储能科学与技术

容量再生干扰下锂离子电池剩余使用寿命有监督离线回放预测方法

廖志伟，孔　博，吕东泽
（华南理工大学电力学院，广东 广州 510630）

摘　要：针对锂离子电池容量再生引起的局部非单调变化、跨电池退化差异及目标域有效窗口不足，提出一种有监督离线回放剩余使用寿命（remaining useful life，RUL）预测方法。在完整寿命记录条件下，目标电池容量观测按原始循环顺序释放，并遵循“先预测、后评价、再更新”的时序。基于容量差分的指数加权移动平均（exponentially weighted moving average，EWMA）机制用于标记容量再生候选区间、筛选连续有效窗口并维持区间内RUL输出连续；门控循环单元（gated recurrent unit，GRU）经源域预训练后，在目标域冻结第一层并更新第二层及预测层；质量门控变分自编码器生成对抗网络（variational autoencoder generative adversarial network，VAEGAN）作为探索性增强分支。NASA电池数据集上的多随机种子、消融、敏感性和增强对照实验表明，分层适配可降低部分电池的回放误差，EWMA参数影响有效窗口和最终误差，VAEGAN未显示相对于简单增强的稳定增量收益，GRU在当前配置下兼顾误差水平与参数规模。所提框架可用于分析容量再生条件下不同处理与适配环节的时序作用。

关键词：锂离子电池；剩余使用寿命；容量再生；离线回放；门控循环单元；迁移学习
doi：10.19799/j.cnki.2095-4239.2026.0657
中图分类号：TM 912　　文献标志码：A　　文章编号：2095-4239（XXXX）XX-1-17

Supervised Offline Replay Prediction Method for Remaining Useful Life of Lithium-Ion Batteries under Capacity Regeneration Interference

LIAO Zhiwei, KONG Bo, LYU Dongze
(School of Electric Power, South China University of Technology, Guangzhou, Guangdong 510630, China)

Abstract: A supervised offline replay method is proposed for remaining useful life (RUL) prediction under capacity-regeneration-induced local non-monotonicity, cross-battery degradation discrepancies, and limited valid target-domain windows. When complete-life records are available, target-battery observations are released in chronological order following a predict-evaluate-update sequence. An exponentially weighted moving average (EWMA) mechanism based on capacity differences identifies candidate regeneration intervals, screens continuous valid windows, and maintains RUL continuity within these intervals. A gated recurrent unit (GRU) model is pretrained in the source domain; during target-domain adaptation, its first layer is frozen while the second layer, fully connected layer, and output layer are updated. A quality-gated variational autoencoder generative adversarial network

收稿日期：2026-07-27；修改稿日期：2026-10-15。
基金项目：广东省基础与应用基础研究基金项目（2023A1515240038）。
第一作者及通信联系人：廖志伟（1973—），男，博士，副教授，锂离子电池寿命预测与健康管理，epliao@scut.edu.cn。
引用本文：廖志伟, 孔博, 吕东泽. 容量再生干扰下锂离子电池剩余使用寿命有监督离线回放预测方法[J]. 储能科学与技术, XXXX, XX(XX): 1-17.
Citation：LIAO Zhiwei, KONG Bo, LYU Dongze. Supervised Offline Replay Prediction Method for Remaining Useful Life of Lithium-Ion Batteries under Capacity Regeneration Interference[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-17.

(VAEGAN) is included as an exploratory augmentation branch. Multi-seed, ablation, sensitivity, and augmentation-comparison experiments on NASA batteries show that layer-wise adaptation reduces replay errors for some batteries, EWMA parameters affect valid-window availability and final errors, VAEGAN provides no stable incremental gain over simple augmentation, and GRU offers a favorable error-parameter balance under the current configuration. The framework supports reproducible analysis of the temporal effects of processing and adaptation strategies under capacity regeneration.

Keywords: lithium-ion battery; remaining useful life; capacity regeneration; offline replay; gated recurrent unit; transfer learning

1 引 言

锂离子电池剩余使用寿命（remaining useful life, RUL）预测对预防性维护、可靠运行和剩余价值评估具有重要意义[1-2]。RUL通常指电池达到预设寿命终止阈值前的剩余循环次数，是电池健康管理和运维决策的重要依据[2]。在循环老化过程中，容量退化轨迹可能出现阶段转换、膝点及其他非线性特征[3]。除长期不可逆衰减外，容量轨迹还可能叠加短时局部回升，即容量再生。该现象会改变局部退化斜率，使模型将短时容量恢复误判为老化速率减缓，进而造成RUL高估或预测波动。不同电池在衰减速率、阶段转换位置和容量再生特征等方面的差异，进一步增加了跨电池预测难度。

针对容量再生对RUL预测的影响，已有研究从再生点检测、特征表征、容量波动分解和预测误差修正等方面开展探索。文献[4]从容量波动分解和可解释性建模角度分析容量再生对RUL预测的影响；文献[5]采用粒子滤波与Wasserstein距离检测容量再生点，并结合粒子滤波-自回归积分移动平均模型及误差补偿开展RUL预测；文献[6]利用粒子滤波和Mann-Whitney U检验识别容量再生点，在此基础上构建粒子滤波-自回归预测方法。文献[7]提出在线非参数容量再生检测、数据重构及长短期记忆网络（long short-term memory, LSTM）迁移预测方法。文献[8]从充放电过程提取健康因子，并结合支持向量回归、高斯过程回归、无迹卡尔曼滤波和基于Shapley值的可加性解释方法表征容量再生的影响；文献[9]利用多特征提取、门控循环单元（gated recurrent unit, GRU）及时序卷积注意力减弱容量再生对电池健康状态和RUL预测的影响。另有研究采用变分模态分解等方法分离或表征容量序列中的长期退化趋势、局部再生和波动分量[10-11]。上述研究已覆盖检测、分解、解释和预测修正等环节；但对于容量观测逐循环到达的目标电池，历史样本筛选、目标电池容量再生候选区间处理与后续模型适配之间仍需进一步协调。

即使识别并排除容量再生候选区间，目标电池在预测初期仍面临有效观测有限的问题[12]；若进一步排除包含或跨越容量再生候选区间的训练窗口，可用于模型适配的样本还会减少。针对目标电池早期有效观测有限的问题，已有研究从半监督学习和生成式数据增强等方向开展探索。文献[13]提出半监督自学习方法，利用有限容量检查点和伪值重构开展寿命预测；文献[14]采用半监督表示学习，从大量无RUL标签的短期运行数据中提取退化特征，以降低对全寿命标签的依赖。生成式模型也被用于扩充电池退化样本：文献[15]采用变分自编码器-生成对抗网络（variational autoencoder generative adversarial network, VAEGAN）生成退化数据，并结合降噪自编码器、LSTM和迁移训练开展RUL预测；文献[16]构建条件循环生成对抗网络生成电池多变量时序样本；文献[17]利用Wasserstein时间生成对抗网络生成虚拟电池数据以改善容量估计。对于考虑容量再生的离线回放预测过程，目标域增强样本的构造还需结合有效窗口筛选和生成样本质量控制，以避免局部异常退化片段直接进入后续参数适配。

历史电池与目标电池在容量衰减速率、阶段转换位置和再生特征等方面存在退化模式差异。将参与预训练的历史电池数据称为源域，将待预测电池数据称为目标域。迁移学习（transfer learning，TL）利用源域退化知识初始化模型，再依据目标域历史信息调整参数[7,15,18]。本文将利用目标电池截至

当前循环已经释放的有效历史窗口更新源域预训练模型的过程称为目标域适配。在逐循环观测条件下，还需协调容量再生候选区间处理、可用监督样本释放和跨电池参数更新，避免筛选后的有限目标域窗口被不恰当地拼接或提前使用。

本文采用有监督离线回放研究容量再生条件下的跨电池RUL预测。完整寿命记录用于构造离线评价及后续目标域适配所需的RUL标签，目标电池容量观测按原始循环顺序逐步释放，并遵循“先预测、后评价、再更新”的时序。从功能层次看，有监督离线回放用于约束观测、标签与参数更新的信息释放顺序；EWMA分阶段处理与GRU分层迁移构成预测和跨电池适配的主体方法；质量门控VAEGAN用于探索有效目标域窗口受限条件下生成增强的附加作用。NASA电池数据上的重复实验、消融分析、参数敏感性分析和样本审计分别用于评价上述环节的实际作用。

2 容量再生干扰机理与EWMA动态检测及分阶段处理方法

2.1 容量再生对RUL离线回放预测的干扰机制

锂离子电池在循环充放电过程中，其可用容量整体呈不可逆的衰减趋势。本文将电池容量首次下降至初始容量的80%所对应的循环定义为寿命终止（end of life，EOL）状态，即：

$$Q_{EOL} = 0.8Q_0 \tag{1}$$

式（1）中，Q_0为电池初始容量，Q_{EOL}为电池失效阈值容量。设电池达到寿命失效阈值时对应的循环次数为N_{EOL}，当前循环次数为k，则第k次循环对应的剩余使用寿命可表示为：

$$RUL_k = N_{EOL} - k \tag{2}$$

理想退化条件下，电池容量随循环次数增加而逐步下降，相邻循环之间的容量变化能够反映局部退化速率。设第k次循环对应的电池容量为Q_k，则相邻循环容量差分为：

$$\Delta Q_k = Q_k - Q_{k-1} \tag{3}$$

在理想单调退化条件下，容量差分以非正值为主。实际循环老化中可能出现局部容量回升，即容量再生；该现象并不表示不可逆老化被逆转，而是在长期衰减趋势上叠加短时可逆变化。已有研究表明，循环间静置可能引起可用容量短时恢复，该效应与负极过量区域、锂分布重新趋于均匀以及静置时间有关[19-20]。本文所称容量再生是容量观测层面的可用容量恢复现象；EWMA仅识别其统计特征，不用于判定具体电化学反应机制。

与普通随机测量噪声不同，容量再生通常不是孤立的单点扰动，而是具有一定持续时间和方向性的局部正向偏移。普通噪声通常围绕退化趋势上下波动，而容量再生的主要特征是短时间内容量沿着与主退化方向相反的方向变化。因此，若仅采用普通平滑方法处理容量序列，可能同时削弱真实退化斜率和容量再生特征，难以区分短期可逆容量回升与长期不可逆容量衰减。基于这一特点，本文将容量差分序列中的异常正向变化作为容量再生识别的主要依据。

如图1所示，NASA四组电池容量曲线均呈现整体衰减趋势，但局部循环区间内存在不同程度的容量回升。容量再生对RUL离线回放预测的影响主要体现在以下三个方面。

第一，容量再生会造成退化方向误判。正向容量差分进入训练样本或滚动观测窗口后，预测模型可能将短时容量回升误判为退化速率减缓或健康状态改善，进而使失效时刻估计滞后，导致局部RUL预测偏大。

第二，容量再生会引起预测结果波动。在有监督离线回放过程中，目标电池容量数据随循环逐步到达。当容量再生样本进入或退出观测窗口时，模型输入分布会发生局部变化，预测结果容易出现反复调整，降低RUL预测序列的连续性和稳定性。

第三，容量再生会放大跨电池退化差异。不同电池容量再生的发生位置、持续时间和幅值并不一致。当容量再生差异与主退化速率、局部曲率和寿命长度差异叠加后，历史电池与目标电池之间的退化模式偏移会更加明显，从而增加跨电池预测难度。

因此，本文基于容量差分构建动态检测与分阶段处理方法，以标记容量再生候选区间，并削弱其对后续建模的干扰。

2.2 基于EWMA动态检测的容量再生候选区间识别与RUL连续性处理方法

针对容量再生引起的局部非单调扰动，基于容量差分构建单步预测型EWMA监测。设第k次循环的容量差分为ΔQ_k，由于正常老化过程中容量差分通常保持负向变化，而容量再生会表现为明显的正

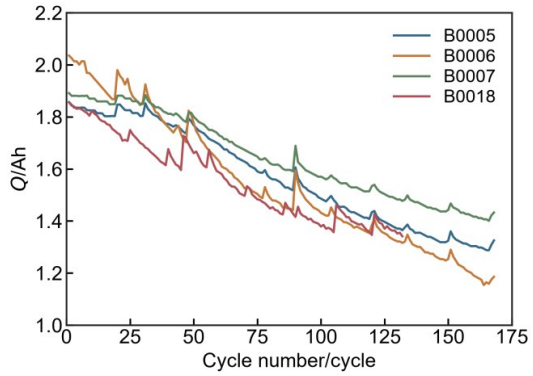


图1 NASA四组电池的容量退化曲线

Fig. 1 Capacity degradation curves of four NASA batteries

向突增，因此可通过容量差分序列的统计变化识别异常正向变化，并据此形成容量再生候选区间。在本文实现中，EWMA统计量由初始容量差分窗口预热后启动，预热阶段不进行容量再生判定。初始化规则与数值参数在实验设置中统一给出。为避免当前异常点参与自身阈值计算导致检测灵敏度降低，本文采用单步预测型EWMA控制策略。第k次循环首先利用第k-1次循环结束后的统计量构造动态控制上限：

$$U_k = \mu_{k-1} + \kappa\sigma_{k-1} \tag{4}$$

式（4）中，U_k为第k次循环对应的动态控制上限，μ_{k-1}和σ_{k-1}分别表示第k–1次循环时容量差分序列的EWMA均值和标准差；κ为控制上限系数。本文固定取κ = 3，参数在实验设置中统一给出。

当$\Delta Q_k > max(0, U_k)$时，将第k次循环识别为异常正向变化候选点。完成当前循环判别后，利用当前差分更新EWMA统计量：

$$\mu_k = \alpha\Delta Q_k + (1-\alpha)\mu_{k-1} \tag{5}$$

$$\sigma_k^2 = \alpha\left(\Delta Q_k - \mu_k\right)^2 + (1-\alpha)\sigma_{k-1}^2 \tag{6}$$

式（5）和式（6）中，μ_k和σ_k^2分别为第k次循环容量差分序列的EWMA均值和方差，分别表示截至当前循环时容量差分的递推中心水平和当前容量差分围绕递推均值的波动程度。α为平滑因子，α越大，当前容量差分在统计量中的权重越高，模型对近期容量变化越敏感；α越小，历史容量变化对当前统计量的影响越强，监测结果越平滑。本文取α = 0.3。完成当前循环判定后，当前容量差分均按式（5）和式（6）更新统计量，候选区间内的容量差分也参与递推。

将首次满足异常正向变化判据的循环记为区间起点k_s，并以其前一循环容量$\hat{Q}_{k_s-1}$作为回落基准。区间开启后，在闭合前不再设置新的起点。当后续容量首次满足

$$Q_k \leqslant \hat{Q}_{k_s-1} + \varepsilon \tag{7}$$

式（7）给出容量再生候选区间的回落闭合判据。ε为容量回落判定容差，本文取0 Ah。将首次满足该判据的循环记为区间终点k_e，据此得到容量再生候选区间：

$$\Omega_r = [k_s, k_e] \tag{8}$$

各容量再生候选区间的再生幅值定义为区间内最大容量与区间起点前一循环回落基准容量之差。若截至当前循环容量尚未满足式（7），则区间保持未闭合状态并继续监测；该过程仅使用当前及之前的容量观测。

EWMA模块向后续环节传递容量观测序列、原始循环编号和容量再生候选区间标记。对于历史电池，仅采用原始循环编号连续且窗口内不含容量再生候选区间标记的样本进行源域预训练；窗口内包含候选区间标记，或跨越候选区间的窗口均不参与训练。窗口末端RUL标签仍依据原始循环编号和寿命终止循环计算，以避免区间筛选造成时间轴压缩和退化速率失真。

对于目标电池，仅将原始循环编号连续且窗口内无容量再生候选区间标记的样本定义为有效目标域窗口。对其中可作为VAEGAN候选样本生成来源的真实有效窗口，称为父窗口。有效目标域窗口直接用于后续GRU监督适配；父窗口仅用于VAEGAN候选增强样本构造。容量再生候选区间内的循环及包含该区间的窗口均不参与目标域参数更新和生成样本构造。若当前循环位于容量再生候选区间内，则不将当前循环及包含该循环的窗口纳入VAEGAN重构或GRU监督适配；第k次循环预测后的参数更新仅使用末端循环不晚于k–1的有效历史样本。容量再生候选区间内最终RUL输出以区间前基准预测进行RUL连续性处理，其中区间前基准预测是指容量再生候选区间起点前最近一次由完整有效窗口得到的RUL预测。

设容量再生候选区间起点和终点分别为k_s和k_e，区间起点前一循环的预测RUL为$\widehat{RUL}_{k_s-1}$，则容量再生候选区间内第k次循环经RUL连续性处理后的预测RUL可表示为：

$$\widehat{RUL}_k = \max\left(0, \widehat{RUL}_{k_s-1} - (k - k_s + 1)\right), k \in [k_s, k_e] \quad (9)$$

式（9）中，$\widehat{RUL}_k$表示容量再生候选区间内第k次循环经RUL连续性处理后的预测RUL。式（9）根据实际循环推进量对区间前基准预测$\widehat{RUL}_{k_s-1}$进行递减，并通过*max*函数保证RUL非负。式（9）仅约束预测输出的连续性，不改变EWMA统计量，也不生成或补充训练样本。对于尚未闭合的容量再生候选区间，式（9）仅使用截至当前循环的容量观测进行计算，无需预先获知后续容量观测。

式（9）的启用条件是区间起点前已经获得区间前基准预测。若在$k_s - 1$时尚无区间前基准预测，则在已经形成完整输入窗口的前提下，暂由源域预训练模型给出原始RUL输出；在获得首个区间前基准预测之前，不启用式（9）。若尚未形成完整输入窗口，则暂不输出RUL，待达到统一预测起点并形成完整输入窗口后再开始预测。

容量再生候选区间结束后，正常容量观测重新进入有效样本集。重新形成一个原始循环编号连续且窗口内无容量再生候选区间标记的完整输入窗口后，恢复VAEGAN重构和GRU目标域适配；在此之前，RUL输出以最近一次区间前基准预测为基准，并随循环推进逐次递减。式（9）仅用于RUL连续性处理，不判断容量恢复是否改变电池的实际寿命终点。

上述分阶段处理在两个阶段承担不同功能：源域预训练阶段筛选历史电池中原始循环连续且不含容量再生候选区间标记的窗口，以减弱局部再生片段对共享时序表征的影响；目标域回放阶段依据当前容量再生候选区间状态控制输入构窗、监督样本释放和容量再生候选区间内RUL连续性处理。处理结果为后续GRU分层适配提供目标域真实样本，并为探索性VAEGAN候选增强分支限定父窗口范围。

3 基于EWMA分阶段处理与GRU迁移的有监督离线回放预测方法

3.1 探索性VAEGAN候选增强分支

经容量再生候选区间筛选后，目标电池可用于监督适配的有效窗口进一步减少，离线回放初期尤其明显。为考察生成式增强能否补充有效窗口附近的局部退化样本，在真实有效窗口始终作为基础监督样本的前提下，引入一维卷积VAEGAN作为探索性候选增强分支。编码器将有效容量窗口映射为潜变量分布，解码器兼作生成器输出重构窗口，判别器约束真实窗口与重构窗口的分布一致性；本文将用于控制生成样本接入的预设质量筛选准则称为质量门，候选窗口仅在通过质量门并完成排序后作为附加样本进入GRU适配。

VAEGAN以重构损失、库尔贝克－莱布勒散度（Kullback-Leibler divergence，KL）损失和对抗损失分别约束窗口重构、潜变量分布以及真实窗口与重构窗口的分布一致性，其计算形式见式（10）—式（14）。

$$L_{rec} = \frac{1}{n}\sum_{i=1}^{n}\left\| Y_i - \widehat{Y}_i \right\|_2^2 \quad (10)$$

$$L_{KL} = -\frac{1}{2}\sum_{j=1}^{m}\left(1 + \ln\sigma_j^2 - \mu_j^2 - \sigma_j^2\right) \quad (11)$$

$$L_{adv} = E_{Y\sim P_{data}}[\log D(Y)] + E_{Z\sim q_\varphi(z|Y)}[\log(1 - D(G(z)))] \quad (12)$$

$$L_{adv,G} = -E_{Z\sim q_\varphi(z|Y)}[\log D(G(z))] \quad (13)$$

$$L_{E,G} = L_{rec} + L_{KL} + L_{adv,G} \quad (14)$$

式（10）为重构损失，式（11）为KL损失，式（12）为生成器与判别器的对抗价值函数，式（13）为生成器方向的对抗项，式（14）给出编码器—生成器联合目标。式中，Y_i和$\widehat{Y}_i$分别为第i个真实容量窗口及其重构窗口，n为窗口样本数；μ_j和σ_j^2为潜变量第j维的均值和方差，m为潜变量维数；z为潜变量，$q_\varphi(z|Y)$为编码器给出的近似后验分布，P_{data}为真实窗口分布，G和D分别为生成器和判别器。

VAEGAN仅围绕父窗口生成候选样本，容量再生候选区间内的样本不参与增强。每个父窗口生成100组候选。默认质量门要求容量序列均方根误差不超过0.02 Ah、容量差分序列均方根误差不超过0.01 Ah/循环，且归一化容量值落入[0,0.01]或[0.99,1]边界区间的比例不超过0.10。通过质量门的候选按重构误差排序，每个父窗口最多保留10组；无合格候选时不引入生成样本。入选窗口保留父窗口的末端循环编号并继承其RUL标签。上述阈值在B0005参数开发阶段固定，B0006、B0007和B0018不参与阈值选择。

针对每块目标电池，质量门所用的[0,1]归一化尺度由其对应源域的全部有效窗口统一确定：取全部源域有效窗口容量值的最小值和最大值，并在两

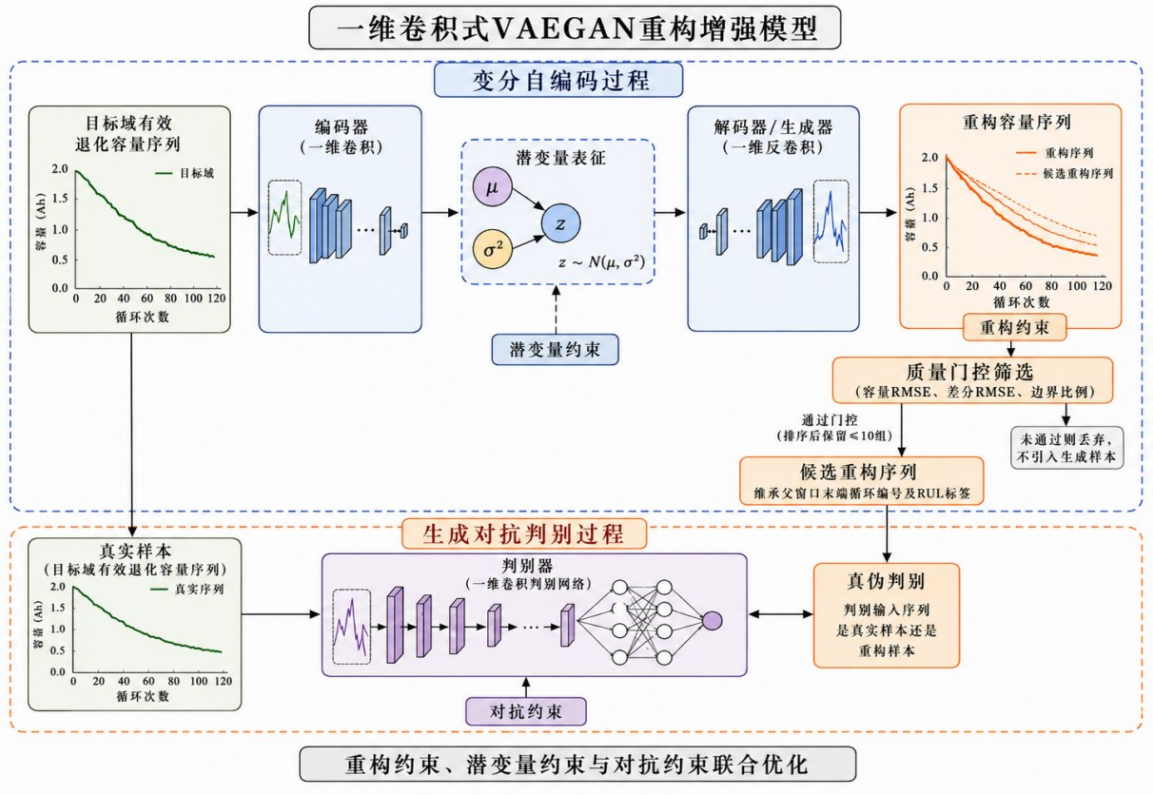


图2 探索性VAEGAN候选增强与质量筛选框架

Fig. 2 Exploratory VAEGAN candidate augmentation and quality-screening framework

端各扩展源域极差的2%后进行Min-Max变换。该尺度在目标电池的整个回放过程中保持不变；父窗口与生成窗口共用同一组归一化参数，生成窗口也由该参数反归一化到物理容量尺度。边界比例按生成窗口中归一化容量值不大于0.01或不小于0.99的时间点数占窗口长度的比例计算。

VAEGAN仅重构窗口内的容量特征，不改变原始循环编号及末端循环，故增强窗口与其父窗口共享末端RUL标签：

$$y(Y_k') = y(Y_k) = N_{EOL} - k \tag{15}$$

式（15）中，Y_k'为重构窗口，Y_k为其来源容量窗口，y为窗口末端RUL监督标签。

目标域真实有效窗口始终构成GRU监督适配的基础样本，VAEGAN窗口只作为探索性附加样本。在触发目标域适配时，若有候选样本通过质量门，则将入选生成窗口与真实有效窗口共同用于更新；否则仅使用真实有效窗口。质量门只控制生成样本是否接入，不改变真实窗口的使用。

3.2 面向跨电池适配的GRU分层迁移预测方法

经EWMA处理后，目标电池的真实有效窗口按原始循环顺序逐步进入监督适配；若探索性VAEGAN候选通过质量门，则作为附加样本共同参与更新。针对跨电池容量衰减速率、阶段转换位置和寿命长度差异，采用GRU分层迁移方法，以源域历史电池学得的时序退化表示初始化模型，再根据目标电池逐步累积的有效历史窗口调整第二层GRU、全连接层和输出层参数。

本文将GRU迁移模型划分为第一层GRU共享时序特征提取层、第二层GRU目标域时序适配层和RUL映射层。其中，第一层GRU主要提取不同电池之间共享的基础容量变化规律和局部时序依赖特征；第二层GRU在第一层输出基础上进一步表征与目标电池退化速率、阶段转换及局部趋势相关的时序特征；全连接层和输出层用于建立第二层GRU输出特征与RUL之间的映射关系。源域预训练阶段，利用经EWMA容量再生候选区间检测和区间筛选后的历史电池有效退化样本对模型进行端到端训练，第一层GRU、第二层GRU、全连接层和输出层参数均参与更新。

设第t个时刻的输入特征为x_t，上一时刻隐藏

状态为h_{t-1}，GRU的状态更新过程如下：

$$\begin{cases} z_t = \sigma(W_z x_t + b_z^{\mathrm{x}} + U_z h_{t-1} + b_z^{\mathrm{h}}) \\ r_t = \sigma(W_r x_t + b_r^{\mathrm{x}} + U_r h_{t-1} + b_r^{\mathrm{h}}) \\ \widetilde{h}_t = \tanh(W_h x_t + b_h^{\mathrm{x}} + r_t \odot (U_h h_{t-1} + b_h^{\mathrm{h}})) \\ h_t = z_t \odot h_{t-1} + (1 - z_t) \odot \widetilde{h}_t \end{cases} \tag{16}$$

式（16）中，z_t和r_t分别表示更新门和重置门，$\widetilde{h}_t$表示候选隐藏状态，h_t表示当前隐藏状态；σ为Sigmoid激活函数，tanh为双曲正切激活函数，⊙表示按元素相乘；W，U，b为待学习参数。更新门z_t用于调节历史退化信息h_{t-1}与当前候选状态$\widetilde{h}_t$的融合比例，重置门r_t用于控制历史状态对当前候选状态的影响程度。通过重置门和更新门的协同作用，GRU能够在容量退化序列中保留长期退化特征。

本实现采用TensorFlow 2.20.0的默认GRU参数化形式。式（16）中，上标x和h分别标记输入偏置与循环偏置；重置门在循环线性变换后作用于候选状态的循环贡献，更新门z_t对历史状态h_{t-1}加权，$1-z_t$对候选状态加权。输入维数为1、单层单向GRU单元数为30时，第一层GRU参数量为3×30×(1+30+2)=2970；第二层GRU输入维数为30，参数量为5580；全连接层和输出层参数量分别为930和31，总参数量为9511，与表7一致。

目标域适配的监督标签、释放顺序和参数更新时序按4.1节所述离线回放协议确定。模型仅在形成新增真实有效窗口时更新；更新时固定第一层GRU共享时序特征提取层，并更新第二层GRU目标域时序适配层、全连接层和输出层，所得参数从下一次循环起生效。

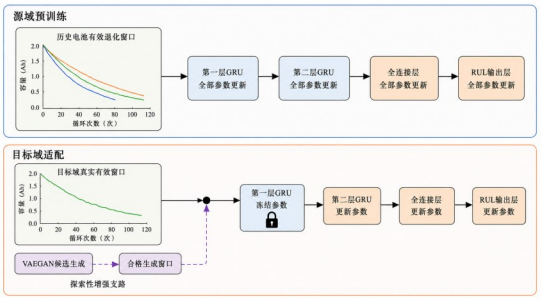


图3　基于GRU的分层迁移学习过程

Fig. 3　Layer-wise transfer learning process based on GRU

如图3所示，目标域适配阶段固定第一层GRU参数，并联合更新第二层GRU、全连接层和输出层，以适配目标电池的退化特征和RUL映射关系。

由此形成以容量再生分阶段处理和GRU跨电池分层迁移为主体、以VAEGAN为探索性候选增强分支的有监督离线回放流程。真实有效窗口直接参与目标域适配；生成窗口仅在满足质量门时作为附加样本接入。图4按源域预训练、第k次循环预测与离线评价、目标域监督适配三个阶段给出完整时序。

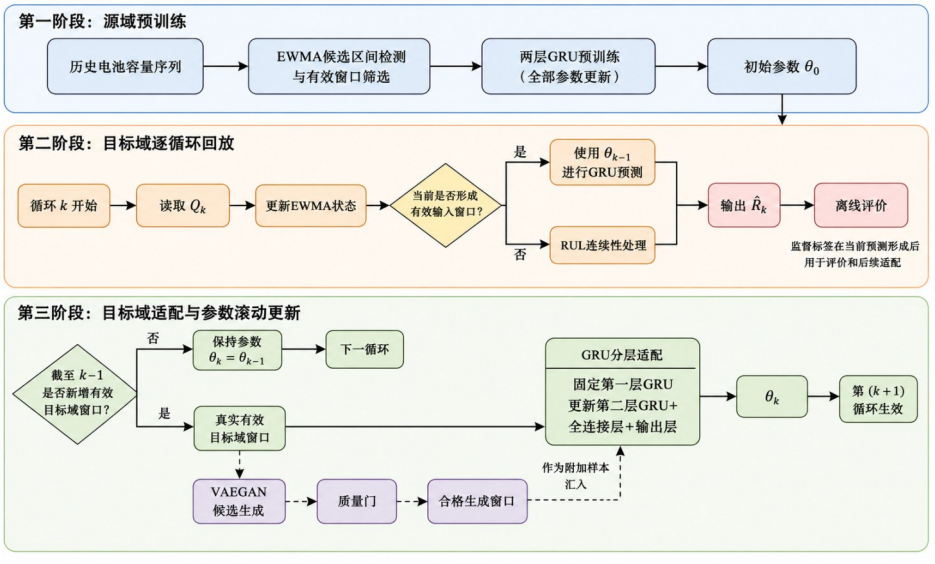


图4　三阶段RUL有监督离线回放框架

Fig. 4　Three-stage supervised offline replay framework for RUL prediction

4 实验验证

4.1 数据集、离线回放流程与评价指标

本文选取NASA锂离子电池老化数据集中的B0005、B0006、B0007和B0018四组电池，将每块电池首个有效放电循环的实测容量记为Q_0，并按$Q_k^* = Q_k/Q_0 \times 1.85\ \text{Ah}$对第$k$次循环容量进行统一尺度映射。该映射仅用于统一不同电池的容量尺度，不改变原始循环编号。将首次满足$Q_k^* \leqslant 1.48\ \text{Ah}$的循环定义为寿命终点$N_{EOL}$，其中$1.48\ \text{Ah} = 0.8 \times 1.85\ \text{Ah}$。第$k$次循环的RUL标签按$y_k = N_{EOL} - k$回溯构造，模型训练与评价范围截至该寿命终点循环。

实验每次选取一组电池作为目标电池，其余三组作为历史电池。历史电池经EWMA检测和区间筛选后形成源域预训练样本；目标电池容量观测按循环顺序逐步释放，并采用相同规则判断容量再生状态。目标域适配遵循“先预测、后评价、再更新”的顺序，更新后的参数只作用于后续循环。

有监督离线回放是按时间顺序释放目标域信息的监督参照实验，不等同于在役阶段实时获得RUL标签的在线监督预测。对于第k次循环，模型输入、容量再生状态判断及RUL输出仅使用截至第k次循环的容量观测；目标域RUL标签由完整寿命记录中的EOL按式（2）回溯构造，在当前输出形成后用于离线评价，并作为后续循环目标域适配的监督信息。该设置的作用是固定信息释放顺序并量化历史有效窗口逐步增加时各处理环节的行为，而不是将完整寿命标签作为工程在线输入。

预测起点统一设为第15次循环。在首次预测之前，仅累计目标电池容量观测并完成EWMA状态递推，不进行目标域监督参数更新；第15次循环的首次预测由源域预训练模型给出。此后的有监督离线回放顺序如下。

设θ_{k-1}为第k次循环预测开始前已经生效的模型参数，X_k为以第k次循环为末端的容量输入窗口。在第k次循环的离线回放过程中，依次执行以下过程：

（1）读取第k次循环容量，并依据截至当前循环的容量观测完成EWMA状态判定；

（2）使用参数θ_{k-1}对当前容量窗口X_k给出RUL预测。若第k次循环位于容量再生候选区间，则当前循环样本不作为有效适配样本，最终RUL输出按照式（9）进行RUL连续性处理；若容量再生候选区间已经结束但尚未重新形成完整有效窗口，则保持RUL输出连续递减；

（3）在当前RUL输出形成后，调用由已知EOL按式（2）回溯构造的RUL标签计算离线评价指标。第k次循环的标签不参与第k次循环预测，也不进入本次参数更新；

（4）完成当前循环预测和离线评价后，检查截至第k–1次循环是否形成新增有效目标域窗口。若存在，则将满足条件的目标域有效历史窗口作为监督适配基础样本；同时将可用于生成增强的有效窗口作为父窗口，构造VAEGAN候选样本，并将通过质量门的生成窗口作为附加样本加入适配数据集。随后固定第一层GRU参数，更新第二层GRU、全连接层和输出层，所得参数从第k+1次循环起生效。

与一次性离线训练—测试不同，本文在每个循环位置恢复当时可用的容量观测、有效窗口集合及模型参数状态，并按照历史信息的实际释放顺序触发或暂停目标域更新。该回放方式能够记录容量再生候选区间、有效窗口累积和参数更新之间的路径依赖，用于分析不同适配策略随目标域历史信息增加时的动态行为。

式（9）给出的RUL连续性处理结果作为相应循环的最终预测输出，并与GRU直接预测结果共同纳入平均绝对误差（mean absolute error, MAE）、均方根误差（root mean square error, RMSE）和决定系数（coefficient of determination，R^2）统计。

本文以MAE、RMSE和R^2评估模型性能。MAE用于衡量预测RUL与真实RUL之间的平均偏差；RMSE对较大预测偏差更为敏感；R^2用于评价预测结果对真实RUL变化趋势的拟合程度。通常情况下，MAE和RMSE越小，R^2越接近1，说明模型预测性能越好。计算公式为：

$$MAE = \frac{1}{n}\sum_{i=1}^{n}\left|y_i - \hat{y}_i\right| \tag{17}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(y_i - \hat{y}_i\right)^2} \tag{18}$$

$$R^2 = 1 - \frac{\sum_{i=1}^{n}\left(y_i - \hat{y}_i\right)^2}{\sum_{i=1}^{n}\left(y_i - \bar{y}\right)^2} \tag{19}$$

式（17）—式（19）中，y_i和$\hat{y}_i$分别为第i个

评价循环的真实RUL和预测RUL，$\bar{y}$为全部评价循环真实RUL的算术平均值，n为评价循环数。

4.2 容量再生处理与目标域候选样本审计

图5在原始循环时间轴上给出四块电池的EWMA容量再生候选区间检测与循环点筛选结果。图5(a)统一采用容量差分实线、EWMA动态控制上限虚线、容量再生候选区间浅色阴影和被标记循环叉号；图5(b)以浅灰色完整原始容量曲线保留真实轨迹，并以断续实线和圆点突出有效容量。候选区间两侧的有效容量段不作跨区间连线。

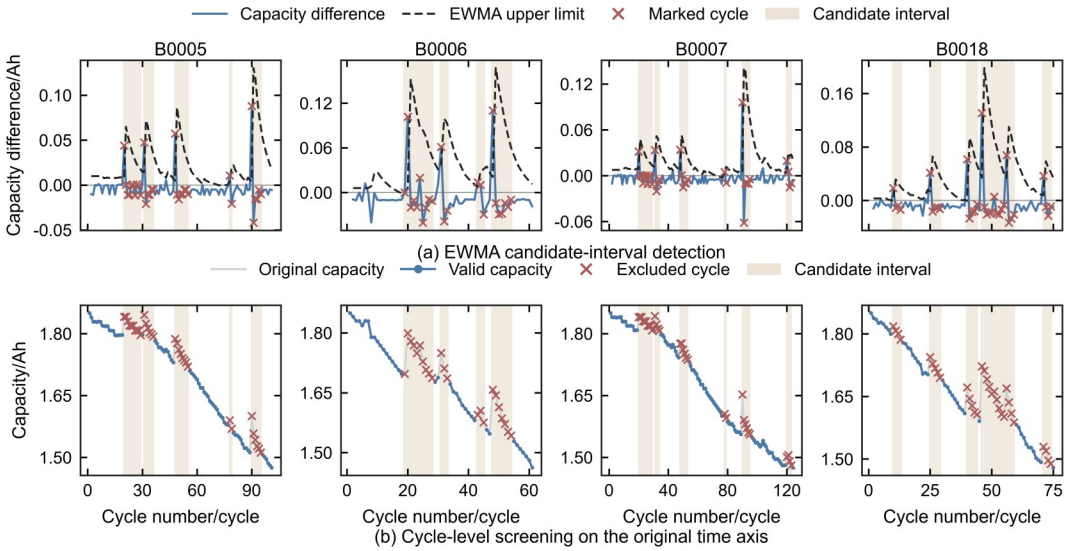


图5 EWMA容量再生候选区间检测与循环点筛选结果：(a) 容量差分、动态控制上限及容量再生候选区间；(b) 原始循环时间轴上的有效容量与筛除循环

Fig. 5 EWMA-based candidate-interval detection and cycle-level screening: (a) capacity differences, dynamic control limits, and candidate intervals; (b) valid capacity and excluded cycles on the original cycle axis

图5展示的是循环点层面的容量再生候选区间标记与筛除结果。图5(b)中的浅灰色曲线表示未经筛选的完整容量轨迹，蓝色有效容量段按原始循环编号绘制；容量再生候选区间造成的断点被有意保留，模型不会跨越断点拼接训练窗口。容量再生候选区间内RUL连续性处理按式（9）执行，训练窗口数量、被排除窗口数及有效窗口保留率由表8统计。

容量再生候选区间筛选后，目标电池真实有效窗口直接用于后续GRU监督适配。对可用于生成的真实有效窗口，程序记录其父窗口身份、候选样本质量指标、质量门通过状态和最终入选状态，形成样本审计日志。图6据此展示真实父窗口、候选重构窗口与最终入选样本的对应关系，用于说明样本接入的可追溯性。

图6选取B0007在基础随机种子2026下、父

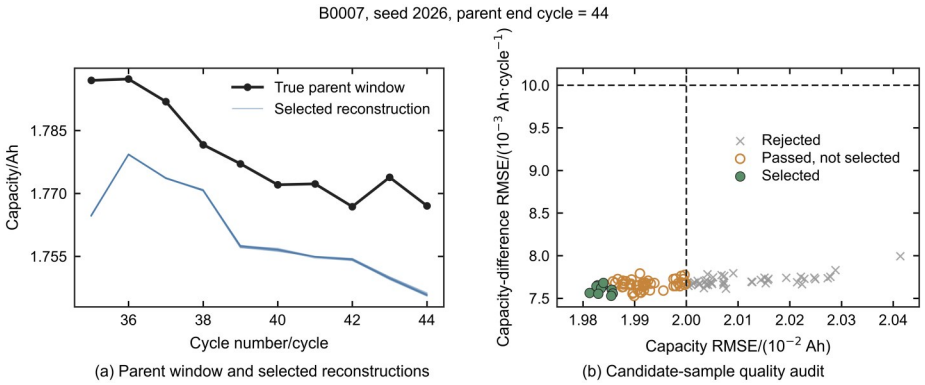


图6 VAEGAN父窗口重构与候选样本质量审计：(a) 真实父窗口与入选重构窗口；(b) 候选样本质量门结果

Fig. 6 VAEGAN audit: (a) parent and selected reconstructions; (b) candidate quality-gate results

窗口末端为第44次循环的一次代表性更新。在第72次循环预测和评价完成后生成100组候选，其中57组通过质量门，按重构误差排序后最终入选10组。左图绘制真实父窗口和全部10组入选重构窗口；右图通过实心圆、空心圆和叉号分别表示最终入选、通过但未入选和未通过质量门的候选。右图仅直接展示容量序列均方根误差与容量差分序列均方根误差两项筛选条件，归一化边界比例不大于0.10作为第三项独立质量约束同时执行。

4.3 参数设置

本文的数据读取、EWMA预处理、VAEGAN候选样本构造、时序模型训练及离线回放均在64位Windows环境下采用Python 3.12.14实现；数据处理、数值计算、结果可视化和误差评价分别使用Pandas 2.3.3、NumPy 2.5.2、Matplotlib 3.11.1和scikit-learn 1.9.0，重复实验统一基于TensorFlow 2.20.0实现。计算平台配备Intel Core i5-14490F CPU（16个逻辑处理器）和NVIDIA GeForce RTX 5060 GPU（8 GB显存）；所用TensorFlow为非CUDA的CPU构建，实验训练与推理实际使用CPU，GPU未参与计算。

在B0005上比较VAEGAN卷积核数量、卷积核尺寸、膨胀因子序列和GRU单元数的候选组合，并综合MAE与运行时间确定后续参数。表2报告B0005参数开发阶段的单次结构筛选结果；表3采用固定参数和5个预设随机种子执行完整离线回放，两表的实验目的和统计口径不同，不作直接性能比较。

B0005作为开发集。B0006、B0007和B0018在模型结构、训练协议及质量门阈值固定后构成固定参数内部评估集。评估其中任一目标电池时，该电池不进入该轮源域预训练，源域由其余三块电池组成。B0006、B0007和B0018曾作为源域数据参与B0005开发实验，开发阶段与后续内部评估在数据角色上存在耦合，因此当前结果用于内部评估，不作为独立外部泛化证据。

表1 GRU的网络参数

Table 1 Network parameters of GRU

结构参数	取值	训练参数	取值
输入窗口长度	10	学习率	0.005
全连接层节点数	30	训练轮数	250
候选隐藏状态激活函数	tanh	损失函数	均方误差
输出维度	1	优化器	Adam
第一层GRU节点数	30	学习率下降因子	0.2
第二层GRU节点数	30	学习率下降周期	100

如表1所示，预测网络包含两层GRU隐藏层、全连接层和输出层。目标域适配使用真实有效窗口及通过质量门的增强样本；第一层GRU保持冻结，其余层参与更新。

表2 B0005开发阶段候选结构比较结果（单次运行）

Table 2 Candidate-structure comparison on B0005 during development (single run)

VAEGAN卷积核数量	VAEGAN卷积核尺寸	VAEGAN膨胀因子	GRU单元数	MAE/循环	运行时间/s
16	10	[1-2,4,8,16,32]	30	2.21	2.6
32	10	[1-2,4,8,16,32]	30	1.81	3.2
128	10	[1-2,4,8,16,32]	30	1.65	8.7
64	1	[1-2,4,8,16,32]	30	2.81	1.4
64	5	[1-2,4,8,16,32]	30	1.79	2.6
64	20	[1-2,4,8,16,32]	30	2.03	5.2
64	10	[1-2,4,8]	30	1.98	1.8
64	10	[1-2,4,8,16]	30	1.72	2.8
64	10	[1-2,4,8,16,32,64]	30	1.61	6.5
64	10	[1-2,4,8,16,32]	10	2.10	3.3
64	10	[1-2,4,8,16,32]	50	1.85	3.6
64	10	[1-2,4,8,16,32]	100	1.57	4.7
64	10	[1-2,4,8,16,32]	30	1.12	3.8

EWMA参数对四组电池统一设置。递推前采用最初5个容量差分进行预热；若其中至少包含2个非正差分，则优先使用这些非正差分计算初始均值和方差，否则使用全部有效预热差分。标准差下

限设为10^{-6}Ah，平滑因子α = 0.3，控制上限系数κ = 3，容量回落判定容差ε=0 Ah。标准差下限仅用于避免预热窗口内容量差分波动过小时控制上限退化，不作为容量再生的独立判定阈值。参数α和κ分别控制统计状态对近期变化的响应程度及异常正向差分的判定灵敏度。上述参数在四组电池上保持不变，其跨电池适用性通过检测敏感性和固定参数内部评估共同考察。

上述EWMA参数采用统一经验设置，未以B0005或固定参数内部评估电池的预测误差为目标进行寻优，并在四块电池上保持不变。4.4.1节用于考察参数变化对容量再生候选区间标记、有效窗口及最终RUL误差的影响，不作为参数优化过程。

在参数开发阶段已比较的候选组合中，当VAEGAN卷积核数量为64、卷积核尺寸为10、膨胀因子序列为[1,2,4,8,16,32]、GRU单元数为30时，单次比较的MAE为1.12个循环，运行时间为3.8 s；后续实验采用该组合。

VAEGAN训练采用Adam优化器，编码器—生成器与判别器的学习率均为0.001，批量大小为32；每个批次依次更新判别器和编码器—生成器各1次，更新比例为1∶1，重构损失、KL损失和生成对抗损失的权重均为1。目标域真实有效窗口首次达到5个时初始化VAEGAN并训练200轮；此后仅在新增真实有效窗口出现时继承已有参数，并利用截至当前的全部真实有效窗口增量训练20轮，无新增窗口时不重复训练。

固定模型结构、质量门阈值与训练协议后，采用基础随机种子2026、2027、2028、2029和2030，对每块目标电池分别执行5次完整训练与离线回放。为避免不同目标电池共享同一随机序列，B0006、B0007和B0018分别在基础种子上增加100000、200000和300000的固定偏移。所有预设种子均纳入统计，不依据结果筛选；各指标报告5次运行的均值±样本标准差。

统一回放中，源域预训练学习率和轮数分别为0.005和250，批量大小为16；目标域每出现新增有效窗口时，模型更新5轮，学习率为0.0035，批量大小为16。真实目标域样本的逐样本权重设为1。为避免生成样本数量扩增直接转化为训练权重增加，每次更新时由全部生成样本共同分配受控总权重。生成样本总权重比例在B0005开发阶段采用预设随机种子2026—2028，与目标域学习率、单次更新轮数和批量大小进行有界联合搜索后确定为0.10，并在B0006、B0007和B0018的固定参数内部评估中保持不变。该值表示预设搜索范围和开发评价准则下的选定结果，不解释为理论最优或跨电池最优权重。目标域适配阶段，第一层循环层保持冻结。在第k次预测完成后，使用末端循环不晚于$k-1$的已释放历史窗口更新模型参数，并从第$k+1$次循环起生效。

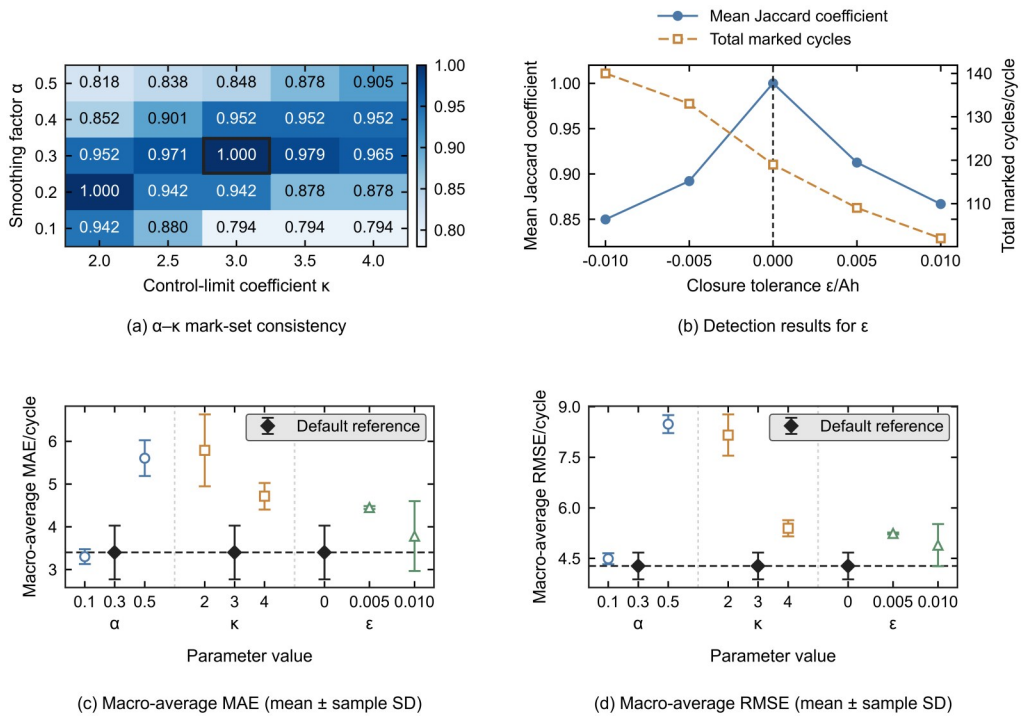
4.4 同一实验条件下的消融、敏感性与增强策略分析

4.4.1 EWMA参数敏感性

在不重新选择默认参数的前提下，对平滑因子α、控制上限系数κ和容量回落判定容差ε开展检测层敏感性分析。α取0.1—0.5，κ取2.0—4.0，ε取−0.010—0.010 Ah；默认设置为α=0.3、κ=3、ε=0 Ah。图7(a)给出不同α—κ组合相对于默认设置的再生标记集合Jaccard系数。该系数为某参数组合与默认设置所标记循环集合的交集大小除以并集大小，越接近1表示两组标记越一致。图7(b)给出ε变化时固定参数内部评估电池的平均Jaccard系数及4块电池总标记点数。

在默认参数邻域内，固定参数内部评估电池的平均Jaccard系数为0.878—0.979；当ε由−0.010 Ah变至0.010 Ah时，该系数为0.850—0.913，4块电池的总标记点数由140变至102。默认设置在当前数据邻域内具有一定检测稳定性，但参数变化会改变区间持续时间和有效窗口数量。该结果评价检测与筛选层的敏感性，不涉及后续RUL预测误差最优性。

为检验参数变化是否传递至最终RUL误差，固定GRU结构、分层适配规则和训练预算，关闭VAEGAN以隔离EWMA作用，采用种子2026—2028在B0006、B0007和B0018上运行GRU+EWMA+TL。图7(c)和图7(d)按α、κ和ε分组绘制离散数据点，不在不同参数配置之间连接折线；竖直误差棒表示3个预设随机种子的均值±样本标准差。同一参考设置α=0.3、κ=3、ε=0 Ah在三个参数组中重复显示以便组内比较，不代表新增实验。参考设置的MAE和RMSE分别为3.398±0.627和4.275±0.397个循环。α=0.1时MAE降低0.095个循环，但RMSE增加0.217个循环；α=0.5或κ=2



(a) α–κ mark-set consistency　(b) Detection results for ε

(c) Macro-average MAE (mean ± sample SD)　(d) Macro-average RMSE (mean ± sample SD)

图7　EWMA检测层与预测层参数敏感性：(a) *α*—*κ*参数下的标记一致性；(b) *ε*参数下的检测结果；(c) 不同EWMA参数配置下的宏平均MAE（均值±样本标准差）；（d）不同EWMA参数配置下的宏平均RMSE（均值±样本标准差）

Fig. 7　Detection- and prediction-level sensitivity of EWMA parameters: (a) mark-set consistency under *α* and *κ*; (b) detection results under *ε*; (c) macro-average MAE across EWMA parameter settings (mean ± sample standard deviation); (d) macro-average RMSE across EWMA parameter settings (mean ± sample standard deviation)

时两项误差均明显增大；*κ*=4和*ε*=0.005 Ah未带来改善，*ε*=0.010 Ah的种子间离散程度增大。EWMA参数会经容量再生候选区间和有效窗口数量影响预测；参考设置用于统一实验协议。不同参数下MAE和RMSE响应方向并不完全一致，因此本组结果不用于重新选择EWMA参数。

4.4.2　五随机种子固定参数消融与不确定性

依次选取4块电池作为目标电池，其余3块作为源域电池。表3在统一数据划分、预测起点、标签释放顺序和训练预算下比较不同流程的有监督离线回放结果。Source-Only GRU+EWMA仅采用源域预训练参数进行目标电池预测；GRU+EWMA+TL利用目标域真实有效窗口执行分层适配；GRU+EWMA+TL+门控VAEGAN为完整流程，在真实窗口基础上加入通过质量门控的生成样本；无EWMA流程关闭容量再生候选区间识别、有效窗口筛选、容量再生候选区间内RUL连续性处理以及容量再生候选区间结束后重新形成完整有效窗口前的连续递减处理，其余训练与更新条件保持一致。无EWMA对照同时移除了容量再生候选区间识别、有效窗口筛选和RUL连续性处理，因此其结果反映EWMA相关处理链的综合作用，不用于分解各子环节的独立贡献。

与Source-Only GRU+EWMA相比，采用真实目标域有效窗口执行分层适配后，三块固定参数内部评估电池的宏平均MAE由约6.87个循环降至3.90个循环，宏平均RMSE由约7.81个循环降至4.75个循环。逐电池结果表明，误差改善主要来自B0007，B0006变化较小，B0018误差增加，说明目标域适配的作用具有明显的电池差异。

图8按原始循环编号比较真实RUL、完整流程5随机种子均值、完整流程±1样本标准差带和无EWMA流程5随机种子均值。标准差带仅用于完整流程，不为无EWMA流程叠加第二组阴影；B0005明确标记为开发集。

统计以每个基础种子在B0006、B0007和B0018上对应指标的等权算术平均为单位，即先在每个种子内对3块固定参数内部评估电池求均值，

表3　开发阶段参考与固定参数内部评估流程的五随机种子结果（均值±样本标准差）

Table 3　Five-seed results of the development reference and fixed-parameter internal-assessment workflows (mean ± sample standard deviation)

目标电池	方法	MAE/循环	RMSE/循环	R^2
B0005（开发阶段参考）	Source-Only GRU+EWMA	13.47±0.18	14.41±0.20	0.671±0.009
	GRU+EWMA+TL	4.32±0.91	5.40±1.26	0.952±0.022
	GRU+EWMA+TL+门控VAEGAN（完整流程）	3.62±1.01	4.70±1.35	0.963±0.020
	GRU+TL+VAEGAN（无EWMA）	5.01±0.53	6.72±0.70	0.928±0.015
B0006（固定参数内部评估）	Source-Only GRU+EWMA	4.52±1.05	4.54±1.06	0.883±0.052
	GRU+EWMA+TL	4.51±3.00	4.71±2.96	0.841±0.203
	GRU+EWMA+TL+门控VAEGAN（完整流程）	4.51±3.00	4.71±2.96	0.841±0.203
	GRU+TL+VAEGAN（无EWMA）	4.04±0.70	5.13±1.06	0.852±0.061
B0007（固定参数内部评估）	Source-Only GRU+EWMA	14.26±0.22	15.53±0.25	0.761±0.008
	GRU+EWMA+TL	4.56±0.11	5.52±0.22	0.970±0.002
	GRU+EWMA+TL+门控VAEGAN（完整流程）	4.57±0.21	5.60±0.26	0.969±0.003
	GRU+TL+VAEGAN（无EWMA）	3.70±0.39	5.61±0.63	0.968±0.007
B0018（固定参数内部评估）	Source-Only GRU+EWMA	1.84±0.23	3.35±0.12	0.964±0.003
	GRU+EWMA+TL	2.62±0.88	4.01±0.55	0.947±0.015
	GRU+EWMA+TL+门控VAEGAN（完整流程）	2.62±0.88	4.01±0.55	0.947±0.015
	GRU+TL+VAEGAN（无EWMA）	4.89±0.55	6.36±0.59	0.869±0.024

注：B0005为参数开发集，其结果仅用于说明参数开发阶段表现，不作为内部评估证据；B0006、B0007和B0018为固定参数内部评估集。

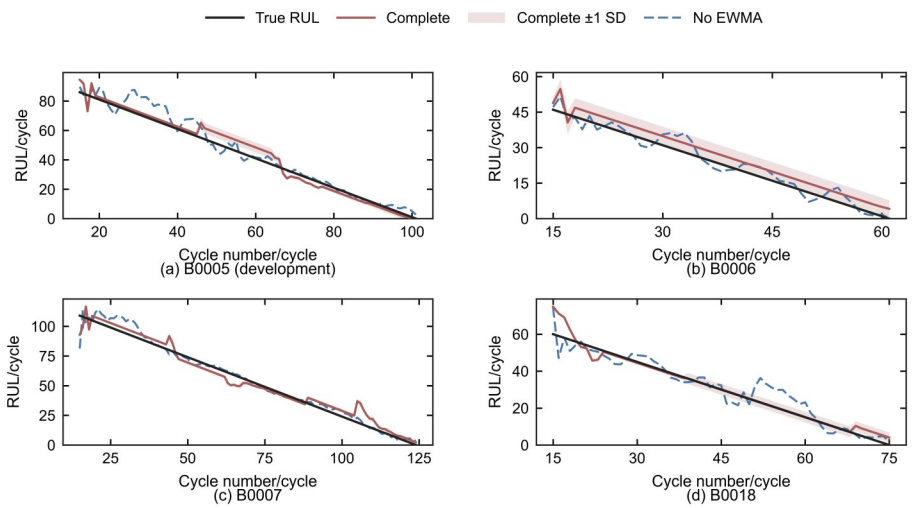


图8　完整流程与无EWMA流程的RUL预测曲线：(a) B0005（开发集）；(b) B0006；(c) B0007；(d) B0018。完整流程显示5随机种子均值±1样本标准差，无EWMA流程显示5随机种子均值

Fig. 8　RUL prediction curves of the complete and no-EWMA workflows: (a) B0005 (development); (b) B0006; (c) B0007; (d) B0018. The complete workflow shows the five-seed mean ± one sample standard deviation, whereas the no-EWMA workflow shows the five-seed mean

再比较不同流程。完整流程与无EWMA流程的宏平均MAE分别为3.90±1.11和4.21±0.39个循环，二者相差0.31个循环，小于完整流程1.11个循环的种子间标准差。RMSE分别为4.77±1.06和5.70±0.63个循环，表明EWMA处理对平均误差和较大偏差的影响并不一致。因此，进一步从逐电池误差方向、种子间离散程度以及有效窗口保留情况分析EWMA处理的作用。

逐电池比较显示，完整流程相对于无EWMA流程仅在B0018上同时降低MAE和RMSE；B0006表现为MAE略高而RMSE略低，B0007表现为MAE略高而RMSE近似。图8中B0006完整

流程的预测标准差带明显宽于B0007和B0018，与其MAE样本标准差3.00个循环一致；无EWMA均值曲线则直接呈现关闭容量再生候选区间处理后的轨迹差异。B0006对随机初始化、有效窗口数量和参数更新路径更敏感，其不稳定性在4.6节结合再生特征讨论。

4.4.3 探索性VAEGAN增强分支及增量作用分析

表4依据5个种子的样本审计日志汇总探索性VAEGAN分支的候选生成、质量门通过和最终入选情况。候选样本数为全部回放更新节点上的累计生成数量；同一父窗口在不同更新节点产生的候选分别计入，因此该数值不等同于唯一父窗口数。无候选通过质量门时，流程自动退化为仅使用真实目标域窗口适配。

表4 探索性VAEGAN分支的候选与入选样本审计

Table 4 Candidate and selected-sample audit of the exploratory VAEGAN branch

目标电池	候选样本数	通过数（通过率/%）	入选样本数	有入选种子/5
B0005	170500	10095（5.92）	1249	5/5
B0006	17500	0（0.00）	0	0/5
B0007	512500	23786（4.64）	3157	5/5
B0018	2500	148（5.92）	20	2/5

B0006上完整流程与GRU+EWMA+TL的三项指标完全一致，因为5个种子均无生成样本通过默认质量门，VAEGAN分支没有实际参与更新。B0018虽有2个种子合计入选20组生成样本，且原始模型输出在部分循环出现差异，但相关循环处于容量再生或窗口恢复连续性处理阶段，最终用于评价的RUL输出仍与仅使用真实窗口适配的流程一致；B0007的5个种子均有样本入选，MAE却略高。三块固定参数内部评估电池均未观察到VAEGAN带来的误差改善。B0005的MAE变化只属于参数开发阶段现象，不作为内部评估证据。

因此，质量门在当前流程中主要承担候选样本接入控制和可追溯审计功能。候选通过率和入选数量反映VAEGAN在不同目标电池中的实际参与程度。

为隔离质量门阈值的影响，门控敏感性实验对基础随机种子2026—2028固定同一批候选样本，仅改变筛选阈值，并依次设置严格、默认和宽松3档质量门：严格质量门的3项阈值为0.015 Ah、0.0075 Ah/循环和0.05；默认质量门的阈值为0.020 Ah、0.0100 Ah/循环和0.10；宽松质量门的阈值为0.025 Ah、0.0125 Ah/循环和0.20。每个父窗口最多保留10组。父窗口覆盖率定义为至少存在1个候选样本通过质量门的父窗口数与参与生成的父窗口总数之比。表5报告各档质量门的通过率、父窗口覆盖率和入选数，以避免候选池变化对质量门阈值比较造成干扰。

表5 同一候选池上的VAEGAN质量门控敏感性（3个随机种子）

Table 5 Sensitivity of VAEGAN quality gates on an identical candidate pool (three random seeds)

目标电池	门控	候选通过率/%	父窗口覆盖率/%	入选样本数
B0005（开发）	严格	2.34	3.13	278
	默认	6.25	8.41	808
	宽松	13.26	15.44	1522
B0006	严格	0.00	0.00	0
	默认	0.00	0.00	0
	宽松	0.00	0.00	0
B0007	严格	1.68	4.16	1025
	默认	4.14	6.93	1921
	宽松	6.44	8.94	2610
B0018	严格	0.27	13.33	4
	默认	9.87	13.33	20
	宽松	10.33	13.33	20

宽松门提高了B0005和B0007的候选通过率和父窗口覆盖率；B0006在3档门控下均无候选通过，B0018的父窗口覆盖率保持不变。在当前实验中，生成样本的接入程度随目标电池和门控阈值而异。

为区分生成模型的分布学习作用与样本数量增加、重复训练或一般扰动效应，比较仅真实样本、真实样本重复、Bootstrap重采样[21]、高斯轻微扰动和VAEGAN。其中，真实样本重复、Bootstrap重采样、高斯轻微扰动和VAEGAN四种增强策略保持可用于增强的父窗口、每次新增样本数、附加样本总权重、更新时间点和训练预算一致；Bootstrap重采样采用从真实窗口中有放回抽取的方式。表6以3块固定参数内部评估电池在每个种子内的电池级宏平均为统计单位，采用预设的3个随机种子。MAE差值定义为“对照策略减VAEGAN”，正值表示VAEGAN误差更低；同时给出该差值的95%置信区间（95% confidence

interval，95% CI）。

具体地，先在每个基础随机种子内对B0006、B0007和B0018的MAE等权平均，再形成3个种子级配对差值。95% CI采用配对差值均值的双侧Student *t*区间，以配对差值的样本标准差估计不确定性，样本量n=3，自由度为2。

表6　等增强机会下的简单增强与VAEGAN参照（均值±样本标准差）

Table 6　Simple augmentation and VAEGAN under equal augmentation opportunities (mean ± sample standard deviation)

增强策略	MAE/循环	RMSE/循环	R^2	MAE差值的95% CI
仅真实样本	3.398±0.627	4.275±0.397	0.95108±0.01412	[-0.026, 0.041]
真实样本重复	3.393±0.616	4.280±0.382	0.95103±0.01396	[-0.010, 0.015]
Bootstrap	3.384±0.628	4.270±0.396	0.95114±0.01412	[-0.043, 0.030]
高斯轻微扰动	3.392±0.617	4.279±0.384	0.95104±0.01397	[-0.011, 0.016]
VAEGAN	3.390±0.613	4.276±0.386	0.95107±0.01401	参照

VAEGAN与真实样本重复、Bootstrap及高斯轻微扰动的宏平均MAE分别为3.390、3.393、3.384和3.392个循环。三种简单增强策略与VAEGAN的宏平均MAE绝对差值均不超过0.006个循环，种子级配对差值的95%置信区间均包含0，当前实验未观察到VAEGAN的稳定增量收益。

可能原因包括：容量再生筛选后可用父窗口较少，质量门进一步压缩候选接入数量；重构窗口继承父窗口的末端循环和RUL标签，主要扩展局部形态而未引入新的退化阶段；小样本条件限制了生成分布学习；生成样本总权重比例0.10由B0005开发阶段的有界联合搜索确定，并在内部评估中保持固定。该设置限制了生成样本在参数更新中的相对贡献，其跨电池适用性仍需进一步验证。这些解释与当前审计结果一致，但仍需在独立数据和更多父窗口条件下验证。

4.5　当前配置下GRU、LSTM与BiLSTM的误差与参数量参照

GRU、LSTM和双向长短期记忆网络（bidirectional LSTM，BiLSTM）采用相同的源域与目标域数据、EWMA处理、监督样本及释放时点、VAEGAN样本、预测更新顺序、优化器、学习率、训练轮数、批量大小和基础随机种子2026—2030，仅替换循环网络类型。三种架构均为两层结构，目标域适配时冻结第一层循环层，更新第二层循环层、全连接层和输出层；B0005不进入主比较。由于参数量未匹配，本节只比较当前配置下的误差与参数规模，不据此判断不同循环网络的内在优劣。

表7　当前配置下循环网络的五随机种子误差与参数量参照

Table 7　Five-seed error and parameter-count reference for recurrent networks under the current configurations

目标电池/范围	架构	参数量	MAE/循环	RMSE/循环	R^2
B0006	GRU	9511	4.510±3.002	4.710±2.964	0.841±0.203
	LSTM	12121	4.811±2.508	5.203±2.452	0.827±0.141
	BiLSTM	31381	4.232±2.620	4.672±2.247	0.859±0.121
B0007	GRU	9511	4.565±0.208	5.599±0.262	0.969±0.003
	LSTM	12121	4.504±0.213	6.338±0.240	0.960±0.003
	BiLSTM	31381	6.460±0.978	8.192±1.102	0.932±0.018
B0018	GRU	9511	2.623±0.881	4.007±0.548	0.947±0.015
	LSTM	12121	3.643±0.676	4.812±0.732	0.924±0.022
	BiLSTM	31381	2.952±1.002	3.996±0.767	0.947±0.020
3块固定参数内部评估电池宏平均	GRU	9511	3.899±1.113	4.772±1.055	0.919±0.069
	LSTM	12121	4.319±0.790	5.451±0.844	0.904±0.048
	BiLSTM	31381	4.548±0.529	5.620±0.573	0.913±0.035

注：GRU、LSTM和BiLSTM的参数量分别为9511、12121和31381；BiLSTM约为GRU的3.30倍。本表保持监督信息、处理组件和训练协议一致，但未匹配参数规模。

三块固定参数内部评估电池的种子内宏平均MAE分别为3.899±1.113、4.319±0.790和4.548±0.529个循环。BiLSTM参数量约为GRU的3.30倍，但在当前配置下未取得更低的B0007或宏平均误差。由于未进行等参数量匹配，本组结果仅用于比较误差与参数规模的联合表现，不用于判断不同循环网络的固有优劣。

4.6 结果讨论、适用边界与局限性

为讨论EWMA处理对RUL预测的影响，表8汇总四块电池在统一参数下的再生特征与长度为10的训练窗口筛选结果。有效窗口指原始循环编号连续且窗口内不含容量再生候选区间标记的窗口；有效窗口保留率定义为有效窗口数与全部可构造窗口数之比，括号内为被排除窗口数。各容量再生候选区间的再生幅值为该区间内最大容量与区间起点前一循环回落基准容量之差，表中平均/最大幅值分别为同一电池各容量再生候选区间再生幅值的算术平均值和最大值。该统计直接来自EWMA检测和窗口审计，不涉及重新训练。

表8 容量再生特征与有效窗口筛选统计

Table 8 Capacity-regeneration characteristics and valid-window screening statistics

电池	EOL/循环	容量再生候选区间数	标记循环数	平均/最大幅值Ah	有效/全部窗口（排除）	保留率/%
B0005（开发）	101	5	32	0.050/0.088	26/92（66）	28.3
B0006	61	4	23	0.074/0.110	9/52（43）	17.3
B0007	124	6	32	0.038/0.096	45/115（70）	39.1
B0018	75	5	32	0.058/0.131	5/66（61）	7.6

B0006的寿命终止循环为61，识别出4个容量再生候选区间和23个标记循环，平均再生幅值为0.074 Ah；其有效窗口仅保留9个，保留率为17.3%。有限的目标域监督窗口可能放大随机初始化和参数更新路径差异，从而使不同随机种子下的预测结果呈现较大离散性。该电池完整流程的MAE标准差为3.00个循环，明显高于Source-Only流程的1.05个循环和无EWMA流程的0.70个循环。无EWMA流程在B0006上的MAE低0.47个循环，但RMSE高0.42个循环，反映出平均误差、较大偏差及预测离散程度同时发生变化。

在三块固定参数内部评估电池中，B0018的有效窗口保留率最低（7.6%）且最大再生幅值最高（0.131 Ah），完整流程相对于无EWMA流程的MAE和RMSE分别低2.27和2.35个循环；B0007的有效窗口保留率最高（39.1%），无EWMA流程的MAE低0.87个循环，但RMSE仅高0.01个循环。结果表明，EWMA处理的影响可能与再生幅值、区间位置和窗口损失共同有关；这一关系仍需通过更多独立电池数据进一步验证。

本研究利用完整寿命记录按式（2）回溯构造目标域RUL标签，用于离线评价和后续目标域监督适配，目标域信息仍按原始循环顺序释放。每块目标电池在其自身评估轮次均未进入源域预训练，但内部评估电池曾作为B0005开发实验的源域数据，因而存在开发阶段的数据角色耦合，尚不能代表独立外部泛化。数据规模较小、B0006预测离散度较大、统一EWMA参数具有预测层敏感性，以及探索性VAEGAN接入率和增量作用有限，均构成当前研究边界。

EWMA采用统一经验参考设置，生成样本总权重比例0.10则由B0005开发阶段的三随机种子有界联合搜索确定。两类参数的跨数据集适用性仍需在独立电池数据上验证。

5 结 论

针对容量再生干扰、目标域有效窗口有限及跨电池退化差异，构建有监督离线回放RUL预测方法。该方法以EWMA分阶段处理和GRU分层迁移为主体，以VAEGAN作为探索性候选增强分支。

（1）EWMA方法能够在原始循环时间轴上标记容量再生候选区间，并据此筛选源域与目标域有效窗口、执行容量再生候选区间内RUL连续性处理。检测层与预测层敏感性分析表明，参数变化会改变容量再生候选区间、有效窗口及最终RUL误差；统一参数在不同电池上的作用方向并不一致。

（2）有监督分层适配利用逐步释放的目标域有效历史窗口更新第二层GRU、全连接层和输出层，在部分电池上降低了离线回放误差，但适配效果和种子间稳定性存在电池差异。在相同监督信息和处

理组件、但参数量未匹配的当前配置下，GRU 呈现较好的误差—参数规模平衡。

（3）探索性 VAEGAN 分支能够构造并筛选可审计的候选窗口。在当前父窗口规模、质量门、生成样本权重和训练预算下，VAEGAN 与真实样本重复、Bootstrap 重采样和高斯轻微扰动的预测误差接近，未表现出稳定的增量收益；其当前作用主要体现在生成样本构造和质量审计。

完整寿命记录用于构造离线评价和后续目标域适配所需的监督标签，当前结果属于有监督离线回放内部评估。后续将引入 CALCE、Oxford、HUST 等公开电池数据集，开展固定参数外部验证和跨数据集迁移实验，考察不同退化轨迹和数据条件下的泛化性能；同时研究不依赖真实目标域 RUL 标签的无监督、半监督目标域适配方法，并进一步考察生成样本权重敏感性。

参 考 文 献

[1] LI T, ZHOU Z, THELEN A, et al. Predicting battery lifetime under varying usage conditions from early aging data[J]. Cell Reports Physical Science, 2024, 5(4): 101891. DOI: 10.1016/j.xcrp.2024.101891.

[2] ZHANG Y, WIK T, BERGSTRÖM J, et al. A machine learning-based framework for online prediction of battery ageing trajectory and lifetime using histogram data[J]. Journal of Power Sources, 2022, 526: 231110. DOI: 10.1016/j.jpowsour.2022.231110.

[3] ATTIA P M, BILLS A, BROSA PLANELLA F, et al. Review—'Knees' in lithium-ion battery aging trajectories[J]. Journal of The Electrochemical Society, 2022, 169(6): 060517. DOI: 10.1149/1945-7111/ac6d13.

[4] 吴胜利, 郭琪, 邢文婷. 考虑容量再生的可解释性锂离子电池剩余寿命预测方法[J]. 电工技术学报, 2026, 41(9): 3208-3220. DOI: 10.19595/j.cnki.1000-6753.tces.250665.

[5] HE N, YANG Z, QIAN C, et al. Remaining useful life prediction of lithium-ion battery based on fusion model considering capacity regeneration phenomenon[J]. Journal of Energy Storage, 2024, 85: 111068. DOI: 10.1016/j.est.2024.111068.

[6] MA Q, ZHENG Y, YANG W, et al. Remaining useful life prediction of lithium battery based on capacity regeneration point detection [J]. Energy, 2021, 234: 121233. DOI: 10.1016/j.energy.2021.121233.

[7] CHEN X, LIU Z, SHENG H, et al. Transfer learning based remaining useful life prediction of lithium-ion battery considering capacity regeneration phenomenon[J]. Journal of Energy Storage, 2024, 76: 109798. DOI: 10.1016/j.est.2023.109798.

[8] LI Z, SHEN S, YE Y, et al. An interpretable online prediction method for remaining useful life of lithium-ion batteries[J]. Scientific Reports, 2024, 14: 12541. DOI: 10.1038/s41598-024-63160-2.

[9] WANG X H, DAI K, HU M, et al. Lithium-ion battery health state and remaining useful life prediction based on hybrid model MFE-GRU-TCA[J]. Journal of Energy Storage, 2024, 95: 112442. DOI: 10.1016/j.est.2024.112442.

[10] 李英顺, 阚宏达, 郭占男, 等. 基于数据预处理和VMD-LSTM-GPR的锂离子电池剩余寿命预测[J]. 电工技术学报, 2024, 39(10): 3244-3258. DOI: 10.19595/j.cnki.1000-6753.tces.230210.

[11] 董作林, 宋金岩, 孟子迪. 基于模态分解和深度学习的锂离子电池寿命预测[J]. 储能科学与技术, 2025, 14(4): 1645-1653. DOI: 10.19799/j.cnki.2095-4239.2024.0983.

[12] 陈勇, 王俊磊, 王鹏, 等. 锂离子电池早期剩余寿命预测方法综述[J]. 电池, 2026, 56(1): 222-230. DOI: 10.19535/j.1001-1579.2026.01.035.

[13] CHE Y, STROE D I, HU X, et al. Semi-supervised self-learning-based lifetime prediction for batteries[J]. IEEE Transactions on Industrial Informatics, 2023, 19(5): 6471-6481. DOI: 10.1109/TII.2022.3206776.

[14] MA L, TIAN J, ZHANG T, et al. Enhanced battery life prediction with reduced data demand via semi-supervised representation learning[J]. Journal of Energy Chemistry, 2025, 101: 524-534. DOI: 10.1016/j.jechem.2024.10.001.

[15] 尹杰, 刘博, 孙国兵, 等. 基于迁移学习和降噪自编码器-长短时间记忆的锂离子电池剩余寿命预测[J]. 电工技术学报, 2024, 39(1): 289-302. DOI: 10.19595/j.cnki.1000-6753.tces.221890.

[16] CHOWDHURY M A, MODEKWE G, LU Q. Lithium-ion battery capacity prediction via conditional recurrent generative adversarial network-based time-series regeneration[C]// Proceedings of the 2025 American Control Conference. IEEE, 2025: 1469-1475. DOI: 10.23919/ACC63710.2025.11107734.

[17] SOO Y Y, WANG Y, XIANG H, et al. A data augmentation method for lithium-ion battery capacity estimation based on Wasserstein Time Generative Adversarial Network[J]. Energy Technology, 2025, 13(8): 2400488. DOI: 10.1002/ente.202400488.

[18] LIU K, PENG Q, CHE Y, et al. Transfer learning for battery smarter state estimation and ageing prognostics: Recent progress, challenges, and prospects[J]. Advances in Applied Energy, 2023, 9: 100117. DOI: 10.1016/j.adapen.2022.100117.

[19] LEWERENZ M, DECHENT P, SAUER D U. Investigation of capacity recovery during rest period at different states-of-charge after cycle life test for prismatic Li(Ni1/3Mn1/3Co1/3)O2-graphite cells[J]. Journal of Energy Storage, 2019, 21: 680-690. DOI: 10.1016/j.est.2019.01.004.

[20] EPDING B, RUMBERG B, JAHNKE H, et al. Investigation of significant capacity recovery effects due to long rest periods during high current cyclic aging tests in automotive lithium ion cells and their influence on lifetime[J]. Journal of Energy Storage, 2019, 22: 249-256. DOI: 10.1016/j.est.2019.02.015.

[21] LIU Z, WANG Y, CHEN J, et al. Dual-Driven Battery Life Prediction Based on Data Augmentation and Capacity Recovery Identification[J]. Particuology, 2026. DOI: 10.1016/j.partic.2026.08.006.