

DOI: 10.13718/j.cnki.xdzk.2024.12.002

朱建功, 张仁杰, 姜波, 等. 小样本条件下动力电池容量和内阻协同估计 [J]. 西南大学学报(自然科学版), 2024, 46(12): 14-23.

小样本条件下动力电池容量和内阻协同估计

朱建功, 张仁杰, 姜波, 戴海峰, 魏学哲

同济大学 汽车学院, 上海 201800

摘要: 锂离子电池的容量和内阻分别是表征电池系统能量和功率特性的重要参数, 准确估计容量和内阻对于电动汽车电池管理系统有至关重要的作用. 提出了一种数据驱动的电容量和内阻估计方法. 该方法首先从电池的恒流充电片段提取容量增量 (incremental capacity, IC) 特征, 经过重采样方法构建特征向量. 然后将 IC 特征输入弹性网络模型进行训练, 从而实现容量和内阻估计. 应用 KIT 数据集对所提方法进行验证. 结果表明: 该模型可以在相同特征输入下实现高精度的容量和内阻协同估计, 且在小样本训练 (仅使用 2 个电池作为训练集) 时保持容量估计误差在 2% 以内, 内阻的估计误差在 3% 以内. 最后提出了基于容量和内阻双参量的“三段式”电池评价方法.

关键词: 锂离子电池; 数据驱动; 容量和内阻估计; 小样本训练; 电池评价方法

中图分类号: TM912

文献标志码: A

开放科学(资源服务)标识码(OSID):



文章编号: 1673-9868(2024)12-0014-10

Data Driven Estimation of Capacity and Internal Resistance of Lithium-Ion Batteries

ZHU Jiangong, ZHANG Renjie, JIANG Bo,
DAI Haifeng, WEI Xuezhe

School of Automotive Studies, Tongji University, Shanghai 201800, China

Abstract: Capacity and internal resistance of lithium-ion batteries are important parameters that characterize the energy and power characteristics of battery system. Accurate estimation of capacity and internal resistance is crucial for electric vehicle battery management systems. Therefore, this article proposes a data-driven method for estimating battery capacity and internal resistance. This method first extracts incremental capacity (IC) features from the constant current charging segment of the battery, constructs feature

收稿日期: 2024-09-30

基金项目: 国家自然科学基金资助项目(52107230, 52377211).

作者简介: 朱建功, 博士, 副教授, 主要从事电动汽车动力电池系统失效管控的研究.

vectors through resampling, and then inputs IC features into Elastic Net model for training, thereby achieving capacity and internal resistance estimation. The proposed method is validated using the KIT dataset. The results show that the model proposed in this paper can achieve high-precision capacity and internal resistance estimation under the same feature input, and maintain capacity estimation error within 2% and internal resistance estimation error within 3% during small sample training (using only 2 batteries as the training set). Finally, a “three-stage” battery evaluation method based on dual parameters of capacity and internal resistance was proposed.

Key words: lithium-ion battery; data driven; capacity and internal resistance estimation; small sample training; battery evaluation method

为实现“力争 2030 年实现碳达峰, 2060 年实现碳中和”的“双碳”目标, 我国政府积极推动新能源汽车产业的发展。锂离子电池由于其能量密度高、循环寿命长、功率密度高和自放电率低等优点^[1-2]而被广泛用作电动汽车储能元件。锂离子电池的容量和内阻分别是表征电池系统能量和功率特性的重要参数。在电动汽车整车层面, 电池容量决定了一次充满电后电动汽车的最大行驶里程, 内阻则决定了电动汽车输出的最大功率; 在电池管理系统(battery management system, BMS)层面, 容量和内阻则是电池关键状态估计算法和寿命预测算法的必要输入。因此, 准确估计电池容量和内阻可以帮助用户实时了解电池状态, 帮助 BMS 更准确地评估电池系统性能。

电池容量和内阻的估计方法可以分为两大类^[3]: 基于模型的方法和数据驱动的方法。基于模型的估计方法的重点在于建立能够描述电池衰减过程的物理模型, 再结合电池的实验数据, 利用滤波算法^[4-6]更新模型参数, 从而实现电池的状态估计。这类方法的泛化能力有限, 且对参数的敏感性较高。数据驱动的方法通常不需要对电池机理深入理解, 而是基于大量电池实验数据, 应用机器学习算法拟合电池健康特征(health indicator, HI)与电池状态变量之间的复杂映射关系, 如相关向量机^[7]、梯度提升树^[8]以及各种神经网络算法^[9-10]。

随着计算机技术的发展, 数据驱动模型得到广泛关注。但现有的数据驱动模型通常仅聚焦电池单一状态的估计或预测, 且需要大量的实验数据训练模型, 导致数据收集的时间和经济成本较高。针对上述问题, 本文提出了一种基于弹性网络算法的电池容量和内阻估计模型, 提取充电片段的容量增量作为模型特征, 经过基于重采样的特征重构, 可以使用相同的特征实现高精度的容量和内阻协同估计, 并且对训练样本的需求量不大。本文还提出了基于容量和内阻双参量的“三段式”电池评价方法, 从而更全面地评价电池系统性能。

1 容量和内阻双参量提取

本文应用了德国卡尔斯鲁厄理工学院(KIT)公开的电池老化试验数据集^[11](下文简称 KIT 数据集)进行研究。KIT 数据集包含了 3 种不同正极材料的三元锂电池在不同温度和不同充放电倍率下循环测试的实验数据, 具体的实验设置可以参考文献[11]。本文使用了 KIT 数据集中的部分电池作为研究样本, 如表 1 所示, 并将表中所示 3 类电池样本分别简记为 NCM(25 °C)、NCM(45 °C)和 NCA(25 °C)。

表 1 本文选取的研究样本

正极材料	循环温度/°C	充/放电倍率(C/C)	电池数量/个
NCM	25	0.5/1	23
	45		28
NCA	25		19

数据集中电池一个完整的充放电循环包括 5 个部分,如图 1 所示,即(I)恒流(CC)充电、(II)恒压(CV)充电、(III)充电后的弛豫阶段、(IV)CC 放电和(V)放电后的弛豫阶段,充电弛豫阶段后的放电电流电压瞬态响应如图 1 中子图所示. 本文的电池容量以 CC-CV 充电的电流时间积分计算,电池的直流内阻由式(1)近似计算:

$$R = \frac{V_{\text{relaxation, end}} - V_{\text{CCdischarge, start}}}{I_{\text{CCdischarge}}} \quad (1)$$

式中: $V_{\text{relaxation, end}}$ 为充电后弛豫时间的最后一个采样点, $V_{\text{CCdischarge, start}}$ 为 CC 放电的第一个采样点, $I_{\text{CCdischarge}}$ 为 CC 放电电流. 图 2a 和图 2b 分别为 3 种电池随着循环次数增加而产生的容量衰减和内阻增加的示意图.

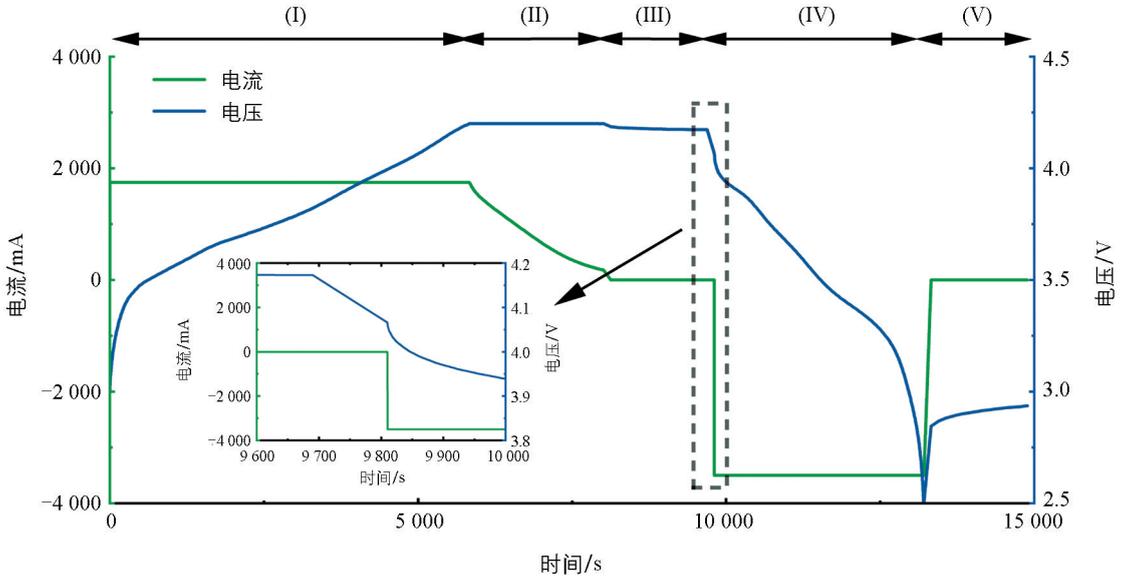


图 1 电池充放电的电流电压曲线

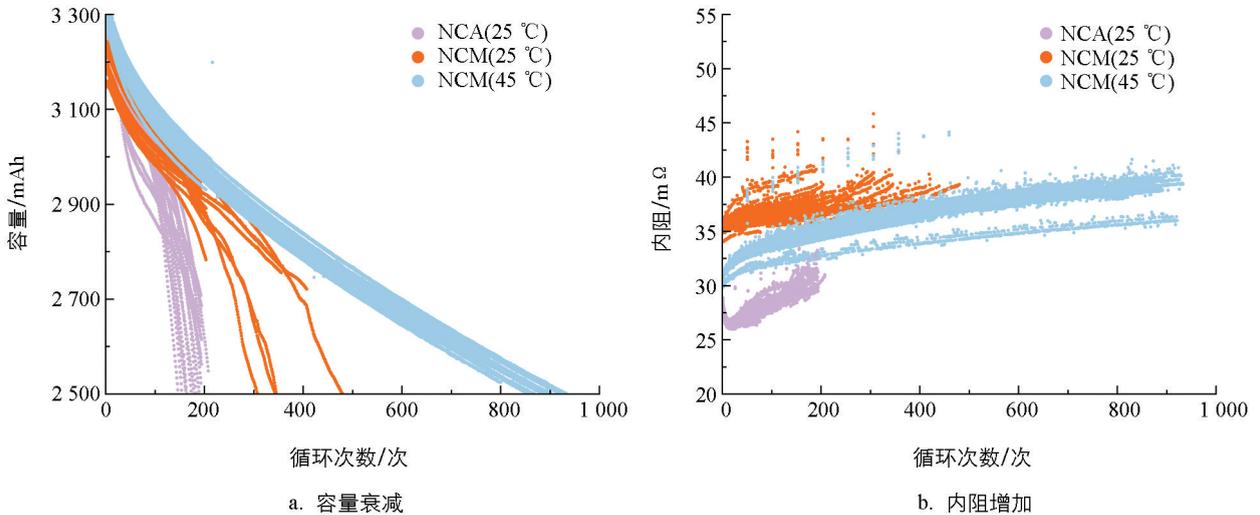


图 2 电池容量衰减和内阻增加图

2 容量增量特征构建

在电动汽车这一应用场景中,动力电池的放电过程受随机因素影响很大,难以从中提取出通用且稳定的数据特征来表征电池的健康状态^[12]. 相比之下,电池的充电过程都遵循特定的充电协议,其工况相对稳

定, 便于从中提取特征. 本文使用从恒流充电过程中提取的容量增量(incremental capacity, IC) 特征进行建模. IC 特征是一种与电池老化状态相关性极强的特征^[13], 在电池健康状态估计研究中应用广泛. IC 特征的计算方法为:

$$\frac{dQ}{dV} = \frac{\int I dt}{dV} \quad (2)$$

式中: t, I, V 和 Q 分别为电池充电过程中的时间、电流、电压和容量.

为了保证模型具有固定长度的输入, 进行了如下所述的重采样过程^[14]以重构特征向量. 用 $D^m = \{(t_i^m, I_i^m, V_i^m) \mid i=1, 2, \dots, n\}$ 表示 CC 充电过程中的时间、电流和电压的实测值集合, 其中: 上标 m 代表测量值, n 表示采样点总数, I_i^m 和 V_i^m 分别表示对应采样时刻 t_i^m 的电流和电压. 在一个指定的电压区间 $[V_l, V_h]$ 以相等的采样间隔 ΔV 取 k 个电压采样点, 则该区间的电压数据可表示为:

$$V = \{V_l, V_l + \Delta V, V_l + 2\Delta V, \dots, V_h\} = \{V_i \mid i=1, 2, \dots, k\} \quad (3)$$

式中: V_i 表示重采样后的电压, k 表示采样点数量. k 的计算方法为:

$$k = \frac{V_h - V_l}{\Delta V} + 1 \quad (4)$$

此时, 可以通过对 D^m 中与 V_i 数值最接近的电压实测值 V_i^m 和 V_{i+1}^m 及对应的采样时间 t_i^m 和 t_{i+1}^m 进行线性插值:

$$\frac{V_i - V_i^m}{V_{i+1}^m - V_i^m} = \frac{t_i - t_i^m}{t_{i+1}^m - t_i^m} \quad (5)$$

移项得到对应于重采样电压 V_i 的重采样时间 t_i :

$$t_i = \frac{V_i - V_i^m}{V_{i+1}^m - V_i^m} (t_{i+1}^m - t_i^m) + t_i^m \quad (6)$$

同理可得重采样电流 I_i 的计算公式为:

$$I_i = \frac{V_i - V_i^m}{V_{i+1}^m - V_i^m} (I_{i+1}^m - I_i^m) + I_i^m \quad (7)$$

根据式(1)到式(7), 对于 CC 充电过程中一个给定的电压区间 $[V_l, V_h]$ 和采样间隔 ΔV , 总能得到重采样的充电片段数据 $D = \{(t_i, I_i, V_i) \mid i=1, 2, \dots, k\}$, 从而可将式(2)所示的 IC 计算公式改写为:

$$\frac{dQ}{dV} = \frac{\int I dt}{dV} \approx \frac{I_i (t_{i+1} - t_i)}{V_{i+1} - V_i} \quad (8)$$

得到对应于重采样电压 V_i 的容量增量特征.

由于电动汽车用户充电行为的不确定性, 越接近满电时的充电数据有越大概率被获取, 因此本文仅使用电池 CC 充电至电压为 4.0~4.2 V 的片段数据计算 IC 特征, 即重采样的电压值区间为 $[4.0, 4.2]$, 使用的重采样间隔为 5 mV. 对于电池的每一个测试循环, 都有 40 个 IC 值作为模型输入特征.

3 基于弹性网络的电池容量和内阻估计

3.1 弹性网络算法原理

弹性网络(elastic net, EN)算法在本文被用作电池容量和内阻估计建模. EN 模型是一个线性回归模型, 是普通最小二乘法(ordinary least squares, OLS)的推广, 其基本的数学表达式为:

$$\hat{y}_i = \hat{\mathbf{w}}^T \mathbf{X}_i + \hat{b} \quad (9)$$

式中: \hat{y}_i 是样本 i 的容量或内阻估计值, \mathbf{X}_i 是样本 i 的 k 维特征向量, \hat{b} 是线性方程的截距, $\hat{\mathbf{w}}^T$ 表示 \mathbf{X}_i 的权重系数, 通过最小化如下的损失函数得到:

$$\hat{\mathbf{w}} = \arg \min_{\mathbf{w}} (\| \mathbf{y} - \mathbf{X}\mathbf{w} \|_2^2 + \alpha P(\mathbf{w})) \quad (10)$$

式中: $\arg \min(\cdot)$ 函数的作用是找到使函数值最小的 \mathbf{w} 值; \mathbf{y} 是表示电池容量或内阻真实值的 n 维向量 (n 是样本总数); \mathbf{X} 是 $n \times k$ 阶的系数矩阵, $\| \mathbf{y} - \mathbf{X}\mathbf{w} \|_2^2$ 是最小二乘法的计算公式; 正则化强度系数 α , 是一个非负标量, 用于控制正则化的强弱程度; $P(\mathbf{w})$ 是 EN 模型区别于 OLS 的正则化项. $P(\mathbf{w})$ 定义如下:

$$P(\mathbf{w}) = \left(\frac{1-\rho}{2} \| \mathbf{w} \|_2^2 + \rho \| \mathbf{w} \|_1 \right) \quad (11)$$

式中: $\| \mathbf{w} \|_1$ 和 $\| \mathbf{w} \|_2^2$ 分别表示 \mathbf{w} 的 L1 和 L2 范数, ρ 是正则化混合系数, 用于控制 L1 和 L2 正则项的权重, 取值范围在 0 到 1 之间.

3.2 模型超参数选择

为了获取合适的 EN 模型超参数, 即正则化强度系数 α 和正则化混合系数 ρ , 结合 K 折交叉验证 (K -fold Cross Validation) 技术和网格搜索方法进行模型超参数的选择.

K 折交叉验证的原理如图 3 所示. 将训练数据拆分成 K 个大小相等的子集进行 K 次迭代, 每个子集轮流做验证集, 其余子集合并做训练集, 迭代得到 K 个验证集的评价指标的均值作为交叉验证的最终结果. K 折交叉验证可以在数据量有限时提高数据的利用率, 使得模型的评估更稳健. 网格搜索是一种超参数选择方法. 其原理是, 遍历模型超参数的所有可能取值组合, 选择其中使得模型性能最佳的一组. 这一过程通常需要结合交叉验证使用, 以避免选择结果受数据划分的随机性影响而出现较大偏差. 由于网格搜索所需的计算量较大、耗时较长, 该方法通常在模型的超参数空间不大的情况下使用. 而对于仅有两个超参数的 EN 模型而言, 网格搜索的计算耗时是可接受的. 结合 K 折交叉验证的网格搜索确定 EN 模型的超参数: 对于容量估计, 正则化强度系数 α 取 42, 正则化混合系数 ρ 取 0.8; 对于内阻估计, 正则化强度系数 α 取 1, 正则化混合系数 ρ 取 0.4.

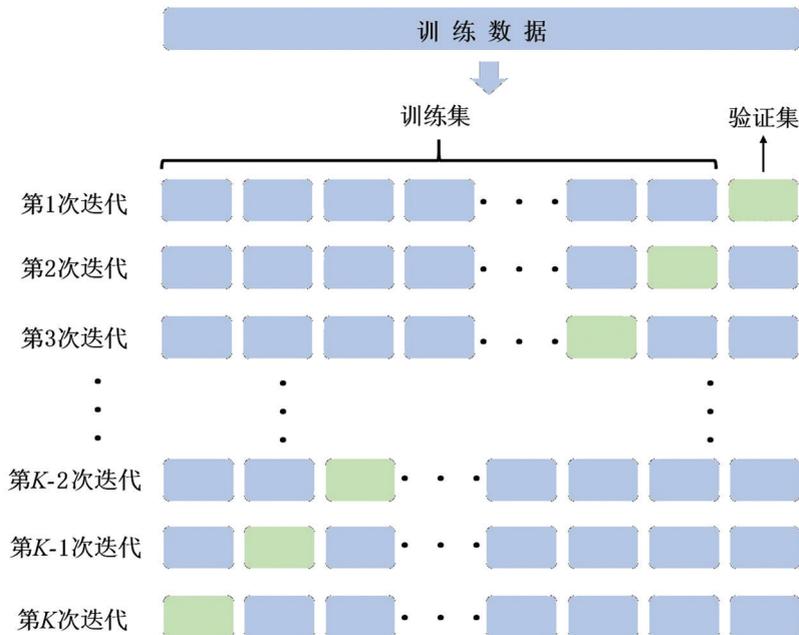


图 3 K 折交叉验证原理图

4 模型精度验证与分析

4.1 评价指标

本文采用了均方根误差 (root mean square error, RMSE) 和平均百分比绝对值误差 (mean absolute percentage error, MAPE) 来评价模型对容量和内阻的估计精度, 二者的定义分别为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (13)$$

式中: i 表示测试样本编号, n 表示测试样本总数, y_i 和 \hat{y}_i 分别表示对应于样本 i 的真实值和模型估计值.

4.2 模型精度验证

将建立的模型在前文所述 3 类电池上分别验证, 以 4 : 1 的比例按电池单体编号随机划分训练集和验证集. 由于不同电池单体之间存在差异, 为了降低数据划分的随机性对模型估计精度的影响, 实验重复进行了 10 次随机分组, 记录每次的模型估计结果, 以稳健地评估模型性能. 模型 10 次随机分组的容量和内阻估计 RMSE 和 MAPE 的均值、最佳情况和最差情况分别如表 2 和表 3 所示. 分析表 2 和表 3 可见, 模型在 NCM(25 °C)、NCM(45 °C) 和 NCA(25 °C) 3 类电池的容量和内阻估计上均取得了较高的估计精度, 容量估计的平均 MAPE 分别为 1.055%, 0.832% 和 0.610%, 内阻估计的平均 MAPE 分别为 1.238%, 0.946% 和 1.512%. 在 10 次随机分组的最差情况中, 容量估计 MAPE 均小于 1.5%, 内阻估计 MAPE 均小于 2.2%. 为了直观地展示随机分组的最佳情况和最差情况, 图 4 和图 5 分别展示了对应的可视化结果. 模型估计结果证明了本文建立的弹性网络模型可以在相同特征输入的情况下, 实现高精度的锂离子电池容量和内阻估计, 且有良好的鲁棒性.

表 2 容量估计的 RMSE 和 MAPE

	RMSE/mAh			MAPE/%		
	10 次均值	最佳	最差	10 次均值	最佳	最差
NCM(25 °C)	38.44	31.49	49.17	1.055	0.840	1.449
NCM(45 °C)	32.52	25.65	41.08	0.832	0.506	1.149
NCA(25 °C)	22.69	15.24	31.88	0.610	0.413	0.865

表 3 内阻估计的 RMSE 和 MAPE

	RMSE/mΩ			MAPE/%		
	10 次均值	最佳	最差	10 次均值	最佳	最差
NCM(25 °C)	0.612 1	0.440 1	0.902 1	1.238	0.941	1.607
NCM(45 °C)	0.462 3	0.356 5	1.012 2	0.946	0.778	1.819
NCA(25 °C)	0.508 3	0.333 1	0.700 3	1.512	0.963	2.144

4.3 模型在小样本训练下的估计结果

在实际应用中, 由于成本限制, 通常希望使用尽可能少的训练数据实现精确地建模. 因此本节探讨了模型在训练数据量较小的情况下, 模型的容量和内阻估计精度. 对于每一种类型的电池, 任取 5 个电池作为验证集, 在验证集不变的前提下, 逐渐扩大训练数据的规模, 即依次随机取 1 个、2 个、...、5 个电池作为训练集, 分析模型精度随训练样本规模增大的变化. 为了避免随机抽样对结果的影响, 实验重复进行了 10 次.

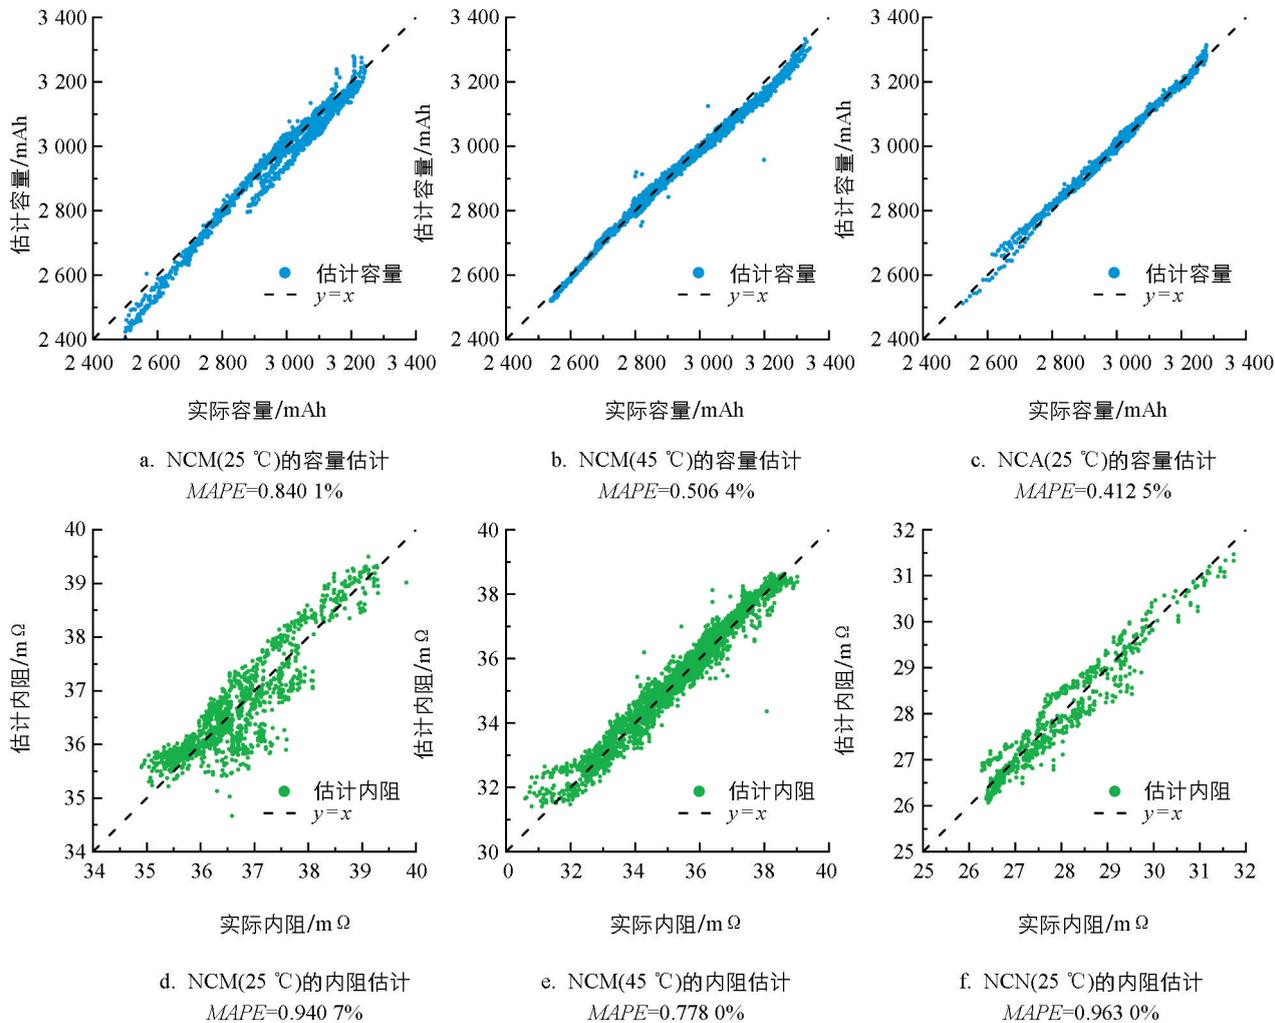


图 4 容量和内阻估计在 10 次随机分组的最佳情况

图 6 展示了模型的估计精度随训练样本数增加的变化。在仅有 1 个电池做训练样本时，模型容量和内阻估计结果的标准差较大，说明抽样的随机性对模型影响较大。这是由于训练集和验证集的数据分布不均造成的。而随着参与模型训练的电池数量的增加，容量和内阻估计的 MAPE 及其标准差均在降低。总体而言，对于每一种材料体系和温度工况的电池，仅需 2 个电池的实验数据用作模型训练，就可以保证容量估计的误差在 2% 以内，内阻估计的误差在 3% 以内，证明了本文建立的模型对训练样本数的需求量不大，可以有效地降低基于数据驱动建模的数据收集成本，对实际工程应用有一定参考价值。

5 基于容量和内阻双参量的评价方法

在建立的容量和内阻协同估计模型的基础上，本文提出了基于容量和内阻双参量的“三段式”电池评价方法，从而在两个维度评价电池的不一致性。图 7 展示了前文所述 3 种电池随着循环次数的增加，其容量衰减和内阻增加的散点图。由图 7 可知，电池的容量衰减和内阻增加随循环数的变化并非单一的线性关系，而且可以分成 3 个部分：区域(I)处于电池衰减初期，电池容量和内阻的相关性相对较弱，容量和内阻两维度的信息可以帮助在电池衰减初期进行更合理的电池分选；在电池老化的全生命周期中，还存在一个拐点将容量—内阻曲线分为(II)和(III)两个斜率明显不同的部分，说明在分界点附近电池的衰减机理发生了变

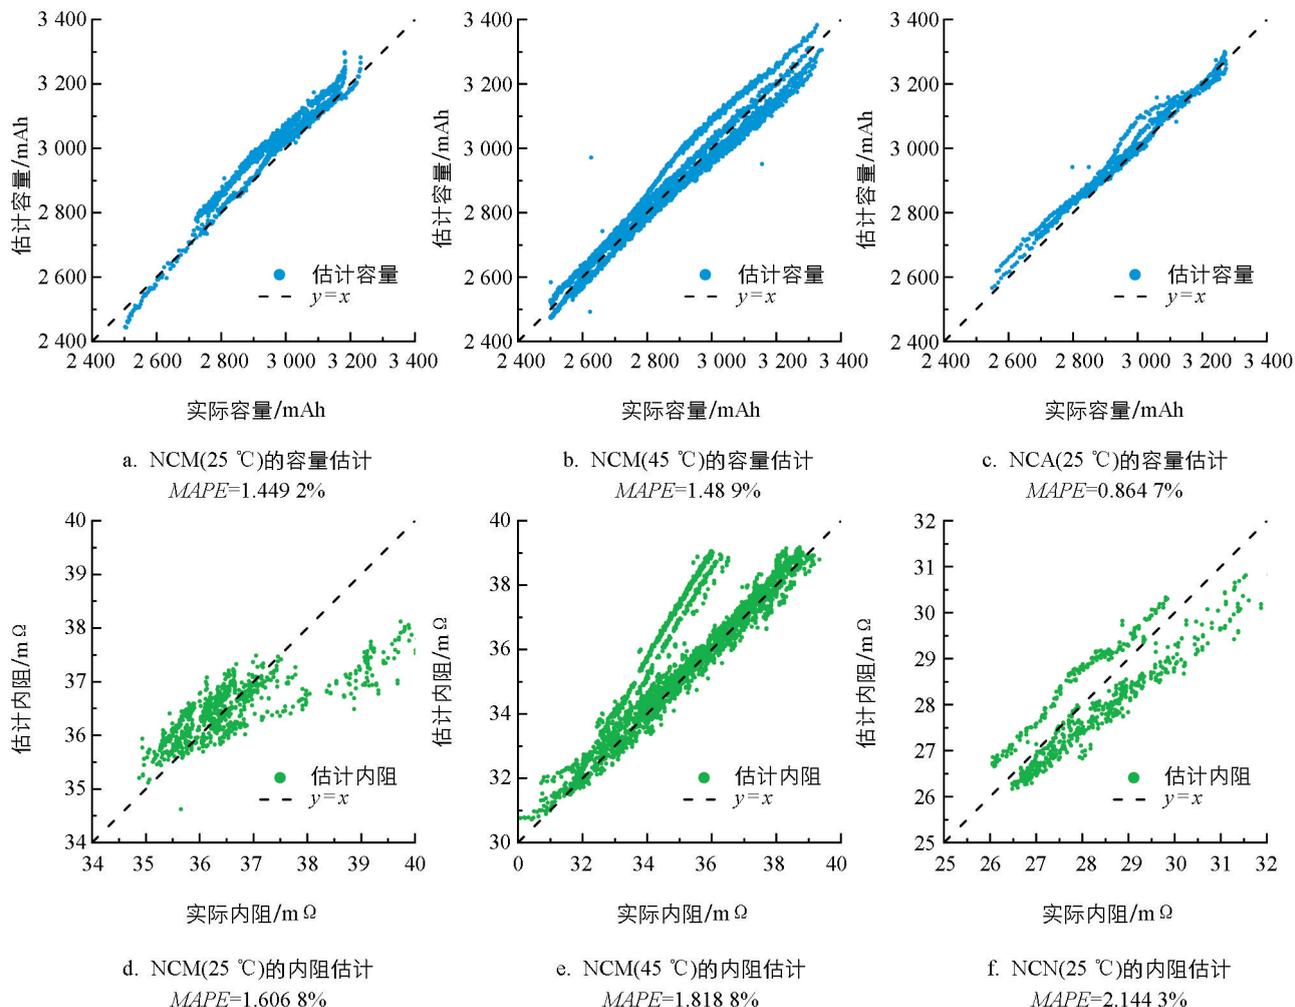


图 5 容量和内阻估计在 10 次随机分组中的最差情况

化, 导致电池的热力学和动力性特性的变化速率也随之改变. 电池容量和内阻双参量的“三段式”分析表明, 以往仅通过单一的电池容量参数来评价电池性能是片面的, 需要引入基于容量和内阻的双参量评价方法, 从能量特性和功率特性两方面更全面地评估电池系统性能.

6 结论

为了准确估计锂离子电池的容量和内阻, 本文提出了一种基于数据驱动和弹性网络算法的电池容量和内阻估计方法, 可以在相同特征输入下实现高精度的容量和内阻协同估计, 且在小样本训练时仍保持较高的估计精度. 从电池恒流充电至 4.0 V 到 4.2 V 电压区间的充电片段提取容量增量(IC)特征, 经过重采样过程重构特征向量, 训练弹性网络模型. 使用 KIT 数据集中 3 种不同材料体系和温度工况的电池进行验证. 研究表明, 使用相同的输入特征, 模型的容量估计误差在 1% 左右, 内阻估计误差在 1.5% 左右, 证明了本文模型在容量和内阻估计方面的优越性; 并且模型在小样本训练(仅使用 2 个电池训练模型)时, 可以保证容量估计的误差在 2% 以内, 内阻估计的误差在 3% 以内, 从而大大降低电池数据驱动建模的数据收集成本. 最后, 本文提出了基于容量和内阻双参量的“三段式”电池评价方法, 可以从两个维度更全面地评价电池系统性能.

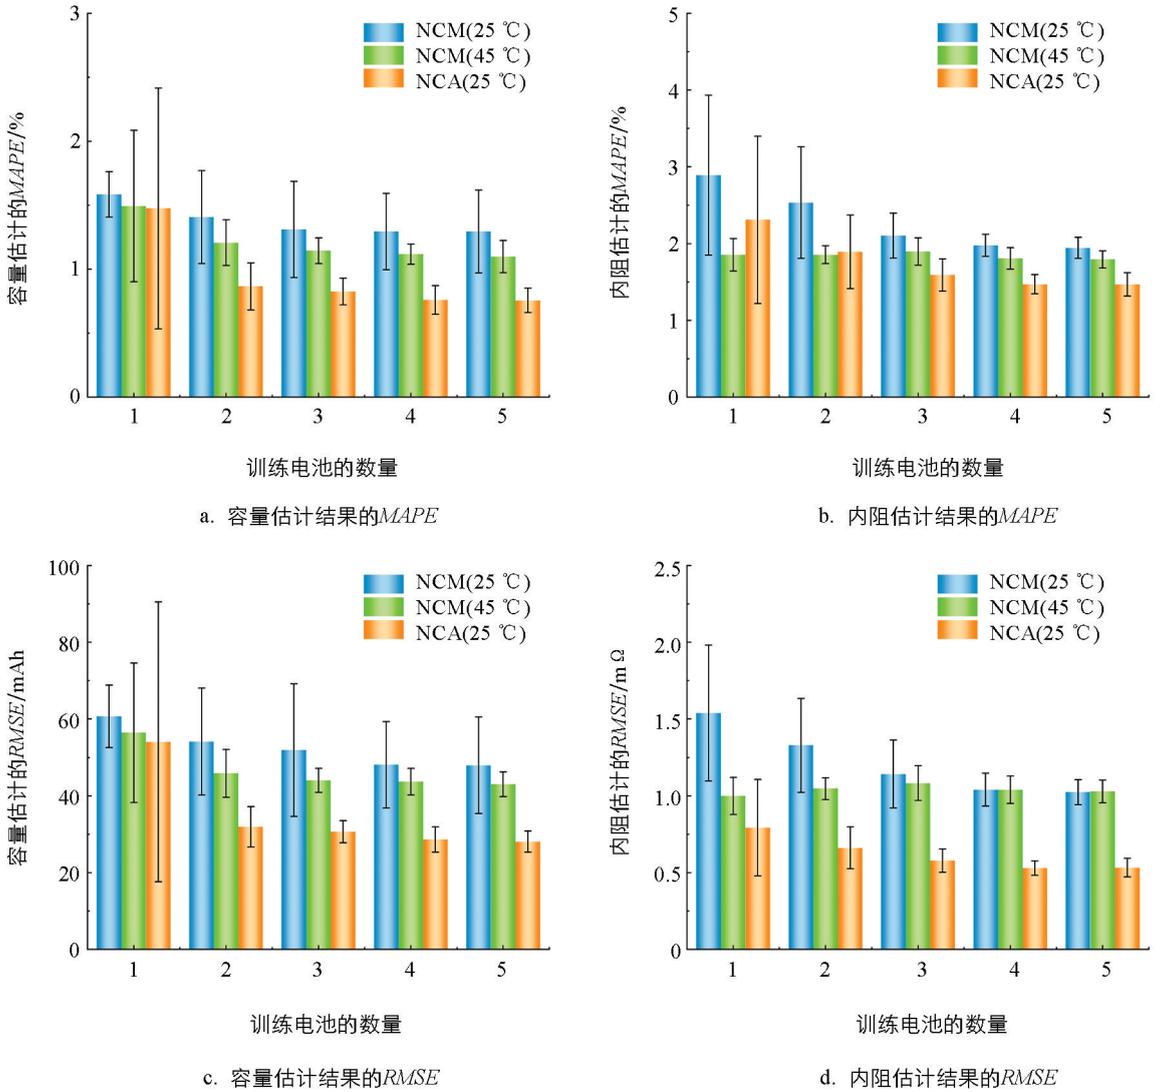


图 6 模型在小样本训练下估计精度随训练样本数增加的变化

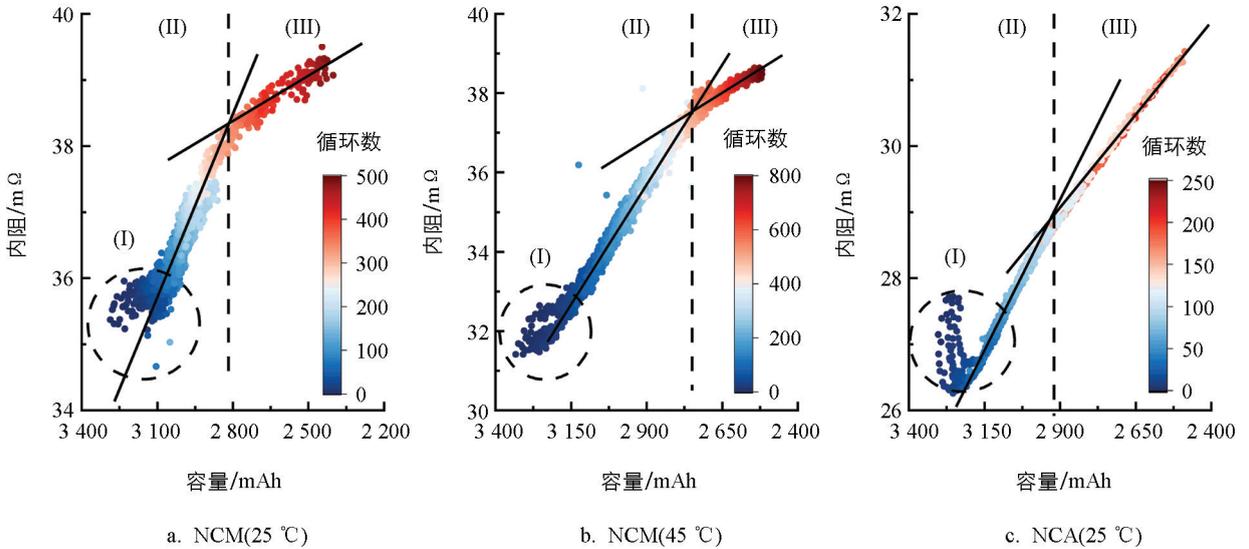


图 7 基于容量和内阻的电池二维评价体系

参考文献:

- [1] OPITZ A, BADAMI P, SHEN L, et al. Can Li-Ion Batteries Be the Panacea for Automotive Applications? [J]. *Renewable and Sustainable Energy Reviews*, 2017, 68: 685-692.
- [2] HAN X B, LU L G, ZHENG Y J, et al. A Review on the Key Issues of the Lithium Ion Battery Degradation among the Whole Life Cycle [J]. *ETransportation*, 2019, 1: 100005.
- [3] HASIB S A, ISLAM S, CHAKRABORTTY R K, et al. A Comprehensive Review of Available Battery Datasets, RUL Prediction Approaches, and Advanced Battery Management [J]. *IEEE Access*, 2021, 9: 86166-86193.
- [4] TULSYAN A, TSAI Y, GOPALUNI R B, et al. State-of-Charge Estimation in Lithium-Ion Batteries: a Particle Filter Approach [J]. *Journal of Power Sources*, 2016, 331: 208-223.
- [5] RAHIMIAN S K, RAYMAN S, WHITE R E. State of Charge and Loss of Active Material Estimation of a Lithium Ion Cell under Low Earth Orbit Condition Using Kalman Filtering Approaches [J]. *Journal of the Electrochemical Society*, 2012, 159(6): A860-A872.
- [6] FAN G D, LI X Y, ZHANG R G. Global Sensitivity Analysis on Temperature-Dependent Parameters of a Reduced-Order Electrochemical Model and Robust State-of-Charge Estimation at Different Temperatures [J]. *Energy*, 2021, 223: 120024.
- [7] JIANG B, DAI H F, WEI X Z, et al. Multi-Kernel Relevance Vector Machine with Parameter Optimization for Cycling Aging Prediction of Lithium-Ion Batteries [J]. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 2023, 11(1): 175-186.
- [8] YANG F F, WANG D, XU F, et al. Lifespan Prediction of Lithium-Ion Batteries Based on Various Extracted Features and Gradient Boosting Regression Tree Model [J]. *Journal of Power Sources*, 2020, 476: 228654.
- [9] TIAN J P, XIONG R, SHEN W X, et al. Flexible Battery State of Health and State of Charge Estimation Using Partial Charging Data and Deep Learning [J]. *Energy Storage Materials*, 2022, 51: 372-381.
- [10] REN L, DONG J B, WANG X K, et al. A Data-Driven Auto-CNN-LSTM Prediction Model for Lithium-Ion Battery Remaining Useful Life [J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(5): 3478-3487.
- [11] ZHU J G, WANG Y X, HUANG Y, et al. Data-Driven Capacity Estimation of Commercial Lithium-Ion Batteries from Voltage Relaxation [J]. *Nature Communications*, 2022, 13(1): 2261.
- [12] WANG Y X, ZHU J G, CAO L, et al. A Generalizable Method for Capacity Estimation and RUL Prediction in Lithium-Ion Batteries [J]. *Industrial & Engineering Chemistry Research*, 2024, 63(1): 345-357.
- [13] LIN C P, XU J, HOU J Y, et al. A Fast Data-Driven Battery Capacity Estimation Method under Non-Constant Current Charging and Variable Temperature [J]. *Energy Storage Materials*, 2023, 63: 102967.
- [14] WANG Y X, ZHU J G, CAO L, et al. Online Capacity Estimation of Lithium-Ion Batteries by Partial Incremental Capacity Curve [C] // 2022 IEEE Vehicle Power and Propulsion Conference (VPPC). New York: IEEE Press, 2022: 1-6.

责任编辑 张构