



## 计及退化阶段特征的服役电池容量预测

周涛, 缪书唯

(三峡大学电气与新能源学院, 湖北 宜昌 443002)

**摘要:** 精准预测锂电池容量对保证其安全稳定运行极为重要。为此, 本研究将锂电池简称为电池, 将已知全生命周期数据的电池称为测试电池, 正在使用中且数据有限的电池称为服役电池, 提出基于迁移学习且计及退化阶段特征的服役电池容量预测模型。首先, 采用双 Bacon-Watts 方法, 将测试电池全生命周期划分为早期、中期、末期3组退化阶段。接着, 构建电池阶段性匹配机制, 该机制根据测试电池早期容量数据与服役电池容量数据间的时间扭曲编辑距离, 通过两步筛选获得与服役电池适配的测试电池。在退化阶段划分的基础上, 通过识别测试电池当前阶段归属以及阶段内的相对位置信息, 刻画其阶段编码。随后, 应用多层感知机对阶段编码进行特征映射, 将映射后的阶段特征嵌入长短期记忆网络中, 同时引入加速退化损失项, 引导模型学习电池实际退化规律, 实现对测试电池的容量预测。最后, 将测试电池的预测模型参数进行微调, 并迁移至服役电池容量预测任务中。利用麻省理工学院公开数据集进行验证, 模型预测平均绝对误差、平均绝对百分比误差及均方根误差均低于1%, 为服役电池早期容量预测提供了可靠方案。

**关键词:** 锂离子电池; 测试电池匹配; 阶段退化; 加速退化; 迁移学习; 容量预测

doi: 10.19799/j.cnki.2095-4239.2025.0925

中图分类号: TM 912; TP 183

文献标志码: A

文章编号: 2095-4239 (2026) 04-1451-12

## Prediction of service battery capacity considering the characteristics of the degradation phase

ZHOU Tao, MIAO Shuwei

(College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, Hubei, China)

**Abstract:** Accurate prediction of lithium-ion battery capacity is of great significance for its safe and stable operation. Hence, this study refers to lithium-ion batteries as batteries, refers to batteries with known full-life cycle data as test batteries, refers to batteries currently in use with limited data as in-service batteries, and proposes an in-service battery capacity prediction model based on transfer learning that accounts for degradation phase characteristics. First, the double Bacon-Watts method is adopted to divide the entire life cycle of test batteries into three degradation phases: early, middle, and end phases. Subsequently, a phased matching mechanism for batteries is constructed. Based on the Time Warping Edit Distance between the early-stage capacity data of test batteries and the capacity data of in-service batteries, this mechanism obtains test batteries compatible with in-service batteries through a two-step screening process, providing high-quality data samples for subsequent model training. On the

收稿日期: 2025-10-20; 修改稿日期: 2025-11-17。

第一作者: 周涛 (2001—), 男, 硕士研究生, 研究方向为锂电池剩余容量预测, E-mail: 3303347080@qq.com; 通信作者: 缪书唯, 副教授, 研究方向为风电场并网系统可靠性评估与优化, E-mail: jabker@163.com。

引用本文: 周涛, 缪书唯. 计及退化阶段特征的服役电池容量预测[J]. 储能科学与技术, 2026, 15(4): 1451-1462.

**Citation:** ZHOU Tao, MIAO Shuwei. Prediction of service battery capacity considering the characteristics of the degradation phase[J]. Energy Storage Science and Technology, 2026, 15(4): 1451-1462.

basis of phase division, the phase code is characterized by identifying both the current phase attribution of the test battery and the relative position information within that phase. Then, a multi-layer perceptron is applied to perform feature mapping on the phase codes. The mapped phase features are embedded into a long short-term memory network, while an accelerated degradation loss term is introduced simultaneously to guide the model in learning the actual degradation law of batteries, thereby achieving capacity prediction for the test batteries. Finally, the prediction model parameters of the test batteries are fine-tuned and then transferred to the capacity prediction task of in-service batteries. Validation was conducted using the public dataset from the Massachusetts Institute of Technology. The model's prediction results show that the mean absolute error, mean absolute percentage error, and Root Mean Squared Error are all below 1%, providing a reliable solution for the early-phase capacity prediction of in-service batteries.

**Keywords:** lithium-ion batteries; test battery matching; stage degradation; accelerated degradation; transfer learning; capacity prediction

在全球能源转型与低碳发展的背景下, 锂电池作为新能源汽车、储能系统等领域的核心储能部件, 其性能稳定性与安全性备受关注<sup>[1]</sup>。电池生产制造时, 厂家会对锂电池开展老化实验, 可获取完整的全生命周期数据, 这类锂电池称为测试电池, 本研究将用户正在使用的锂电池称为服役电池。除特别说明外, 本研究电池均指锂电池。

目前, 国内外学者主要采用物理机理驱动与数据驱动两类方法预测电池容量<sup>[2]</sup>。数据驱动法无需分析电池内部机理, 通过挖掘电池的电压、电流等退化数据, 实现容量预测<sup>[3]</sup>, 实用性更强。其中, 深度学习方法<sup>[4]</sup>具有较强的时序建模能力, 在电池容量预测中得到广泛应用。文献[5]通过充电电压特征融合和注意力机制优化间接健康特征, 采用融合模型预测电池的容量。文献[6]提出的深度学习组合模型, 通过卷积神经网络的局部特征提取能力、高效局部注意力机制的自适应调整能力对输入的特征信息进行更充分提取。文献[7]利用堆叠噪声自编码器去噪, 提取电池退化特征。然而, 这类方法需要充足的电池容量、电压等退化数据训练, 迁移学习<sup>[8]</sup>为解决有限退化数据场景下的预测问题提供了新思路。文献[9]基于特征迁移的卷积神经网络模型, 提出通过卷积神经网络提取服役电池与测试电池的共享特征, 实现容量预测。文献[10]构建深度信念网络和长短期记忆神经网络(long short-term memory, LSTM)混合模型, 用于挖掘测试电池健康指标中的隐藏信息。文献[11]提出基于迁移学习的容量预测框架, 该框架通过三步相似性评价标准

选择匹配的测试电池。

但现有研究仍存在两方面不足: 第一, 常采用测试电池的全部容量数据与服役电池进行匹配, 但服役电池通常处于早期退化阶段, 而测试电池已经历早、中、末退化阶段, 该匹配方式可能导致匹配度较低<sup>[12]</sup>; 第二, 建模时未对电池容量退化的阶段性特征进行针对性提取与深入分析, 可能导致模型难以捕捉容量退化过程中的阶段性差异<sup>[13]</sup>。

针对上述问题, 本研究提出计及退化阶段特征的服役电池容量预测模型, 该模型提出测试电池阶段性匹配准则, 通过双 Bacon-Watts 划分得到测试电池容量退化的早、中、末期阶段。基于各测试电池与服役电池在容量及退化速率上的扭曲编辑距离, 提出两步筛选法确定匹配的测试电池。在阶段划分基础上, 对匹配的测试电池进行阶段编码, 得到阶段标识和相对循环位置, 将其拼接后经多层感知机(multilayer perceptron, MLP)池化并嵌入 LSTM 网络。同时, 损失函数的引入加速退化物理特性的约束项, 可表征电池容量退化随循环次数增大而加剧的现象。最终, 通过微调策略, 实现对服役电池的容量预测。

## 1 基于早期退化相似度的测试电池与服役电池匹配

本研究的服役电池处于早期退化阶段, 而测试电池经历了早、中、末期的容量退化阶段, 二者因所经历的退化阶段不同难以保持较高相似性。故本研究将测试电池的容量退化划分为3组阶段, 且仅

采用其早期退化阶段的容量与服役电池匹配。

### 1.1 基于拐点检测的测试电池退化阶段划分

锂电池退化早期因 SEI 膜稳定生长致容量缓降，中期受 SEI 膜破裂、活性物质溶解及导电性下降影响而衰退加快，末期则因锂枝晶刺穿隔膜、活性物质坍塌致容量骤降。容量退化的速率差异是该机理的外在体现，其退化数据的拐点可直观表征不同退化阶段的转换。

记某测试电池的最大循环次数为  $N$ ，容量随循环次数变化的时间序列为  $\mathbf{C}=(c_1, c_2 \cdots c_N)$ 。其中， $c_i$  为第  $i(i=1, 2 \cdots N)$  次循环时测试电池的容量。记第  $p^*$  次循环作为容量退化早期、中期的拐点，第  $q^*$  次循环作为容量退化中期、末期的拐点。

本研究应用双 Bacon-Watts 模型，拟合确定拐点  $p^*$  和  $q^*$  对应的循环次数，其表达式如下<sup>[14]</sup>：

$$\hat{c}_i = c_1 + \alpha_1(i - p^*) + \alpha_2(i - p^*) \tanh\left[\frac{(i - p^*)}{\gamma}\right] + \alpha_3(i - q^*) \tanh\left[\frac{(i - q^*)}{\gamma}\right] + Z \quad (1)$$

式中， $c_1$  为初始容量， $p^*$ 、 $q^*$  分别初始化为 0.3  $N$  和 0.7  $N$ ， $\alpha_1$  为线性退化斜率， $\alpha_2$ 、 $\alpha_3$  控制非线性变化， $\gamma$  为控制退化阶段平滑过渡的尺度因子， $Z$  为零均值、正态分布的随机扰动项。

本研究应用最小二乘法拟合式(1)中参数，初始参数设置参考文献[15]。其目标函数如下：

$$\min_{\alpha_0, \alpha_1, \alpha_2, \alpha_3, p^*, q^*, \gamma} \sum_{i=1}^N (c_i - \hat{c}_i)^2 \quad (2)$$

式中， $\hat{c}_i$  为式(1)中的计算值。

对式(2)拟合得到的  $p^*$ 、 $q^*$  向下取整得到  $p$ 、 $q$ ，以此近似表征容量退化过程中两个拐点对应的整数循环。该组测试电池容量序列可划分为早期容量序列  $\mathbf{C}_1=(c_1, c_2 \cdots c_p)$ 、中期容量序列  $\mathbf{C}_2=(c_{p+1}, c_{p+2} \cdots c_q)$  和末期容量序列  $\mathbf{C}_3=(c_{q+1}, c_{q+2} \cdots c_N)$ 。重复上述操作，可将  $K$  组测试电池的容量序列划分阶段，得到各组测试电池的早、中、末期容量序列  $\mathbf{C}_1^k$ 、 $\mathbf{C}_2^k$ 、 $\mathbf{C}_3^k$ ，其中， $k=1, 2 \cdots K$ 。

### 1.2 基于扭曲编辑距离的测试电池与服役电池匹配

记  $\mathbf{C}=(c_1^*, c_2^* \cdots c_M^*)$  为服役电池的早期容量序列。将 1.1 所得各测试电池早期退化容量数据  $\mathbf{C}_1^k$ ，用于相似度分析以及与服役电池匹配，并应用扭曲编辑距离(time warp edit distance, TWED)作为测试电池与服役电池的相似度指标。

根据文献[16]的 TWED 距离公式，基于容量和容量退化速率，计算测试电池与服役电池的 TWED 距离  $\delta$  和  $\zeta$ ，并进行测试电池的两步筛选。其中，退化速率近似为相邻循环的容量之差。

(1) 基于距离  $\delta$  的首次筛选。分别计算服役电池容量序列  $\mathbf{C}$  与各测试电池早期容量序列  $\mathbf{C}_1^k$  之间的 TWED 距离  $\delta$ ，得到  $K$  组测试电池的距离指标后，将该指标升序排序，选取距离指标最小的前 5 组测试电池进行下一步筛选。

(2) 基于距离  $\zeta$  的再次筛选。计算容量序列前后两次循环次数的容量之差，可得服役电池容量退化速率序列  $\mathbf{S}=(c_2^*-c_1^*, c_3^*-c_2^* \cdots c_M^*-c_{M-1}^*)$ ，以及首次筛选的 5 组测试电池退化速率序列  $\mathbf{S}^1, \mathbf{S}^2 \cdots \mathbf{S}^5$ 。分别计算  $\mathbf{S}$  与  $\mathbf{S}^1, \mathbf{S}^2 \cdots \mathbf{S}^5$  间的 TWED 距离  $\zeta$ ，得到 5 组测试电池的距离指标后，依据该距离指标最小值，选择最优电池样本作为匹配的测试电池。

## 2 计及退化阶段和加速退化物理特性的电池容量演化规律挖掘

在 1.1 节基础上，对匹配的测试电池进行阶段编码，应用多层感知机池化包含退化阶段特征的阶段编码后，嵌入 LSTM 网络挖掘退化规律，并在损失函数中引入物理约束项。

### 2.1 应用多层感知机池化测试电池的阶段编码

确定匹配的测试电池后，在划分阶段的基础上进行阶段编码。记  $\mathbf{g}$  为阶段标识向量，用于表示各循环次数对应的退化阶段； $\mathbf{r}$  为相对循环向量，表示各循环次数在其所属退化阶段内的相对循环位置。二者具体编码如下所示：

$$\mathbf{g} = (\underbrace{1, 1 \cdots 1}_{1, 2 \cdots p}, \underbrace{2, 2 \cdots 2}_{p+1, p+2 \cdots q}, \underbrace{3, 3 \cdots 3}_{q+1, q+2 \cdots N}) \quad (3)$$

$$\mathbf{r} = (\underbrace{1, 2 \cdots p}_{1, 2 \cdots p}, \underbrace{1, 2 \cdots q - p}_{p+1, p+2 \cdots q}, \underbrace{1, 2 \cdots N - q}_{q+1, q+2 \cdots N}) \quad (4)$$

式中，下括注为各编码对应的循环次数。

鉴于匹配的测试电池与服役电池在容量退化过程具有较高相似性，二者的退化阶段编码可近似视为一致。

对阶段编码进行最大最小值归一化时，可将  $\mathbf{g}$  内元素映射至区间[-0.5, 0.5]；而对于  $\mathbf{r}$ ，其元素取值由各阶段包含的循环次数决定，不同阶段的元素最大值可能存在较大差异。若对  $\mathbf{r}$  进行整体归一化，会掩盖编码  $\mathbf{r}$  的部分信息，需根据  $\mathbf{r}$  中各元素所对

应的阶段标识  $g(g=1,2,3)$  不同, 将  $r$  划分为  $r_1$ 、 $r_2$ 、 $r_3$ , 再进行归一化处理。

$$\begin{cases} \bar{g} = \frac{g-3}{3-1} - 0.5 \\ \bar{r}_g = \frac{r_g-1}{l_g-1} - 0.5 \end{cases} \quad (5)$$

式中,  $l_g$  为  $r$  中各阶段元素的最大值, 其值分别为  $p$ 、 $q-p$ 、 $N-q$ 。

记  $\bar{r} = [\bar{r}_1; \bar{r}_2; \bar{r}_3]$ , 将归一化后的向量拼接为  $V = [\bar{g}; \bar{r}]$ , 共同作为 MLP 的输入。模型的输出为:

$$\hat{V} = \sigma[\sigma(V \cdot W_1 + b_1) \cdot W_2 + b_2] \quad (6)$$

式中,  $W_1$ 、 $W_2$  为权重矩阵,  $b_1$ 、 $b_2$  为偏置项, 均为可学习参数;  $\sigma$  表示线性整流函数。

## 2.2 嵌入退化阶段编码的长短期记忆神经网络

本部分将 2.1 经 MLP 池化后的退化阶段编码嵌入 LSTM, 引导神经网络学习容量退化的阶段性特征。如图 1 红色虚线框所示, 通过调整门控机制, 将  $\hat{V}$  引入 LSTM 的门控计算与状态更新过程。




图1 嵌入退化阶段编码的LSTM单元结构

Fig. 1 The embedding degradation stage encodes the LSTM unit structure

具体而言, 退化阶段编码  $\hat{V}$  并非简单直接拼接于模型输入层, 而是作为反映电池内部退化物理状态的特征, 与上一时刻的输入门控信号  $i_{t-1}$  进行特征融合后, 共同传递至更新门参与后续计算。该连接设计使得  $\hat{V}$  通过输入门、遗忘门、输出门的权重矩阵直接影响各门控决策: 在输入门环节, 当前时间步输入  $x_t$  与上一时间步隐藏状态  $h_{t-1}$  先进行维度拼接, 经激活函数 Sigmoid 初步生成基础激活特征  $i_t$ , 随后与  $\hat{V}$  进行特征融合, 生成携带历史门控决策经验与当前退化物理信息的最终输入门激活特征  $\tilde{i}_t$  ( $\tilde{i}_t = i_t + \hat{V}$ ), 该特征直接参与细胞状态更新的计算, 即  $C_t = f_t \cdot C_{t-1} + \tilde{i}_t \cdot \tilde{C}_t$ , 使当前循环的电池退化阶段信息融入模型新信息编码过程, 完成旧信

息筛选与新信息注入的动态平衡; 同时, 通过  $C_t$  输出值与遗忘门相关联, 动态调节历史状态  $C_{t-1}$  中相关退化信息的保留比例——例如当  $\hat{V}$  指示电池进入加速退化阶段时,  $f_t$  会适应性提升, 优先保留近期与退化机制强相关的关键时序特征, 弱化早期无关状态的干扰; 随后, 细胞状态  $C_t$  经  $\tanh$  激活函数后传递至输出门, 如  $h_t = o_t \cdot \tanh(C_t)$  所示, 确保精准筛选出  $C_t$  与当前退化阶段的关键信息, 生成当前时间步隐藏状态  $h_t$ , 并传递至下一时间步参与循环计算。这一设计使模型可基于包含物理特征的退化阶段编码, 主动调整对电池容量时序数据中关键信息的遗忘、输入和输出策略, 而非被动依赖时序数据中隐含的、缺乏物理解释性的特征模式。本研究设计逻辑通过式(7)直观体现, 模型其余部分的工作原理与传统 LSTM 单元结构保持一致, 具体公式如下。

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{i}_t = i_t + \hat{V} \\ \tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ C_t = f_t \cdot C_{t-1} + \tilde{i}_t \cdot \tilde{C}_t \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = o_t \cdot \tanh(C_t) \end{cases} \quad (7)$$

式中,  $f_t$ 、 $i_t$ 、 $o_t$ 、 $C_t$  分别为遗忘门、输入门、输出门和更新门的输出。

## 2.3 嵌入物理惩罚项的长短期记忆神经网络损失函数

为表征电池容量退化速率随循环次数增加而逐渐加快的现象, 本研究在传统均方误差(mean square error, MSE)损失函数的基础上, 引入了加速退化损失项。模型应用批次训练策略, 批次大小设定为  $H$ 。在每个批次内, 容量数据均按照电池循环次数的先后顺序排列, 以此确保容量退化数据的时序关联性。模型应用滑动窗口预测方法, 将前  $T$  次循环的容量数据输入本模型, 以预测电池下一次循环的容量, 本模型的具体结构将在 3.1 节详细介绍。

以某批次为例, 具体如图 2(a) 所示, 通过窗口的滑动实现逐步迭代预测过程。图中虚线左侧为历史容量数据, 右侧为预测容量数据; 其中, 绿色区域代表输入本模型的窗口内容容量数据, 橙色区域则对应该窗口输出的预测容量, 绿色箭头示意窗口的滑动机制。每完成滑动一次, 需剔除上一窗口的首个数据, 并将该窗口对应的预测值作为新数据补充

至窗口末尾，以此循环迭代，直至完成  $l$  次滑动，最终得到第  $l$  次循环的预测容量。将图 2(a) 中的  $l$  个预测值，按循环次数整合为时序预测序列，并在此基础上生成长度递增的子序列，如图 2(b) 所示。图中蓝色箭头代表了子序列的生成过程：各子序列按时序依次构建，每个子序列均在前一个子序列的基础上滑动扩增一个预测值。具体而言，第一个子序列  $\hat{c}'_1$  包含前 3 次循环的预测值，第二个子序列  $\hat{c}'_2$  包含前 4 次循环的预测值，以此类推，最后一个子序列  $\hat{c}'_{l-3}$  包含整个预测序列。其中， $l$  为预测序列的长度。随后，对每个子序列进行二次函数拟合，通过最小二乘求解二次项系数  $a_t$ 。

$$a_t = \arg \min_{a_t, b_t, c_t} \sum_{x=1}^l [\hat{c}'_x - (a_t x^2 + b_t x + c_t)]^2 \quad (8)$$

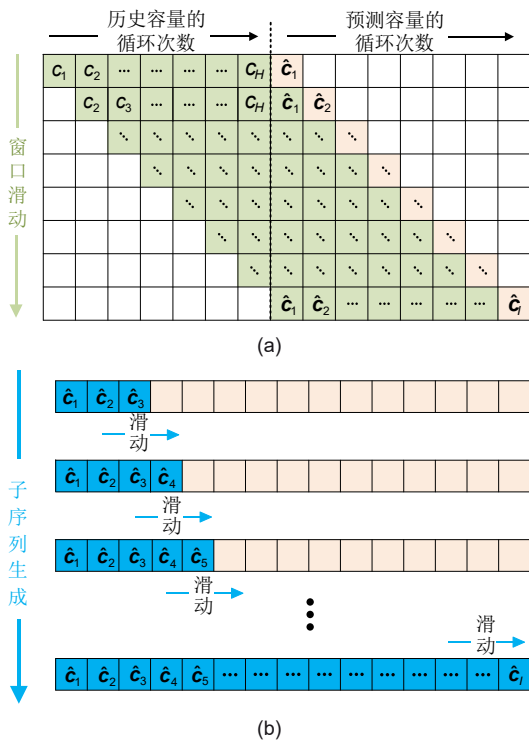


图 2 物理惩罚机制下的电池容量预测子序列生成：(a) 滑动窗口机制；(b) 子序列生成

Fig. 2 Generation of battery capacity prediction subsequences under the physical punishment mechanism: (a) Sliding window mechanism; (b) subsequence generation

若  $a_t < 0$ ，表明该批次内预测所得的容量呈现加速退化特征，反之则不满足该特征需进行惩罚。设计惩罚项如下：

$$L_{acc} = \frac{1}{H} \frac{1}{l-3} \sum_{i=1}^H \sum_{t=1}^{l-3} \max(0, a_t) \quad (9)$$

式中： $a_t$  为式(8)的计算值。

最终，计及加速退化特性的损失函数可表示为：

$$L_{total} = L_{mse} + \theta L_{acc} \quad (10)$$

式中， $\theta$  为用于平衡两个约束的参数。其中， $L_{mse}$  为预测均方误差，公式如下：

$$L_{mse} = \frac{1}{N} \sum_{i=1}^N (\hat{c}_i - c_i)^2 \quad (11)$$

利用测试电池全量容量数据，以总损失  $L_{total}$  为优化目标训练模型，并引入早停机机制：当损失连续 10 次未出现下降时，判定模型训练达到收敛，随即终止训练流程，完成模型训练。

### 3 基于模型迁移的服役电池容量预测

基于 2.2 节构建容量预测模型，通过匹配的测试电池容量数据训练模型后，将模型参数微调并实现服役电池的容量预测。

#### 3.1 基于微调策略的容量迁移预测

本研究构建的电池容量预测模型采用双输入-单输出结构，核心在于融合两类输入特征：时序容量数据与退化阶段编码。模型主体由两层 LSTM 单元(如 2.3 节所述)以及两层全连接层构成，并引入计及加速退化特性的损失函数。

模型利用匹配的测试电池训练后，通过冻结 LSTM 层并微调全连接层实现参数迁移。如图 3 所示，该过程主要包括模型训练与模型迁移两部分，使模型适配于服役电池的容量预测任务。其中，LSTM 层已从通用数据习得普适性容量退化共性时序规律，冻结可保护该知识并避免数据有限时过拟合；而全连接层微调以适配目标任务因电池类型、服役环境不同产生的个性特征，实现共性与个性匹配，提升预测精度。

在微调阶段，引入最大均值差异 (mean squared error, MMD) 作为域自适应正则项。MMD 通过对比测试电池与服役电池样本在特征空间的分布一致性，实现对服役电池特征的有效对齐与自适应优化，从而减小领域偏移对预测性能的影响。具体公式为<sup>[17]</sup>：

$$\begin{aligned} L_{MMD} &= \text{MMD}^2(\mathbf{X}, \mathbf{Y}) = \left\| \frac{1}{N} \sum_{i=1}^N \varphi(x_i) - \frac{1}{n} \sum_{j=1}^n \varphi(y_j) \right\|_H^2 \\ &= \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N \psi(x_i, x_j) - \frac{2}{Nn} \sum_{i=1}^N \sum_{j=1}^n \psi(x_i, y_j) + \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n \psi(y_i, y_j) \end{aligned} \quad (12)$$

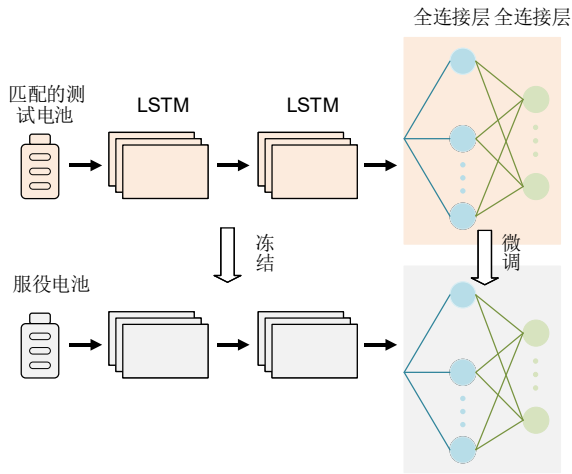


图3 迁移策略  
Fig. 3 Migration strategy

式中， $\mathbf{X}$ 和 $\mathbf{Y}$ 分别为测试电池与服役电池的容量经第一层全连接层映射得到的特征， $N$ 和 $M$ 为特征样本长度， $\varphi$ 为映射函数。其中， $\Psi$ 为高斯核函数，公式如下：

$$\psi(x,y) = e^{-\frac{|x-y|^2}{2\mu^2}} \quad (13)$$

式中， $\mu$ 为高斯核函数的宽度参数。

微调阶段的总损失 $L'_{total}$ 可表示为：

$$L'_{total} = (1 - \beta)L_{mse} + \beta L_{MMD} + \theta L_{acc} \quad (14)$$

式中， $L_{MMD}$ 为跨域正则项；参数 $\beta$ 为权重因子，用于平衡目标域拟合与跨域对齐的影响程度。

综上所述，本研究首先利用匹配的测试电池容量数据进行模型训练，待训练完成后冻结模型中LSTM层的权重参数，将固定LSTM层权重的模型保存，作为后续迁移学习的基础模型。在此基础上，以微调总损失 $L'_{total}$ 为目标函数，用部分服役电池容量数据对上述基础模型进行二次训练，引入早停机制，当损失连续10次未出现下降时，判定模型训练达到饱和，进而完成对模型可训练参数的微调优化。最后，通过逐步迭代预测，即可实现服役电池的容量预测任务。

### 3.2 基于微调策略的容量迁移预测流程

本部分构建基于迁移学习的预测框架，具体步骤如下。

步骤一，根据1.1节中方法对测试电池容量序列进行退化阶段划分，将 $K$ 组测试电池的容量退化划分为早期、中期和末期。

步骤二，选取各测试电池的早期阶段容量，基于TWED距离，通过1.2节提出的两步筛选法进行

相似度筛选，确定与服役电池匹配的测试电池。

步骤三，按2.1节将测试电池阶段信息进一步编码，并将阶段特征编码拼接为 $\mathbf{V}$ 后输入多层感知机，生成包含阶段信息的高维特征向量并嵌入LSTM网络。

步骤四，基于2.2节内容搭建预测模型。预测模型采用“双层LSTM+两层全连接层”架构，并应用2.3节提出的总损失函数。

步骤五，将匹配的测试电池容量数据进行最大最小值归一化，随后，用于预训练模型。

步骤六，保存已训练好的模型，基于3.2节的微调策略实现服役电池容量预测任务，服役电池容量数据沿用匹配的测试电池归一化准则。基于服役电池已知的容量数据，联合最小化拟合误差与MMD损失进行微调训练。

步骤七，利用微调后的模型对服役电池容量序列进行逐步迭代预测，生成完整的容量退化轨迹。

## 4 算例分析

### 4.1 麻省理工学院锂电池数据集

本研究使用的锂电池数据集来自麻省理工学院开展的加速老化试验，包含124个锂电池在快速充电条件下的循环测试，该数据集所用电池的详细信息可参见表1<sup>[16]</sup>。

表1 电池规格参数

Table 1 Battery specifications

参数	规格
电池类型	APR18650MIA
阴极/阳极	磷酸铁锂/石墨
标称容量/标称电压	1.1 Ah/3.3 V
环境温度/°C	30
截止电压/V	3.6、2

针对数据集中存在的突变点，本研究将其界定为异常值，并采用异常值前后相邻数据点的平均值对该异常数据进行替换修正，以消除突变干扰。经上述预处理后，部分锂电池的容量退化曲线如图4所示，该数据集可分为三个批次，各批次由“批次日期”定义，不同批次在试验设计中工况存在差异。

### 4.2 测试电池匹配结果

本部分从4.1节所述数据集中，随机选取覆盖3个批次的5组电池作为待预测的服役电池，且假

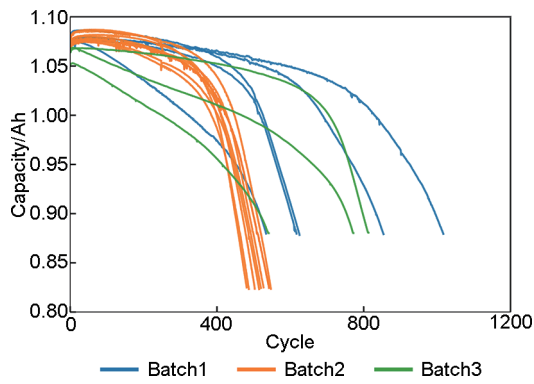


图 4 电池容量退化曲线

Fig. 4 Battery capacity degradation curve

设仅已知其前 30% 的容量样本，后 70% 的容量样本均未知。随后，应用本研究提出的测试电池匹配准则，从涵盖 3 个不同批次的 149 组测试电池中，筛选出与各服役电池匹配的测试电池。

具体的匹配结果如表 2 所示。由表可见，所匹配的测试电池与服役电池源自同一批次，该匹配策略可确保二者具备高度相似的容量退化特征，从而为模型迁移过程中退化特征的有效传递提供保障。其中，068\_CH38 为电池编号，源于“FastCharge\_000068\_CH38\_structure”文件<sup>[10]</sup>的缩写，其余电池编号也类似生成。

表 2 测试电池匹配结果

Table 2 Test the battery matching results

服役电池		测试电池	
批次	编号	批次	编号
批次 2 (2017-6-30)	068_CH38	批次 2 (2017-6-30)	070_CH46
批次 3 (2018-4-12)	015_CH44	批次 3 (2018-4-12)	006_CH43
批次 3 (2018-4-12)	002_CH34	批次 3 (2018-4-12)	012_CH5
批次 1 (2017-5-12)	067_CH41	批次 1 (2017-5-12)	067_CH42
批次 1 (2017-5-12)	065_CH33	批次 1 (2017-5-12)	039_CH27

以 068\_CH38 电池作为服役电池样本，首先需对测试电池容量数据进行拐点检测。如图 5 所示，蓝色虚线为 071\_CH40 电池的拐点检测结果。可以看出，拐点检测以电池实际容量的退化速率变化为依据，通过捕捉退化速率突变节点，实现对测试电池容量退化阶段的划分。图中，红色曲线代表服役电池已知容量数据的退化曲线，黑色曲线为两步筛

选准则筛选出的测试电池容量退化曲线，且已标注出该测试电池容量退化的拐点位置。可以看出，筛选所得测试电池与对应服役电池的容量曲线，在拐点  $p$  之前的退化阶段呈现出高度相似的变化趋势。可合理推断，在后续的容量快速退化阶段，服役电池的容量退化趋势将与该测试电池的退化规律有一致性。

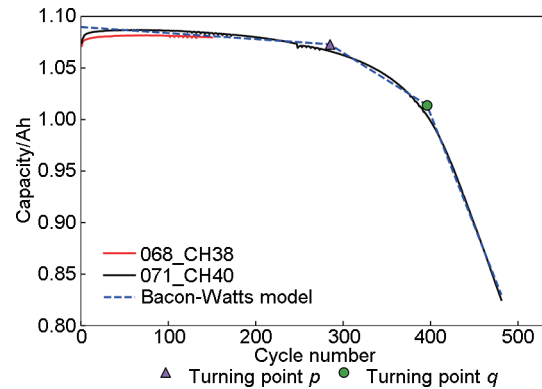


图 5 测试电池匹配

Fig. 5 Test battery matching

### 4.3 模型验证与消融实验

本研究的数值实验在 64 位操作系统、AMD Ryzen 3200G 处理器、DDR 内存、Python 3.7.16、TensorFlow 2.11.0 等软硬件平台上完成，未启用 TensorFlow 显卡加速功能。基于上述平台，完成 3.2 中的全部步骤，累计耗时 6~7 分钟。

本节选取批次 1 中的 068\_CH38、批次 2 中的 015\_CH44 以及 002\_CH34 和批次 3 中的 067\_CH41 作为服役电池，通过本研究所提模型分别预测其容量。同时，为验证模型各模块的有效性，基于本研究所提模型设计了 3 组消融模型：去除加速损失项模块、去除阶段编码模块、同时去除加速损失以及阶段编码模块。

为合理确定模型中各项参数，本研究采用网格搜索法进行超参数调优。其中， $\theta$  为加速退化权重项，用于控制加速退化损失项在总训练损失中的占比，鉴于加速退化损失的数值远大于均方根误差损失项，其网格搜索范围及数值偏小； $\beta$  为跨域迁移的平衡因子，作用是平衡模型微调阶段中“服役电池均方损失”与“测试电池-服役电池间的 MMD 损失”，直接决定跨域微调效果； $T$  为滑动窗口长度，为匹配数据序列的时间步长特性，采用整数寻优方式； $\mu$  为高斯核函数的宽度参数，用于调节核函数

的局部拟合能力, 适配数据分布特性。模型具体超参数设置如表3所示, 其中, “ $\in[0.5 \times 10^{-5}: 10^{-3}]$ ”等表述对应各超参数的网格搜索范围: “0”和“ $10^{-3}$ ”分别为搜索范围的左右边界, “ $5 \times 10^{-5}$ ”为搜索步长; 未标注该类范围的则为直接设定的超参数。

图6为四个服役电池在本模型与消融模型上的容量预测结果, 虚线右侧曲线为服役电池容量预测轨迹部分。图中, 黑色曲线为服役电池实际容量曲线, 红色、蓝色、绿色和橙色曲线则分别对应本模型、去除加速损失的本模型、去除阶段编码的本模型以及同时去除加速损失和阶段编码的本模型对服役电池容量的预测结果。可以看出, 本研究所提模

表3 模型超参数设置

Table 3 Model hyperparameter settings

超参数名称	值
隐藏单元数量	64
学习率	$10^{-4}$
批次	32
最大训练轮数	100
$\theta$	$10^{-4} \in [0.5 \times 10^{-5}: 10^{-3}]$
$\beta$	$0.1 \in [0.0: 1.1]$
$T$	$20 \in [0: 1: 30]$
$\mu$	$1.0 \in [0: 1.0: 10]$

型的预测轨迹均贴合实际容量曲线, 表现出良好的拟合能力与较强的泛化性能。

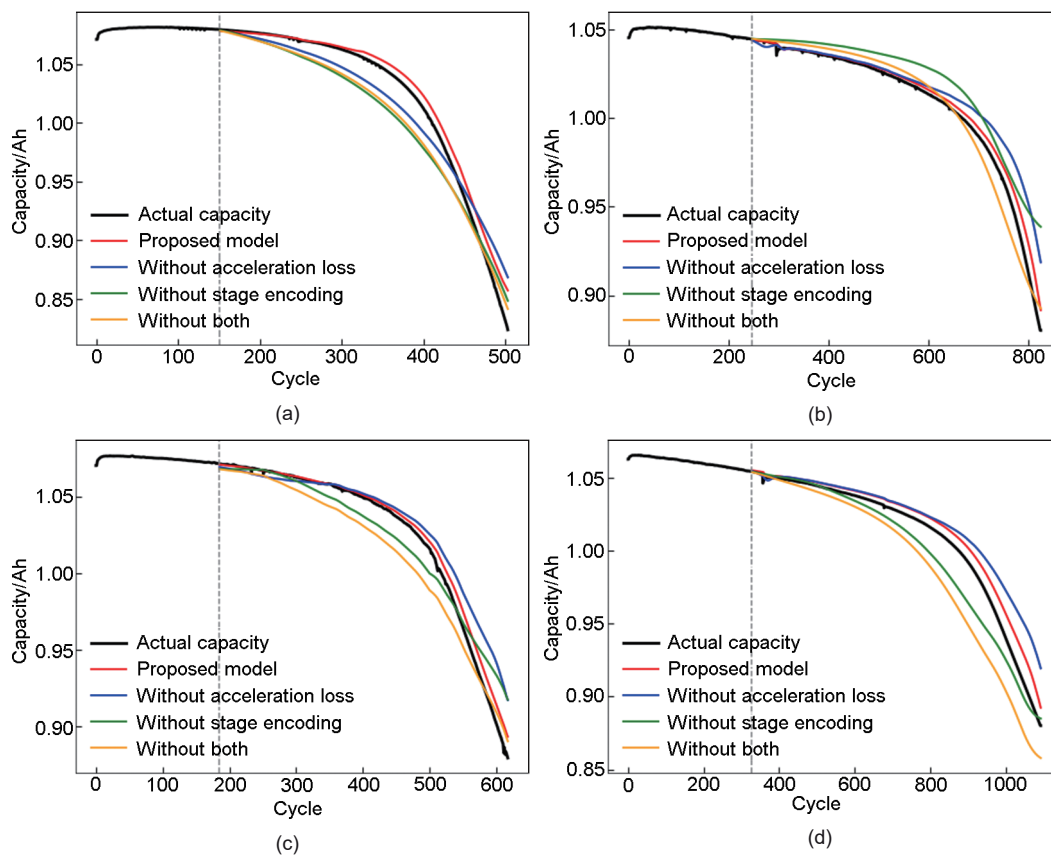


图6 本模型及消融模型的预测结果: (a) 068\_CH38; (b) 015\_CH44; (c) 002\_CH34; (d) 067\_CH41

Fig. 6 Battery capacity prediction results of different module ablation models: (a) 068\_CH38; (b) 015\_CH44; (c) 002\_CH34; (d) 067\_CH41

为验证本研究方法的预测精度, 本研究选用均方根误差(RMSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)作为评价指标。实验中, 将本模型输出的容量预测结果, 与服役电池全生命周期内后70%的实测容量数据进行定量对比; 需说

明的是, 后70%的服役电池数据作为独立测试集使用, 仅用于评估预测精度, 不参与模型的训练和迁移, 最终通过量化计算得到上述3类精度评价指标, 以客观反映模型的预测性能。表4为本模型以及消融模型在不同型号电池上的3类误差指标, 可

得出以下结论。

(1) 本模型对各服役电池容量预测的3类误差指标均在0.01以内: 其中, RMSE最低可达0.0055, MAE最低仅为0.0035, MAPE最低至0.0036。这表明本模型在处理不同服役电池的预测任务时, 具有良好的预测精度和一定的泛化能力。

(2) 与本模型相比, 去除加速损失的预测误差较大。其中, 068\_CH38电池的RMSE达0.0211, 而其余服役电池的预测误差指标在0.01左右。这表明去除加速损失后的本模型具有一定的预测能力, 但相比本模型, 在精度上仍有提升空间。

(3) 在各服役电池容量预测任务中, 去除阶段

编码后的误差指标整体偏高。其中, RMSE指标最大值达0.0308, 最低为0.0164。可见, 其预测结果不仅偏离实际值的幅度较高, 而且误差波动范围较大。

(4) 同时去除加速损失和阶段编码在预测中表现出性能不稳定性。RMSE波动于0.0175~0.0298, MAE处于0.0108~0.0184, MAPE则在0.0112~0.0198内变动。

综上, 消融实验揭示了在引入阶段编码和加速退化损失后, 一定程度上提升了模型在电池容量迁移预测中的泛化能力与预测准确性, 为模型设计的合理性提供了佐证。

表4 本模型及消融模型的预测误差指标

Table 4 The prediction error index of the proposed and ablation models

模型	068_CH38			015_CH44			002_CH34			067_CH41		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE
本模型	0.0058	0.0043	0.0046	0.0088	0.0069	0.0071	0.0055	0.0035	0.0036	0.0058	0.0038	0.0039
去除加速损失项	0.0211	0.0136	0.0146	0.0170	0.0113	0.0118	0.0109	0.0084	0.0086	0.0158	0.0108	0.0112
去除阶段编码	0.0189	0.0119	0.0128	0.0164	0.0103	0.0108	0.0230	0.0152	0.0157	0.0308	0.0208	0.0215
去除加速损失项和阶段编码	0.0298	0.0184	0.0198	0.0256	0.0162	0.0170	0.0175	0.0108	0.0112	0.0176	0.0114	0.0118

为进一步验证本模型的可靠性, 本研究对以上4组电池样本分别开展5次重复实验, 获取其在本模型及各消融模型下的20组预测误差指标。本研究应用Tensorflow框架中的tf.random.set\_seed函数设置随机种子, 该函数使用Mersenne twister随机数发生器, 设定初始随机种子为42, 每重复试验一次, 随机种子增加1, 最终将所有误差数据通过箱型图进行可视化呈现。

图7为本模型与各消融模型整合各电池预测结果后的误差箱型图, 可以看出, 本研究提出的模型在RMSE、MAE、MAPE三项误差指标上均优于各消融模型; 具体来看, 本模型的箱体高度、中位数、上下四分位数均为最小; 仅去除加速损失或阶段编码的消融模型误差次之且存在异常值, 反映出模型性能的不稳定性; 同时去除两者的模型误差波动最大。这表明, 本模型通过加速损失与阶段编码的设计, 提升了电池容量预测的精度与稳定性, 验证了模型各组件的必要性及协同有效性。

#### 4.4 与现有模型的性能比较

本部分选取现有相关模型展开对比研究, 分别选取文献[19]的WOA-VMD-LSTM模型、文献[9]的TL-CNN-AT模型以及文献[10]的TL-DBN-LSTM模

型作为对比模型。其中, WOA-VMD-LSTM模型为传统非迁移学习模型, 其余两个模型采用迁移学习方法。为保障对比实验的公平性, 所有对比模型均基于与本模型完全一致的数据集划分方案。除本研究所提模型需对阶段特征额外实施归一化处理外, 其余对比模型的容量归一化方式均与本研究保持一致, 统一采用最大最小值归一化。以此消除数据层面的变量差异, 确保模型性能对比结果的可信度。

图8为各模型对不同服役电池容量的预测曲线。从曲线拟合程度来看, 相较于本模型, 两种迁移学习模型的预测曲线, 与实际容量曲线存在一定的偏差, 但相较于传统模型, 仍展现出良好的预测精度; 而WOA-VMD-LSTM模型的预测曲线与实际容量曲线相差较大, 反映出该模型在有限数据下难以充分学习服役电池容量变化规律。

表5为不同模型在容量预测任务中的误差指标。结果显示, 本模型三类误差指标均稳定在0.01以内, 以067\_CH41电池的预测结果为例, 其RMSE、MAE和MAPE分别为低至0.0058、0.0038和0.0039, 优于对比模型, 验证了本模型具有较高的预测精度; TL-DBN-LSTM模型性能次之, 尽管其整体误差指标略高于本模型, 但波动范

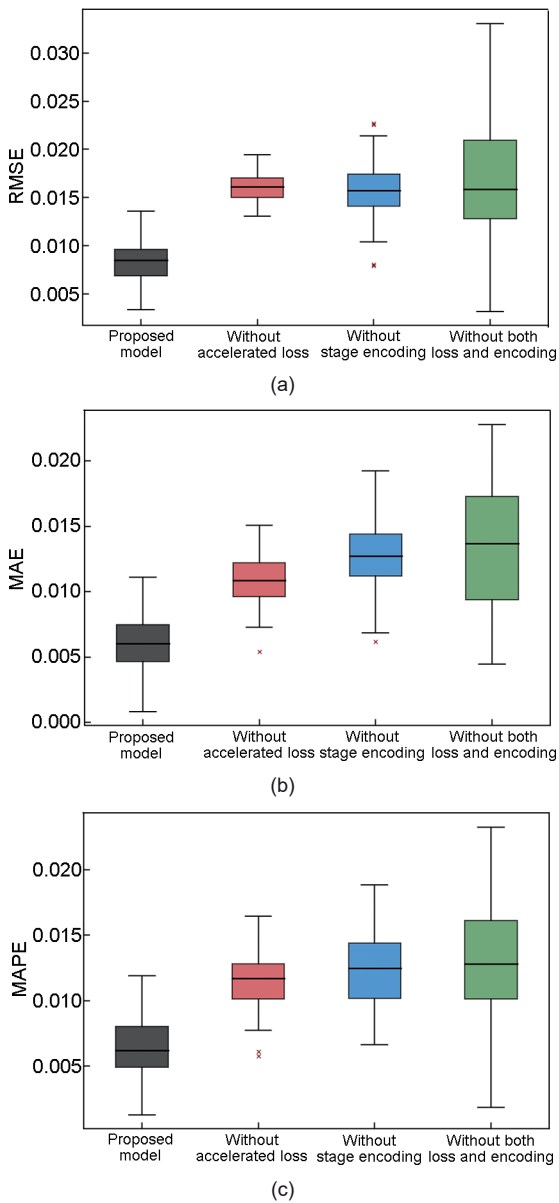


图7 本模型及消融模型的误差箱型图: (a) RMSE 误差指标; (b) MAE 误差指标; (c) MAPE 误差指标

Fig. 7 Error boxplots of the proposed model and ablation models: (a) RMSE error metric; (b) MAE error metric; (c) MAPE error metric

围较小,且在015\_CH44电池样本上展现出较高的预测精度;TL-CNN-AT模型的各项指标平均在0.01,具有良好的稳定性;相较而言,WOA-VMD-LSTM模型性能表现最差,该模型在各服役电池中的预测误差指标多数超过0.02,与其他模型存在差距。上述结果表明,与各对比模型相比,本模型通过采用迁移学习方法与嵌入阶段编码的机制,在有限数据条件下实现了预测精度的提升。

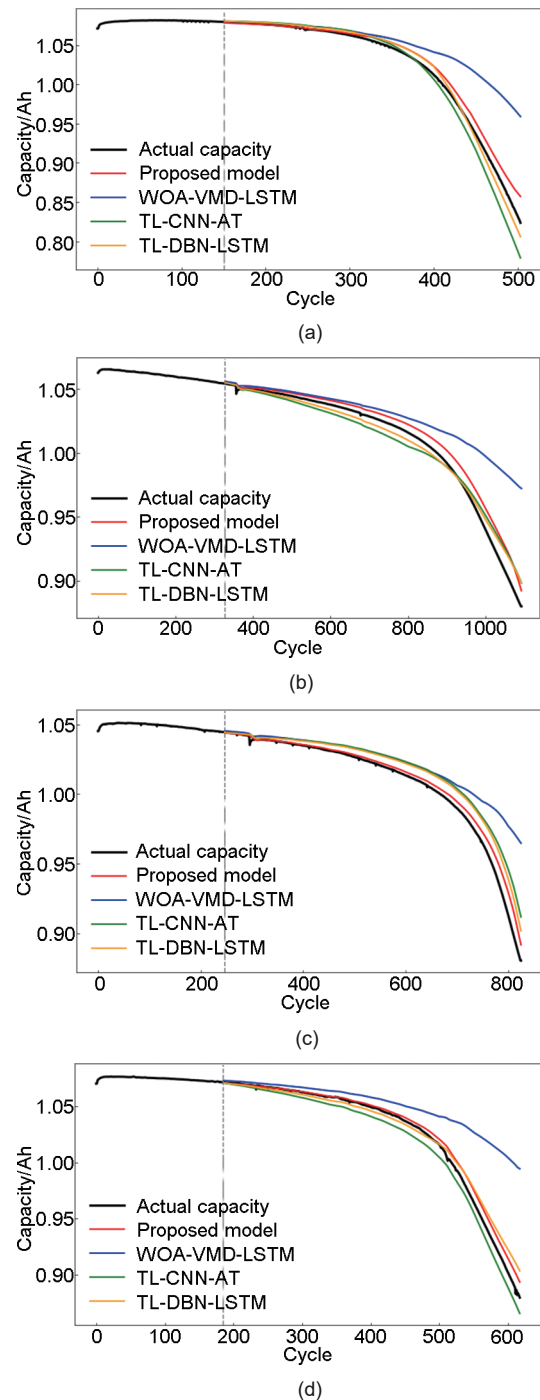


图8 不同模型的电池容量预测结果: (a) 068\_CH38; (b) 015\_CH44; (c) 012\_CH34; (d) 067\_CH41

Fig. 8 Battery capacity prediction results of different models: (a) 068\_CH38; (b) 015\_CH44; (c) 002\_CH34; (d) 067\_CH41

## 5 结论

本研究针对锂电池容量预测中阶段差异、工况波动导致的模型性能不足问题,提出一种计及退化

表 5 本模型及消融模型的预测误差指标

Table 5 The prediction error index of the proposed and ablation models

模型	068_CH38			015_CH44			002_CH34			067_CH41		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE	RMSE	MAE	MAPE
本模型	0.0058	0.0043	0.0046	0.0088	0.0069	0.0071	0.0055	0.0035	0.0036	0.0058	0.0038	0.0039
WOA-VMD-LSTM	0.0475	0.0285	0.0308	0.0310	0.0194	0.0204	0.0231	0.0142	0.0148	0.0398	0.0245	0.0256
TL-CNN-AT	0.0147	0.0093	0.0099	0.0085	0.0070	0.0071	0.0131	0.0099	0.0102	0.0083	0.0075	0.0075
TL-DBN-LSTM	0.0072	0.0057	0.0059	0.0089	0.0060	0.0062	0.0109	0.0084	0.0086	0.0080	0.0054	0.0055

阶段特征的迁移学习方法。该方法通过测试电池精准匹配、阶段编码特征融合、物理约束损失强化与分层微调迁移策略的协同优化，有效提升了电池容量预测的准确性与稳定性，验证结果如下。

(1) 本研究所提模型在跨批次、跨工况迁移任务中表现出更强的泛化能力，可适应锂电池复杂的服役环境差异。

(2) 通过双 Bacon-Watts 的退化阶段划分与 TWED 双维度筛选机制，实现了测试电池与服役电池的精准匹配，为后续模型迁移过程提供先验知识支撑。

(3) 消融实验验证了各模块的有效性，其协同提高了预测精度，使预测结果更契合实际。

### 参考文献

[1] 寇发荣, 杨天祥, 罗希, 等. 基于特征重构与多时间尺度的锂电池 SOH 和 RUL 联合估计[J]. 太阳能学报, 2025, 46(6): 68-78.  
KOU F R, YANG T X, LUO X, et al. Joint estimation of SOH and RUL for lithium batteries based on feature reconstruction and multiple times scales[J]. Acta Energetica Solaris Sinica, 2025, 46(6): 68-78.

[2] 熊庆, 邸振国, 汲胜昌. 锂离子电池健康状态估计及寿命预测研究进展综述[J]. 高电压技术, 2024, 50(3): 1182-1195. DOI: 10.13336/j.1003-6520.hve.20221843.  
XIONG Q, DI Z G, JI S C. Review on health state estimation and life prediction of lithium-ion batteries[J]. High Voltage Engineering, 2024, 50(3): 1182-1195. DOI: 10.13336/j.1003-6520.hve.20221843.

[3] 戴俊彦, 夏明超, 陈奇芳. 基于双重注意力机制的电池 SOH 估计和 RUL 预测编解码模型[J]. 电力系统自动化, 2023, 47(6): 168-177. DOI: 10.7500/AEPS20220615007.  
DAI J Y, XIA M C, CHEN Q F. Encoding and decoding model of state of health estimation and remaining useful life prediction for batteries based on dual-stage attention mechanism[J]. Automation of Electric Power Systems, 2023, 47(6): 168-177. DOI: 10.7500/AEPS20220615007.

[4] 程思涵, 刘思懿, 郭子旭, 等. 基于 CNN-GRU-注意力的锂离子电池 SOC 估计[J]. 电池, 2026, 56(1): 131-135.  
CHENG S H, LIU S Y, GUO Z X, et al. SOC estimation for Li-ion

battery based on the CNN-GRU-Attention[J]. Battery Bimonthly, 2026, 56(1): 131-135.

[5] 蔡雨思, 李泽文, 刘萍, 等. 基于间接健康特征优化与多模型融合的锂电池 SOH-RUL 联合预测[J]. 电工技术学报, 2024, 39(18): 5883-5898. DOI: 10.19595/j.cnki.1000-6753.tces.231057.  
CAI Y S, LI Z W, LIU P, et al. Joint prediction of lithium battery state of health and remaining useful life based on indirect health features optimization and multi-model fusion[J]. Transactions of China Electrotechnical Society, 2024, 39(18): 5883-5898. DOI: 10.19595/j.cnki.1000-6753.tces.231057.

[6] 黄凯, 郝润凯, 郭永芳. 基于特征综合评价和模型优化的锂离子电池健康状态估计方法[J]. 电力系统及其自动化学报, 2025, 37(5): 131-140. DOI: 10.19635/j.cnki.csu-epsa.001599.  
HUANG K, HAO R K, GUO Y F. State-of-health estimation method for lithium-ion battery based on comprehensive feature evaluation and model optimization[J]. Proceedings of the CSU-EPSA, 2025, 37(5): 131-140. DOI: 10.19635/j.cnki.csu-epsa.001599.

[7] 宋兴海, 张小乾, 梁惠施, 等. 基于 SDAE-Transformer-ECA 网络的锂电池剩余使用寿命预测[J]. 储能科学与技术, 2023, 12(10): 3181-3190. DOI: 10.19799/j.cnki.2095-4239.2023.0369.  
SONG X H, ZHANG X Q, LIANG H S, et al. Predicting the remaining service life of lithium batteries based on the SDAE-transformer-ECA network[J]. Energy Storage Science and Technology, 2023, 12(10): 3181-3190. DOI: 10.19799/j.cnki.2095-4239.2023.0369.

[8] SHEN S, SADOUGHI M, LI M, et al. Deep convolutional neural networks with ensemble learning and transfer learning for capacity estimation of lithium-ion batteries[J]. Applied Energy, 2020, 260: 114296. DOI: 10.1016/j.apenergy.2019.114296.

[9] YANG Z X, LI Y, YANG D, et al. Enhanced CNN-based state-of-health estimation framework for lithium-ion batteries using variable-length charging segments and transfer learning[J]. Journal of Energy Storage, 2025, 128: 117214. DOI: 10.1016/j.est.2025.117214.

[10] MA Y, SHAN C, GAO J W, et al. Multiple health indicators fusion-based health prognostic for lithium-ion battery using transfer learning and hybrid deep learning method[J]. Reliability Engineering & System Safety, 2023, 229: 108818. DOI: 10.1016/j.res.2022.108818.

[11] GUO Y F, WANG Y S, DING P Y, et al. Future degradation trajectory prediction of lithium-ion battery based on a three-step

- similarity evaluation criterion for battery selection and transfer learning[J]. *Journal of Energy Storage*, 2023, 72: 108763. DOI: 10.1016/j.est.2023.108763.
- [12] FU S Y, TAO S Y, FAN H T, et al. Data-driven capacity estimation for lithium-ion batteries with feature matching based transfer learning method[J]. *Applied Energy*, 2024, 353: 121991. DOI: 10.1016/j.apenergy.2023.121991.
- [13] 梁佳佳, 何晓霞, 肖浩逸. 基于 CS-DBN 的锂电池剩余寿命预测[J]. *太阳能学报*, 2024, 45(3): 251-259.
- LIANG J J, HE X X, XIAO H Y. Prediction of remaining useful life of lithium batteries based on CS-DBN[J]. *Acta Energetica Sinica*, 2024, 45(3): 251-259.
- [14] FERMÍN-CUETO P, MCTURK E, ALLERHAND M, et al. Identification and machine learning prediction of knee-point and knee-onset in capacity degradation curves of lithium-ion cells[J]. *Energy and AI*, 2020, 1: 100006. DOI:10.1016/j.egyai.2020.100006.
- [15] ZHANG H, ALTAF F, WIK T. Battery capacity knee-onset identification and early prediction using degradation curvature[J]. *Journal of Power Sources*, 2024, 608: 234619. DOI: 10.1016/j.jpowsour.2024.234619.
- [16] MARTEAU P F. Time warp edit distance with stiffness adjustment for time series matching[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(2): 306-318. DOI: 10.1109/TPAMI.2008.76.
- [17] YE Z, YU J B. State-of-health estimation for lithium-ion batteries using domain adversarial transfer learning[J]. *IEEE Transactions on Power Electronics*, 2022, 37(3): 3528-3543. DOI: 10.1109/TPEL.2021.3117788.
- [18] SEVERSON K A, ATTIA P M, JIN N, et al. Data-driven prediction of battery cycle life before capacity degradation[J]. *Nature Energy*, 2019, 4(5): 383-391. DOI:10.1038/s41560-019-0356-8.
- [19] OUYANG M S, SHEN P C. Prediction of remaining useful life of lithium batteries based on WOA-VMD and LSTM[J]. *Energies*, 2022, 15(23): 8918. DOI:10.3390/en15238918.