging system for lithium portable energy storage under extreme cold conditions[J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 83-95.
- [13] 谈发明, 赵俊杰, 李秋焯. 基于简化滞回 OCV 模型的锂电池 SOC 自适应估计策略[J]. 中国电机工程学报, 2021, 41(2): 703-715.
- TAN F M, ZHAO J J, LI Q Y. Adaptive SOC estimation strategy for lithium battery based on simplified hysteresis OCV model [J]. Proceedings of the CSEE, 2021, 41(2): 703-715.
- [14] CHEMALI E, KOLLMAYER P J, PREINDL M, et al. Long short-term memory networks for accurate state-of-charge estimation of li-ion batteries [J]. IEEE Transaction Industrial Electronics, 2018, 65(8): 6730-6739.
- [15] SONG X B, YANG F F, WANG D, et al. Combined CNN-LSTM network for state-of-charge estimation of lithium-ion batteries [J]. IEEE Access, 2019, 7: 88894-88902.
- [16] BIANCHI V, STIGHEZZA M, TOSCANI A, et al. An improved method based on support vector regression with application independent training for state of charge estimation [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-11.
- [17] 张振强, 马思乐, 姜向远, 等. 基于局部模型网络的锂电池 SOC 估计方法[J]. 仪器仪表学报, 2023, 44(7): 161-171.
- ZHANG ZH Q, MA S L, JIANG X Y, et al. State of charge estimation of lithium-ion batteries using local model network [J]. Chinese Journal of Scientific Instrument, 2023, 44(7): 161-171.
- [18] WADI A, ABDEL-HAFEZ M F, HUSSEIN A A, et al. Alleviating dynamic model uncertainty effects for improved battery SOC estimation of EVs in highly dynamic environments [J]. IEEE Transactions on Vehicular Technology, 2021, 70(7): 6554-6566.
- [19] 刘素贞, 任佳乐, 袁路航, 等. 磷酸铁锂电池荷电状态估计的多源数据特征提取[J]. 电工技术学报, 2025, 40(11): 3349-3361.
- LIU S ZH, REN J L, YUAN L H, et al. Multi-source data feature extraction method for state of charge estimation of LiFePO4 battery [J]. Transactions of the China Electrotechnical Society, 2025, 40(11): 3349-3361.
- [20] 钱伟, 王亚丰, 王晨, 等. 基于 BP 神经网络与 H_∞ 滤波的锂电池 SoH-SoC 联合估计研究[J]. 仪器仪表学报, 2024, 45(6): 307-319.
- QIAN W, WANG Y F, WANG CH, et al. Joint estimation of SoH-SoC for lithium battery based on BP neural network and H_∞ infinity filter [J]. Chinese Journal of Scientific Instrument, 2024, 45(6): 307-319.

- [21] 李卫硕, 孙剑, 陈伟. 基于 BP 神经网络机器人实时避障算法[J]. 仪器仪表学报, 2019, 40(11): 204-211.
LI W SH, SUN J, CHEN W. Real-time obstacle avoidance algorithm for robots based on BP neural network[J]. Chinese Journal of Scientific Instrument, 2019, 40(11): 204-211.
- [22] XU P H, WANG CH CH, YE J L, et al. State-of-charge estimation and health prognosis for lithium-ion batteries based on temperature-compensated Bi-LSTM Network and integrated attention mechanism[J]. IEEE Transactions on Industrial Electronics, 2024, 71(6): 5586-5596.
- [23] KIM K H, OH K H, AHN H S, et al. Time-frequency domain deep convolutional neural network for li-ion battery SOC estimation[J]. IEEE Transactions on Power Electronics, 2024, 39(1): 125-134.
- [24] LI N, HE F X, MA W T, et al. An indirect state-of-health estimation method based on improved genetic and back propagation for online lithium-ion battery used in electric vehicles[J]. IEEE Transactions on Vehicular Technology, 2022, 71(12): 12682-12690.
- [25] ZHANG Z P, FAN Y, TIAN J Q, et al. Online estimation of model parameters and state of charge for lithium-ion battery using multitimescale recurrent neural network[J]. IEEE Transactions on Industrial Electronics, 2025, 72(8): 8119-8129.
- [26] 陈媛, 段文献, 何怡刚, 等. 带降噪自编码器和门控递归混合神经网络的电池健康状态估算[J]. 电工技术学报, 2024, 39(24): 7933-7949.
CHEN Y, DUAN W X, HE Y G, et al. State of health estimation of lithium ion battery based on denoising autoencoder-gated recurrent unit[J]. Transactions of the China Electrotechnical Society, 2024, 39(24): 7933-7949.
- [27] 林海飞, 高帆, 严敏, 等. 煤层瓦斯含量 PSO-BP 神经网络预测模型及其应用[J]. 中国安全科学学报, 2020, 30(9): 80-87.
LIN H F, GAO F, YAN M, et al. Study on PSO-BP neural network prediction method of coal seam gas content

and its application[J]. China Safety Science Journal, 2020, 30(9): 80-87.

- [28] CHEN L P, SONG Y J, LOPES A M, et al. Joint estimation of state of charge and state of energy of lithium-ion batteries based on optimized bidirectional gated recurrent neural network[J]. IEEE Transactions on Transportation Electrification, 2024, 10(1): 1605-1616.
- [29] 郭强, 张帆云, 李海啸, 等. 高效四开关 Buck-Boost 变换器多模式控制策略[J]. 仪器仪表学报, 2024, 45(11): 101-116.
GUO Q, ZHANG F Y, LI H X, et al. High-efficiency four-switch Buck-Boost converter multi-mode control strategy[J]. Chinese Journal of Scientific Instrument, 2024, 45(11): 101-116.

作者简介



王龙军, 2021 年于沈阳化工大学获得学士学位, 现为重庆理工大学硕士研究生, 主要研究方向为锂电池识别充电。

E-mail: 52230712152@stu.cqut.edu.cn

Wang Longjun received his B.Sc. degree from Shenyang University of Chemical Technology in 2023. He is currently a master student at Chongqing University of Technology. His main research interests include lithium battery identification and charging.



郭强(通信作者), 2010 年于西南大学获得硕士学位, 2015 年于重庆大学获得博士学位, 现为重庆理工大学副教授, 主要研究方向为 PWM 整流器、混合微电网及储能系统等。

E-mail: guoqiang@cqut.edu.cn

Guo Qiang (Corresponding author) received his M. Sc. degree from Southwest University in 2010, and his Ph. D. degree from Chongqing University in 2015. He is currently an associate professor at Chongqing University of Technology. His main research interests include PWM rectifiers, hybrid microgrid and storage systems.