考虑储能工况的退役动力电池退化建模与剩余寿命预测

马 峰[1,2*] 王海磊[1,3] 黄顺虎[1,3] 张 华[2,3]
1.冶金装备及其控制教育部重点实验室(武汉科技大学),武汉,430081
2.湖北隆中实验室,襄阳,441000
3.机械传动与制造工程湖北省重点实验室(武汉科技大学),武汉,430081

摘要:提出了一种融合鲸鱼优化算法(WOA)、卷积神经网络(CNN)、门控循环单元(GRU)和自注意力机制(SA)的深度学习模型,用于精准预测退役电池的剩余使用寿命。该模型充分发挥了CNN的特征提取能力、GRU的时序建模优势以及自注意力机制的长程依赖捕捉能力,并通过WOA实现超参数的全局最优配置。基于CALCE公开数据集的对比实验结果表明,所提WOA-CNN-GRU-SA模型在测试集上取得均方根误差(RMSE)为0.809 27%、平均绝对误差(MAE)为0.554 40%、决定系数R^2为99.840%的预测性能,相较于次优模型WOA-CNN-LSTM-SA,在RMSE与MAE上分别降低10.35%与13.39%,体现出更高的预测精度与鲁棒性。研究结果可为退役动力电池的精准分级与储能系统的高效可靠管理提供关键技术支撑。

关键词:退役动力电池;剩余使用寿命;储能系统;深度学习;梯次利用
中图分类号:TM912
DOI:10.3969/j.issn.1004-132X.2026.10.012 **开放科学(资源服务)标识码(OSID)**:

Degradation Modeling and Remaining Useful Life Prediction of Retired Power Batteries Considering Energy Storage Conditions

MA Feng[1,2*] WANG Hailei[1,3] HUANG Shunhu[1,3] ZHANG Hua[2,3]
1.Key Laboratory of Metallurgical Equipment and Control Technology, Ministry of Education, Wuhan University of Science and Technology, Wuhan,430081
2.Hubei Longzhong Laboratory, Xiangyang,Hubei,441000
3.Hubei Key Laboratory of Mechanical Transmission and Manufacturing Engineering, Wuhan University of Science and Technology, Wuhan,430081

Abstract: A deep learning model integrating the whale optimization algorithm (WOA), convolutional neural network (CNN), gated recurrent unit (GRU), and self-attention(SA) mechanism was proposed to achieve accurate prediction of the RUL of retired batteries. The proposed model leveraged CNN for feature extraction, GRU for temporal dependency modeling, and SA for capturing long-range dependencies, while WOA was employed to globally optimize hyperparameters. Comparative experiments on the public CALCE dataset demonstrate that the proposed WOA-CNN-GRU-SA model achieves RMSE of 0.809 27%, an MAE of 0.554 40%, and an R^2 of 99.840% on the test set. Compared with the second-best model(WOA-CNN-LSTM-SA), the RMSE and MAE are reduced by 10.35% and 13.39%, respectively, indicating superior prediction accuracy and robustness. These results provide key technical support for accurate health grading of retired power batteries and efficient, reliable management of energy storage systems.

Key words: retired power battery; remaining useful life(RUL); energy storage system; deep learning; cascade utilization

0 引言

在“双碳”目标和新型电力系统建设背景下,风能、光伏等间歇性可再生能源的大规模接入对储能系统的容量、寿命和经济性提出了更高要求。目前储能设备普遍存在投资成本高、回收周期长等问题,已成为制约其大规模应用的重要瓶颈[1]。与此同时,近年来新能源汽车保有量快速增长,动力电池报废量逐年攀升[2-3],如果处置不当,不仅

收稿日期:2025-10-17
基金项目:湖北省技术创新计划(2024BCB093,2024EIA049);湖北省科技重大专项(2023BCA006)

会带来环境污染风险，还将造成宝贵资源的浪费[4-5]。值得注意的是，大部分退役动力电池仍保有70%以上的剩余容量，其电化学性能能够满足储能系统对低倍率、长寿命和稳定运行的需求[6]。因此，将退役动力电池高效回收并应用于储能系统，不仅有助于降低储能建设成本，还能实现资源循环利用，兼顾经济效益与环境效益，具有重要的工程应用价值和广阔的推广前景[7]。

由于退役电池在使用历史、老化程度及性能状态方面存在较大差异，故直接用于储能系统存在可靠性风险[8]。储能系统运行周期长、工况稳定，对电池寿命的可预测性和健康状态管理提出了更高要求[9]。传统梯次利用中采用的通用评估方法未能针对储能工况进行适配，难以满足实际工程中对寿命预测准确性和模型适应性的要求[10]。

目前，锂离子电池剩余使用寿命(RUL)预测方法主要包括电化学模型、等效电路模型、数据驱动方法及混合策略[11]。其中，电化学模型能够基于电池内部反应机理表征退化过程，但在参数辨识、计算效率和稳定性方面仍存在一定挑战[12]；等效电路模型结构相对简洁，但其预测性能对参数辨识精度较为敏感[13]；相比之下，数据驱动方法通过挖掘历史运行数据中的退化规律来建立输入与输出之间的映射关系，已成为当前RUL预测研究的重要方向[14]。RICHARDSON等[15]采用多输出高斯过程(MOGPR)捕捉电池间相关性，提高了预测精度，但对容量突变等非平稳退化现象的刻画能力有限。ZHOU等[16]提出结合高斯过程回归与神经网络的GPRNN模型，提高了长期预测精度并降低了不确定性，但对大量退化数据存在较强依赖。

为进一步提高预测精度与鲁棒性，研究者又提出了多种融合策略。ALI等[17]构建了核递归最小二乘与高斯过程回归的组合模型(KRLS-GPR)混合框架，通过信号分解与双模型融合实现电池健康状态与RUL联合预测，但其预处理与分解过程较为复杂，实时性受限。ZHANG等[18]采用多域特征融合与麻雀搜索算法(SSA)优化Cat Boost模型，取得了较高预测精度，但特征工程复杂，模型跨电池类型的泛化能力不足。WU等[19]提出变分模态分解-蜣螂优化算法-支持向量回归相结合的组合预测(VMD-DBO-SVR)模型，利用变分模态分解抑制容量再生噪声，并通过优化算法调节模型参数，但该方法对先验设定存在一定依赖。WANG等[20]设计自适应门控序列网络(AGSN)，增强了时序特征表征能力，但网络结构复杂，部署成本较高。SALEK等[21]利用首寿历史数据迁移预测退役电池健康状态，但其跨电池型号的适用性仍有待进一步验证。

综上，现有方法在参数辨识与计算开销、数据依赖与实时部署，以及跨退役电池差异适应性等方面存在不同程度的瓶颈，亟需构建兼顾精度与工程可用性的寿命预测框架。

针对退役动力电池在储能工况下寿命预测中存在的非线性强、差异性大及参数调优依赖经验等问题，提出一种鲸鱼优化算法-卷积神经网络-门控循环单元-自注意力机制(WOA-CNN-GRU-SA)的退化建模与寿命预测方法。主要贡献如下：

1)面向退役动力电池储能再利用场景，结合储能运行工况与寿命管理需求，构建退化建模与RUL预测一体化框架。

2)提出WOA-CNN-GRU-SA预测模型，利用CNN提取局部退化特征，结合GRU建模容量演化的时序依赖关系，引入自注意力机制增强关键退化阶段表征能力，并采用WOA对关键超参数进行自动寻优，以提高模型预测精度与稳定性。

3)基于公开全寿命数据集开展对比实验与消融实验，系统评估所提方法在预测精度和泛化性能方面的表现。

4)搭建退役动力电池测试与数据采集平台，利用自建数据验证所提方法在实际退役电池及储能应用条件下的适用性与工程可行性。

1　预测模型构建

1.1　储能场景下退役电池寿命预测需求分析

相较于车辆运行环境，储能系统通常具有放电倍率低、充放电规律性较强、温度波动较小等特征，因此对电池循环稳定性和长期可靠性提出了更高要求。尽管退役动力电池仍具备一定可用容量，但其服役历史、老化程度和性能状态差异显著，导致退化路径复杂，寿命预测不确定性较高。随着循环的进行，退役电池还会出现容量衰减加剧、循环效率下降和内阻升高等现象，进而影响储能系统运行效率与安全性。与此同时，现有预测方法在特征表达、退化过程建模及参数配置等方面仍存在不足，难以兼顾预测精度、稳定性和泛化能力。

针对上述问题，本文提出一种融合WOA、CNN、GRU和SA的剩余寿命预测方法。该方法可为储能场景下退役电池的筛选、分级与运维管

理提供支撑。

需要说明的是，本文所述“退化建模”并非建立电化学机理方程或等效电路参数演化模型，而是面向工程应用构建可观测“退化特征-退化状态-寿命指标”之间的数据驱动映射关系。具体而言，通过提取各循环中的关键健康特征向量，并利用序列模型学习其随循环演化的变化规律，实现对退化状态及剩余使用寿命的表征与预测。

1.2 CNN-GRU-SA预测模型结构设计

为实现对退役动力电池剩余寿命的有效预测，本文构建了融合CNN、GRU与SA的深度学习模型。该结构能够同时兼顾局部特征提取、时序关系建模和关键退化阶段增强，适用于储能场景下退役电池缓慢演化、非线性退化的特征。

本文以循环级健康表征特征作为模型输入。对第t个循环提取3个健康表征特征，记为$\boldsymbol{f}_t\in\mathbf{R}^3$。本文采用单步输入形式，单个输入样本表示为

$$\boldsymbol{x}_t=\boldsymbol{f}_t\in\mathbf{R}^{1\times3}$$

为统一描述同循环与未来循环容量预测，引入预测步长$H\geqslant0$，对应标签定义为

$$y_t=C_{t+H}$$

其中，C_{t+H}为$t+H$个循环的容量。当$H=0$时，模型预测当前循环容量；当$H>0$时，模型预测未来第H个的循环容量。为保证标签可获得性，样本索引t的取值范围满足$t+H$不超过循环总数，末端不足H的循环样本不参与训练与评估。本文实现中，模型输入层尺寸为(None,1,3)，其中，None为批量维，1为时间步长，3为特征维度。模型输出为单一标量$\hat{y}\in\mathbf{R}$，即预测容量$\hat{C}_{t+H}$。

模型整体框架如图1所示。输入特征首先经过CNN模块提取局部退化表征，随后输入GRU模块以建模退化过程中的时序依赖关系；在此基础上，引入自注意力机制对隐藏特征进行自适应加权，以突出对容量预测更为关键的退化信息；最后通过全连接层输出预测结果。该模型形成了“局部特征提取—时序依赖建模—关键信息增强—回归输出”的端到端预测流程。模型结构由三层核心子模块构成。

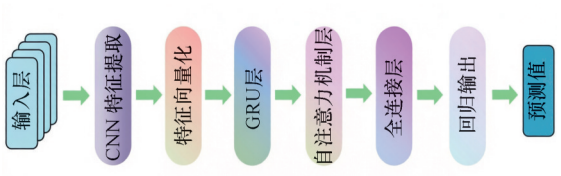

图1 模型整体框架

Fig.1 Overall framework of the proposed model

1)CNN层。CNN层用于提取输入特征中的局部变化模式，增强退化表征能力。对于循环级健康特征序列，卷积操作能够挖掘相邻特征之间与容量演化相关的局部关联信息，为后续时序建模提供有效特征基础。卷积操作定义如下：

$$Z^{(l)}=\sigma(\boldsymbol{W}^{(l)}*\boldsymbol{X}^{(l-1)}+b^{(l)})$$

式中：$\boldsymbol{X}^{(l-1)}$为上一层输出；$\boldsymbol{W}^{(l)}$为卷积核；$b^{(l)}$为偏置项；σ为激活函数。

2)GRU层。GRU层用于刻画特征序列中的时序依赖关系，增强对退化演化趋势的建模能力。通过门控机制，模型能够保留与寿命变化相关的有效信息，并减弱无关波动对预测结果的干扰。GRU的计算过程如下：

$$z_t=\sigma(\boldsymbol{W}_z\cdot[h_{t-1}\quad x_t])$$
$$r_t=\sigma(\boldsymbol{W}_r\cdot[h_{t-1}\quad x_t])$$
$$\tilde{h}_t=\tanh(\boldsymbol{W}_h\cdot[r_t*h_{t-1}\quad x_t])$$
$$h_t=(1-z_t)*h_{t-1}+z_t*\tilde{h}_t$$

式中：W_z、W_r、W_h分别为更新门、重置门及候选隐藏状态的权重矩阵；z_t、r_t分别为更新门和重置门；$\tilde{h}_t$为候选隐藏状态；h_t为当前隐藏状态。

3)SA层。为了提高模型对关键退化阶段的识别能力，在GRU输出后引入SA。该机制可根据时序特征间的依赖关系自动分配注意力权重，从而强化对重要时间片段的特征表达，抑制冗余信息的干扰。注意力权重计算公式如下：

$$A(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})=Softmax(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_k}})\boldsymbol{V}$$

式中：$Softmax$表示归一化指数函数；$\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$分别为查询矩阵、键矩阵、值矩阵；d_k为维度缩放因子。

该模型结构通过多维特征融合与优化，兼顾局部短时特征、长期退化趋势与关键信息关注能力，能够有效提高RUL预测的精度与稳定性。

1.3 模型参数优化方法

深度神经网络的预测性能在较大程度上依赖于超参数设置，如卷积核尺寸、GRU单元数、学习率和批量大小等。传统人工设定或网格搜索方法效率较低，且在样本差异大、模型复杂度高的场景下难以保证参数选择的稳定性。为此，本文引入具有较强全局搜索能力的WOA，对CNN-GRU-SA模型关键超参数进行自动寻优，以提高模型训练效率和预测性能。

WOA通过模拟座头鲸在围捕猎物过程中的“螺旋攻击”和“包围行为”完成搜索与更新，主要包括以下三种操作。

1)包围猎物。鲸鱼个体更新位置向当前全局最优解靠近：

$$\boldsymbol{X}(t+1)=\boldsymbol{X}^*(t)-\boldsymbol{A}\cdot\boldsymbol{D}$$

$$D=\left|C\cdot X^{*}(t)-X((t)\right|$$

式中：$X^{*}(t)$为当前最优解；A、C为系数向量，随迭代次数调整。

2）螺旋攻击行为。模拟鲸鱼围绕猎物螺旋前进的行为：

$$X(t+1)=D'\mathrm{e}^{bl}\cos(2\pi l)+X^{*}(t)$$

$$D'=|X^{*}(t)-X(t)|$$

式中：b、l为常数控制螺旋曲率。

3）随机搜索行为。以一定概率跳出局部最优区域，增强全局探索能力。

WOA的整体优化流程如图2所示。算法在每次迭代中依据随机数P以及$|A|$的判别在收缩包围、随机搜索与螺旋更新三种机制间切换，并更新全局最优解θ^{*}。迭代终止后输出最优解θ^{*}及其对应适应度$F(\theta^{*})$。

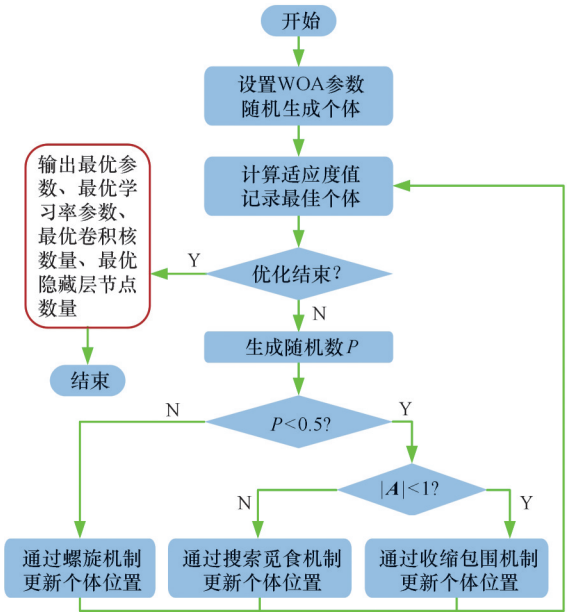

图2　WOA优化流程图

Fig.2　WOA optimization flowchart

为减少人工调参带来的不确定性，本文采用WOA对CNN-GRU-SA模型的关键超参数进行全局寻优。将待优化超参数定义为三维向量：

$$\theta=(\eta,H,\lambda)$$

其中，η为学习率；H为GRU隐藏层单元数；λ为L2正则化系数。其余网络结构与训练超参数均实验设置固定不变，仅对η、H、λ进行WOA寻优。

对于整数型H变量，在WOA位置更新后采用取整映射得到实际网络节点数。对任一候选超参数组合θ，通过适应度函数$F(\theta)$（定义为验证集上的均方误差（MSE））评估其预测误差，并以最小化$F(\theta)$为优化目标。算法迭代过程中记录每代全局最优适应度并绘制收敛曲线，见图3。

结合模型结构特点与训练过程中的关键敏感参数，本文设置WOA种群规模为8，最大迭代次数为5，优化维度为3。选取η、H、λ作为WOA优化对象，并分别设定对应搜索范围，如表1所示。

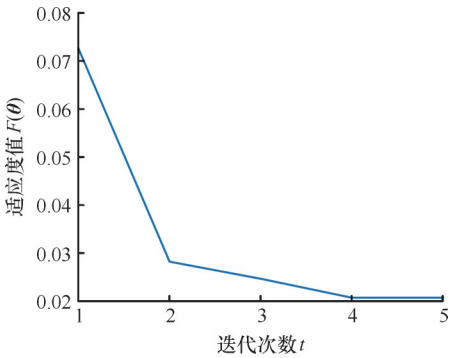

图3　WOA收敛曲线

Fig. 3　WOA convergence curve

表1　WOA优化的关键超参数与搜索范围

Tab.1　Key hyperparameters optimized by WOA and their search ranges

优化变量	类型	搜索范围
学习率η	连续	[0.001,0.01]
GRU隐藏层单元数H	整数	[50,100]
L2正则化系数λ	连续	[0.0001,0.1]

2　实验数据与特征构建

2.1　实验数据来源

本文选取的数据来自美国马里兰大学可靠性工程中心（CALCE）公开发布的锂离子电池全寿命循环数据集[22]，包括CS2-35、CS2-36、CS2-37和CS2-38四组电池样本。该数据集在恒流-恒压充电（CC-CV）与恒流放电（CC）模式下采集，涵盖不同倍率（0.5C、1C等，C为电池容量）及不同温度（室温、高温、低温）条件下的全生命周期性能衰退过程。为保证数据与储能系统应用场景的匹配性，本文仅选取了在室温（25 ℃）及0.5C充电/1C放电条件下运行的电池样本，以模拟储能系统中退役动力电池的典型工作工况。此外，为提高训练数据的稳定性与可比性，仅保留了数据记录完整且无异常波动的4节电池的循环数据。原始数据中包含充放电过程中电压、电流、容量、内阻、时间等多维度测量值，可全面反映电池在整个寿命周期内的电化学性能演变。图4是不同电池的容量衰退曲线，可直观观察其在全寿命过程中的衰减趋势与速率差异。

为避免“泛化性”表述产生歧义，本文将其限定为：在CALCE公共数据集所覆盖的电池体系与测试协议/工况范围内，模型对未参与训练的样本（或未见循环片段）仍能保持稳定预测误差的能力，并通过测试集误差指标进行评价。需要说明

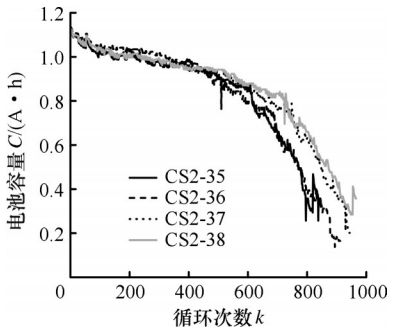

图4 容量随循环次数变化轨迹

Fig.4 Capacity variation trajectory with cycle number

的是，跨温度、倍率、化学体系或电池型号等更强的域外迁移不在本文讨论范围内。

此外，本文采集的少量退役动力电池数据由于样本规模有限，暂不足以支撑严格的训练-测试划分与统计性对比，因此仅用于对特征提取流程与预测输出趋势进行一致性检查和工程可行性说明，不作为泛化能力结论依据。

2.2 特征提取

为了准确刻画锂离子电池在运行过程中的性能退化特征，并为模型提供有效的输入变量，本文基于原始实验数据提取了能够从多个维度反映健康状态演化规律的关键特征，包括内阻、恒流充电时间(CCCT)、恒压充电时间(CVCT)和放电容量。内阻用于表征电池内部离子迁移与电子传导阻力的变化，其增大往往伴随能量损失和发热效应的加剧，是反映老化过程的重要参数；恒流充电时间代表在恒定电流阶段将电池充至设定电压所需的时间，受活性材料可逆容量和极化效应影响，随着衰老过程通常缩短；恒压充电时间则是在恒定电压阶段电流衰减至截止值所需的时间，与极化特性和容量保持率密切相关；放电容量反映了电池在单次循环中可释放的有效电量，是衡量能量输出能力的核心指标，随着循环次数的增加呈逐渐衰减趋势。在特征处理阶段，首先对原始采集数据进行异常值剔除和缺失值插补，以消除测试误差与偶发波动的影响；随后对各特征进行归一化处理，将数值映射至[0,1]区间，消除不同量纲对模型训练干扰；最后，采用循环级样本构建方式将每个循环的健康表征特征组织为模型输入，结合统一的数据归一化与训练策略，实现对容量退化演化的回归建模。图5为CS2-35电池样本中内阻、恒流充电时间、恒压充电时间随循环次数的变化曲线，可以清晰地观察到各特征在全寿命周期内的演化规律及其与容量衰退趋势的相关性。

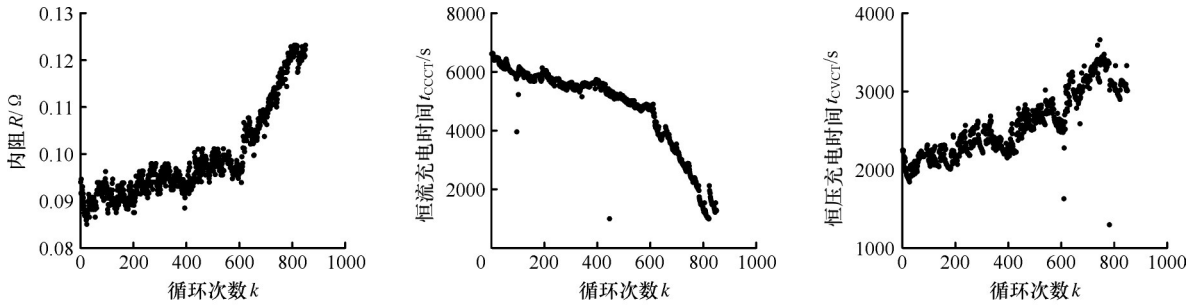

图5 内阻、CCCT、CVCT随循环次数的变化关系

Fig.5 Relationship between cycle number and internal resistance, CCCT, CVCT

2.3 退化表征指标与RUL推断方法

退役动力电池的性能衰退通常表现为容量随循环次数持续下降，因此本文以容量及其归一化形式的健康状态作为退化表征指标，刻画全寿命周期内的退化演化过程。设第k次循环的放电容量为C_k，初始容量为C_0，则健康状态S^{H}定义为

$$S_k^{\mathrm{H}}=C_k/C_0$$

在此基础上，本文根据第2.2节提取的多维特征时间序列样本，建立数据驱动的退化建模框架，对退化表征指标随循环演化的趋势进行估计，从而获得未来退化轨迹。该过程的核心目标是对退化状态与时间的关系进行显式刻画，使得后续寿命推断能够建立在可解释的退化演化基础之上，而非仅停留在对时间序列的定性描述。

为将退化轨迹进一步转化为RUL，本文采用工程领域常用的寿命终止准则(EOL)：当容量衰减至初始容量的80%时认为电池达到寿命终止状态，即

$$S_{\mathrm{EOL}}^{\mathrm{H}}=0.8$$

当获得预测退化轨迹$\{S_t^{\mathrm{H}}\}$后，寿命终止循环数定义为首次达到阈值的循环：

$$k_{\mathrm{EOL}}=\min(t\geqslant k\,|\,S_t^{\mathrm{H}}\leqslant 0.8)$$

从而在循环k时刻得到预测剩余寿命(以循环次数计)：

$$R_k=k_{\mathrm{EOL}}-k$$

同理，可由实测容量序列得到真实k_{EOL}与R_k，用于寿命层面的误差评估。由此，本文形成了退化轨迹建模-阈值-推断寿命的完整闭环，使退化

建模方法在文中得到显式体现并具备可复现性。

3　实验验证与评估

为验证所提出的模型对储能领域退役电池RUL的评估准确性及适用性，利用CALCE数据集的电池健康退化数据来训练模型。将结果与WOA-CNN-GRU、CNN-GRU、WOA-CNN-LSTM-SA、WOA-CNN-LSTM（长短时记忆网络）和CNN-LSTM模型的结果进行比较。使用的硬件和软件配置如下：AMD 7500f、32GB内存、NVIDIA GeForce GTX 4060Ti和MATLAB 2023b。

3.1　数据划分

本文采用跨电池训练-目标电池验证/测试的数据划分策略，具体如表3所示。选取CS35、CS36、CS38的全寿命循环数据构成训练集，仅用于模型参数（网络权重）的学习与更新；CS37作为独立目标电池，不参与权重更新，并按循环序列的时间顺序划分为验证集与测试集，前80%循环作为验证集，用于WOA超参数寻优与早停策略和模型选择，后20%循环作为测试集，用于最终性能评估与结果汇报。

表3　数据集划分

Tab.3　Dataset split

阶段	数据来源	划分规则	循环数	窗口参数（L，s）	样本数
训练	CS35+CS36+CS38	全寿命循环	2728	（1，1）	2728
验证	CS37	前80%循环（按时间顺序）	755	（1，1）	755
测试	CS37	后20%循环（按时间顺序）	189	（1，1）	189

3.2　评价指标

本文采用平均绝对误差（MAE）、均方根误差（RMSE）和决定系数R^2三类典型的回归评价指标来评估所提出模型的性能，并结合RUL推理结果计算绝对误差（AE）和相对误差（RE），以反映模型在健康状态拟合精度、寿命估算准确性以及泛化能力等方面的综合性能。

1）平均绝对误差e_{MAE}。MAE是衡量模型预测值与实际值之间误差的平均绝对值，MAE值越小表示预测越精确，定义如下：

$$e_{\mathrm{MA}}=\frac{1}{n}\sum_{i=1}^{n}\left|\hat{y}_i-y_i\right|$$

式中：$\hat{y}_i$为第i个预测值；y_i为真实值；n为样本总数。

2）均方根误差e_{RMS}。RMSE是误差平方的均值开根号，对异常值更为敏感，反映了预测误差的稳定性，越小说明模型波动性越低，定义如下：

$$e_{\mathrm{RMS}}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i-y_i)^2}$$

3）决定系数R^2。R^2表征模型预测值与实际值之间的拟合程度，R^2越接近于1，表明预测结果越接近真实值，拟合效果越好，定义如下：

$$R^2=1-\sum_{i=1}^{n}(y_i-\hat{y}_i)^2/\sum_{i=1}^{n}(y_i-\bar{y})^2$$

式中：$\bar{y}$为真实值的平均数。

3.3　基线模型与参数设置

为保证基线模型对比的公平性，本文所有对比模型均采用一致的数据预处理与归一化方法、相同的训练/测试划分策略，以及相同的输入特征与滑动窗口设置。在网络结构方面，各基线模型与本文方法共享相同的CNN特征提取模块（卷积层数与通道数保持一致），仅在循环单元类型（GRU/LSTM）、是否引入自注意力机制以及是否采用WOA进行超参数寻优等方面进行控制变量对比，具体设置如表4所示。除表中列出的差异外，其余实现细节（如卷积核尺寸、步长、padding、激活函数及归一化层设置等）各模型保持一致；同时各模型采用一致的训练策略（如优化器、训练轮次与学习率调整策略等），以避免非目标因素对结果造成干扰。对于采用WOA的模型，其隐藏单元数等关键超参数由WOA在候选范围内以验证性能最优（MAE最小）为准则搜索确定，记为h^*；对于未采用WOA的基线模型，超参数通过常规调参策略在相同候选范围内确定，记为h_0，从而减少调参力度差异导致的对比偏差。

表4　基线模型参数设置

Tab.4　Baseline model parameter settings

模型	输入（$L\times F$）	CNN配置（filters/层数）	RNN（类型/层数/单元）	Attention	Dropout	输出
WOA-CNN-GRU-SA	1×3	16→32（2层）	GRU/2层/h^*	Self-Attention×2	0.01	1
WOA-CNN-LSTM-SA	1×3	16→32（2层）	LSTM/2层/h^*	Self-Attention×2	0.01	1
WOA-CNN-GRU	1×3	16→32（2层）	GRU/2层/h^*	无	0.01	1
WOA-CNN-LSTM	1×3	16→32（2层）	LSTM/2层/h^*	无	0.01	1
CNN-GRU	1×3	16→32（2层）	GRU/2层/h_0	无	0.01	1
CNN-LSTM	1×3	16→32（2层）	LSTM/2层/h_0	无	0.01	1

3.4 实验验证

本实验中，神经网络的具体结构如表5所示。WOA-CNN-GRU-SA、WOA-CNN-LSTM-SA、WOA-CNN-GRU、WOA-CNN-LSTM、CNN-GRU和CNN-LSTM模型的预测曲线和电池的真实曲线如图6所示。由图6可以直观地看出，各模型在初期阶段的拟合效果普遍较好，能够准确反映电池容量的缓慢衰减过程。然而，随着循环次数的增加，即进入中后期退化阶段，模型间的预测性能差异逐渐显现。WOA-CNN-GRU-SA模型的预测曲线与真实曲线高度吻合，在整体趋势、拐点捕捉及退化速率变化等方面均表现出优异的拟合能力，说明该模型能够有效提取时序特征与关键衰退信息。相较之下，WOA-CNN-LSTM-SA模型表现次之，它在后期预测中略有偏差，但总体趋势仍保持一致。未引入WOA优化与注意力机制的模型，如CNN-GRU和CNN-LSTM，在后期阶段的预测误差明显增大，尤其在衰减速度加快时，难以准确捕捉容量的下降趋势，存在一定程度的滞后或波动。此外，从整体误差分布来看，引入WOA的模型预测曲线更加平滑，能够更好地抑制预测过程中的剧烈波动，表明WOA优化在提高模型稳定性方面具有积极作用。

表5 神经网络的具体结构

Tab.5 Detailed neural network architecture

Layer	Activation function	Output data shape
Input	N/A	None,1,3
CNN1(Convolutional 2D)	Relu	None,1,16
CNN2(Convolutional 2D)	Relu	None,1,32
Pooling Layer	N/A	None,1,32
Flatten Layer	N/A	None,32
GRU Layer 1	Tanh	None,1,50
Self-Attention Layer 1	N/A	None,1,50
Fully Connected Layer 1	N/A	None,1,1
Dropout Layer	N/A	None,1,1
GRU Layer 2	Tanh	None,50
Self-Attention Layer 2	N/A	None,50
Fully Connected Layer 2	N/A	None,1
Output	N/A	None,1

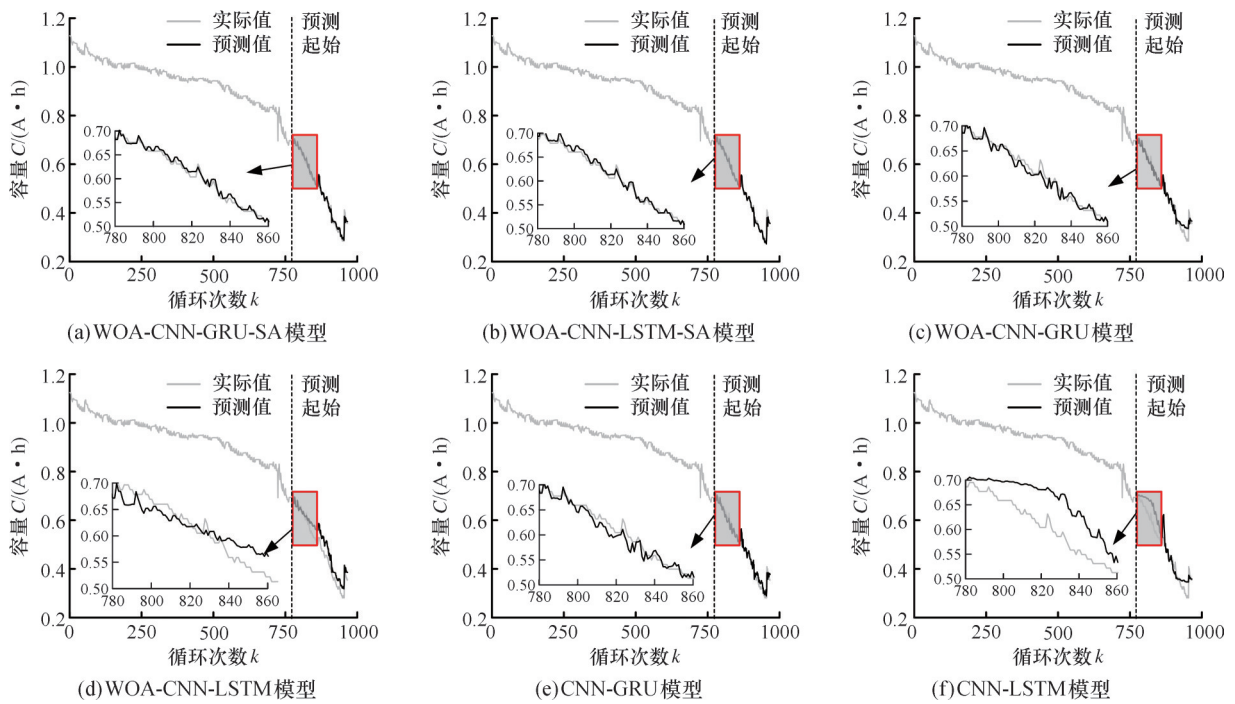

图6 不同模型预测曲线和电池的真实值曲线

Fig.6 Prediction curves of different models and the real value curve of the battery

预测结果如表6所示。为降低随机初始化与训练过程带来的偶然性影响，本文在保持数据划分与训练配置一致的条件下，采用不同随机种子进行重复实验，并以均值±标准差的形式汇报RMSE、MSE、MAE与R^2指标。综合对比可知，WOA-CNN-GRU-SA在4项指标上均取得最优的平均性能，同时其标准差整体较小，说明该模型在多次重复训练下表现更稳定、鲁棒性更强。相比之下，未引入WOA寻优或注意力机制的模型（如CNN-GRU、CNN-LSTM）在误差均值与波动幅度方面均存在明显劣势，表明对关键超参数进行全局寻优并引入注意力机制有助于提高模型的预测精度与训练稳定性。

为验证上述性能提高并非由随机种子带来的偶然波动导致，本文以3次重复实验结果为样本，对WOA-CNN-GRU-SA与WOA-CNN-LSTM-

表6　各算法的预测结果

Tab.2　Prediction results of each algorithm

模型	RMSE/%	MSE/%	MAE/%	R^2/%
WOA-CNN-GRU-SA	0.809 27±0.006 48	0.006 549 4±0.000 105 0	0.554 40±0.005 94	99.840±0.007
WOA-CNN-LSTM-SA	0.902 70±0.007 90	0.008 149 1±0.000 142 7	0.640 10±0.007 25	99.802±0.010
WOA-CNN-GRU	1.388 73±0.012 81	0.019 286 9±0.000 355 8	0.878 83±0.010 41	99.532±0.016
WOA-CNN-LSTM	2.138 90±0.019 04	0.045 751 3±0.000 813 8	1.530 23±0.024 38	98.880±0.040
CNN-GRU	1.472 20±0.014 36	0.021 675 1±0.000 423 1	1.080 57±0.014 36	99.472±0.021
CNN-LSTM	2.764 80±0.028 75	0.076 446 7±0.001 588 4	2.014 53±0.029 21	98.148±0.066

SA(次优模型)在各评价指标上的差异进行Welch'st检验(双侧检验,显著性水平α=0.05)。检验结果表明,本文方法在RMSE、MSE与MAE指标上均显著优于次优模型(显著性概率$P=1.19\times10^{-4}$, 1.70×10^{-4}, 1.20×10^{-4}),且R^2亦显著更高($P=7.80\times10^{-3}$)。因此,可认为WOA-CNN-GRU-SA的性能优势具有统计显著性,进一步验证了模型结果的鲁棒性。

为检验模型是否存在过拟合,本文给出训练集、验证集与测试集上的性能对比结果(表7)。由表7可见,训练集、验证集与测试集的误差指标差距较小,R^2保持在较高水平,说明模型在未见数据上的预测精度与训练阶段一致,未出现训练误差显著低于验证/测试误差的现象,表明模型无明显过拟合风险,在未见数据上仍能保持稳定预测性能。

表7　训练集、验证集与测试集上的预测性能对比

Tab.7　Comparison of prediction performance on the training, validation, and test sets

数据集	RMSE/%	MSE/%	MAE/%	R^2/%
训练集	0.792 30	0.006 277 4	0.543 10	99.852
验证集	0.807 90	0.006 527 0	0.552 80	99.842
测试集	0.809 27	0.006 549 4	0.554 40	99.840

3.5　自建实验平台与验证方案设计

为验证所提出剩余寿命预测方法在真实退役动力电池场景中的适用性,在实验室搭建了由电池充放电测试仪与电池均衡仪组成的测试平台,如图7所示。图8~图10展示了自建实验平台与被测对象的关键硬件与样品组成。图8中的锂电池充放电测试仪用于在CC-CV充电与恒流放电工况下执行循环测试,并实时采集电压、电流等基础数据;锂电均衡维护测试仪用于在充放电过程中平衡模组内各单体电芯的电压差,避免因一致性差异引发的过充或过放现象,从而确保测试过程的安全性与准确性。图9为三元锂离子动力电池总成系统,来源于宁德时代生产的三元锂离子动力电池模组,标称电压365V,额定容量150 A·h,由10个四电芯模组与10个六电芯模组组

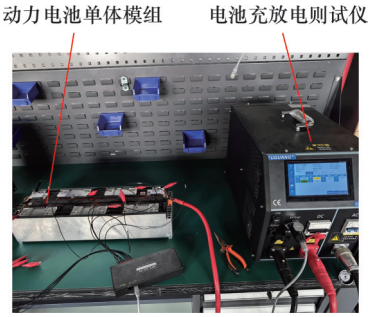

图7　电池充放电测试平台

Fig.7　Battery charge and discharge testing platform



(a)锂电池充放电测试仪　(b)锂电均衡维护测试仪

图8　锂电池充放电测试仪和锂电均衡维护测试仪

Fig.8　Lithium-ion battery charge-discharge tester and lithium battery balancing and maintenance tester

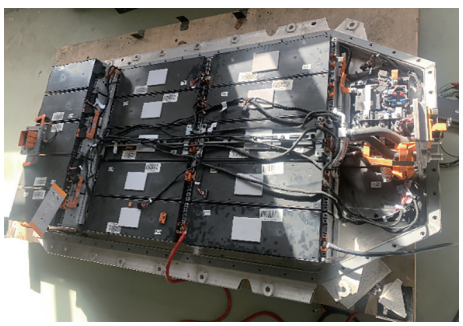

图9　三元锂离子动力电池总成系统

Fig.9　Ternary lithium-ion power battery pack system

成;图10为该总成系统拆分得到的单体模组,为本文实验测试与数据采集的直接对象。

实验流程分为4个阶段:①在恒流恒压模式下进行充电,初始组端电压为19.1 V,6个单体电芯电压约为3.2 V,充电电流由0升至45 A并保持恒定,随着充电的进行,组端电压逐渐升至25.1 V,单体电芯电压升至约4.2 V,进入恒压阶段直至充电结束;②充电完成后模组静置20 min以消

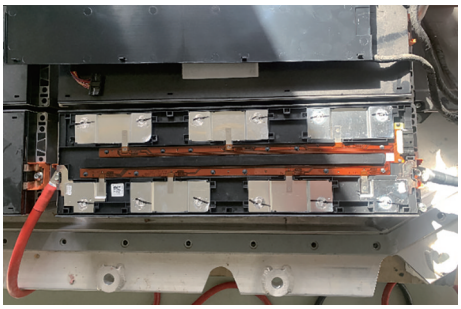

图10　三元锂离子动力电池总成系统单体模组

Fig.10　Single module of the ternary lithium-ion power battery pack system

除极化效应和电化学反应的瞬态影响；③随后在恒流模式下进行放电，初始组端电压为24.9 V，单体电芯电压约为4.2 V，放电电流由0升至75 A并保持恒定，直至组端电压降至18.4 V，单体电芯电压降至约3.0 V；④放电结束后模组再次静置20 min，完成一个完整的充放电循环。

在整个充放电循环过程中，测试平台实时采集了模组及单体电芯的电压、电流等参数。这些数据将用于后续的模型适用性验证，以评估所提出预测方法在真实退役动力电池健康状态预测中的泛化能力与可行性。

为进一步检验所提出方法在真实工程样本上的适用性，本文采用公共数据预训练与自建数据小样本校准相结合的验证思路。首先，利用公共数据集训练得到的基模型作为初始化参数。随后，将自建退役电池数据按循环序列进行时间顺序划分，前40%的循环样本用于对模型进行微调，使模型在保持整体结构不变的前提下更好地适配该退役电池的退化特性与实验工况。微调阶段采用参数冻结与逐步解冻相结合的策略：优先冻结卷积特征提取层及其后续的低层表示模块，仅更新时序建模与输出回归相关的层参数，以在小样本条件下降低参数漂移与过拟合风险；在验证集误差趋于稳定后，可进一步解冻部分高层特征表示模块并采用更小的学习率进行少量轮次的细化更新，以提高对目标电池退化模式的适配能力。微调过程中保持输入特征构造方式和归一化方法与预训练阶段一致，优化器和损失函数设置与主实验一致，并通过隔离验证集监控误差变化，采用早停策略确定微调轮次。接着，将后续10%的样本设置为隔离验证集，用于监控微调过程中的误差变化并选择合适的训练轮次，以降低过拟合风险。最后，将剩余50%的样本作为预测测试集，仅用于输出预测结果与性能评估，确保测试阶段不参与参数更新，从而避免信息泄露。基于上述划分得到的预测对比结果如图11所示，相应的定量评价指标如下：RMSE值为0.6378%，MSE值为0.004 068%，MAE值为0.4851%，R^2值为89.69%。总体而言，模型在自建退役电池样本上的预测曲线能够在趋势上与实测结果保持一致，并在一定程度上反映退化过程的变化特征，为后续关于模型迁移表现与工程可用性的分析提供实验依据。

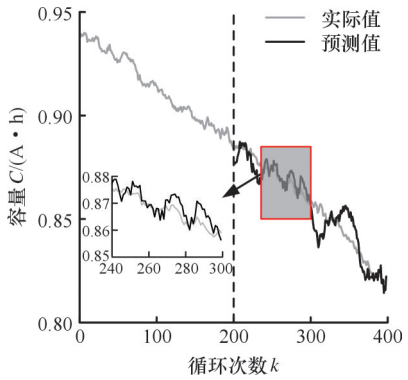

图11　预测结果图

Fig.11　Prediction results plot

为验证模型在真实退役动力电池场景下的工程适用性，本文选取一组实测退役电池数据进行RUL推断，并在不同循环起点处进行多点预测对比（起点分别为213、246和314）。如表8所示，模型在3个起点处输出的预测RUL分别为225、210和124，与对应真实RUL接近；其AE值分别为22、3和0个循环，RE值最大为0.0145。同时，MAPE保持在0.0058～0.0065之间，RMSE为0.0065～0.0070，表明模型在真实退役电池数据上的RUL预测具有较高精度与稳定性。此外，3组起点下的预测误差均保持在较低水平，且未出现随起点变化而显著放大的趋势，说明模型在真实退役电池数据上的RUL推断具有一定鲁棒性与工程可迁移性。

表8　不同起点下的RUL预测结果及误差指标

Tab.8　RUL prediction results and error metrics under different starting points

起点	真实RUL	预测RUL	AE	RE	MAPE	RMSE
213	247	225	22	0.0145	0.0058	0.0065
246	207	210	3	0.0145	0.0060	0.0067
314	124	124	0	0	0.0065	0.0070

4　结论

1）所提出的WOA-CNN-GRU-SA模型充分发挥了各子模块的优势：CNN有效提取电池运行数据中的局部时序特征，GRU适用于捕捉长序列中的衰退模式，SA增强了模型对关键时刻特征的

感知能力，而WOA则在模型训练阶段优化了超参数配置。整体模型在多个评价指标上均优于传统深度学习模型，展现出较强的预测性能与稳定性。

2）准确评估退役电池的RUL对其在储能场景下的应用具有重要意义。通过本模型对电池未来寿命趋势的合理预测，能够实现电池分级管理和智能调度，显著降低因盲目部署导致的储能系统风险与成本。该方法有助于筛选出符合性能要求的退役电池资源，提高储能系统整体的安全性和经济性。

3）本文提出的预测方法为退役电池梯次利用提供了数据驱动的技术路径，为构建绿色、智能、高效的电池回收利用体系奠定了基础。相比于依赖人工检测或电化学建模的方法，该模型具备自动化程度高、适应性强、部署灵活等优势，可推广至实际工程中的在线评估系统，对促进电池全生命周期管理、减缓资源浪费具有积极意义。

参考文献：

[1] LI J, HE S, YANG Q, et al. A Comprehensive Review of Second Life Batteries Toward Sustainable Mechanisms: Potential, Challenges, and Future Prospects [J]. IEEE Transactions on Transportation Electrification, 2023, 9(4): 4824-4845.

[2] CHEN Y, SHI P, CHANG D, et al. Selective Extraction of Valuable Metals from Spent EV Power Batteries Using Sulfation Roasting and Two Stage Leaching Process [J]. Separation and Purification Technology, 2021, 258: 118078.

[3] CONTESTABILE M, PANERO S, SCROSATI B. A Laboratory-scale Lithium-ion Battery Recycling Process [J]. Journal of Power Sources, 2001, 92(1/2): 65-69.

[4] HARPER G, SOMMERVILLE R, KENDRICK E, et al. Recycling Lithium-ion Batteries from Electric Vehicles[J]. Nature, 2019, 575(7781): 75-86.

[5] ZHENG X, ZHU Z, LIN X, et al. A Mini-review on Metal Recycling from Spent Lithium Ion Batteries[J]. Engineering, 2018, 4(3): 361-370.

[6] IQBAL H, SARWAR S, KIRLI D, et al. A Survey of Second-life Batteries Based on Techno-economic Perspective and Applications-based Analysis[J]. Carbon Neutrality, 2023, 2(1): 8.

[7] NIE Y, WANG Y, LI L, et al. Literature Review on Power Battery Echelon Reuse and Recycling from a Circular Economy Perspective[J]. International Journal of Environmental Research and Public Health, 2023, 20(5): 4346.

[8] MARTINEZ-LASERNA E, GANDIAGA I, SARASKETA- ZABALA E, et al. Battery Second Life: Hype, Hope or Reality? a Critical Review of the State of the Art[J]. Renewable and Sustainable Energy Reviews, 2018, 93: 701-718.

[9] LIU Z, LIU X, HAO H, et al. Research on the Critical Issues for Power Battery Reusing of New Energy Vehicles in China[J]. Energies, 2020, 13(8): 1932.

[10] LIU Z, ZHOU T, YANG H, et al. A Review of the Resourceful Utilization Status for Decommissioned Power Batteries[J]. Energies, 2023, 16(23): 7869.

[11] GE M, LIU Y, JIANG X, et al. A Review on State of Health Estimations and Remaining Useful Life Prognostics of Lithium-ion Batteries [J]. Measurement, 2021, 174: 109057.

[12] FAN G. Systematic Parameter Identification of a Control-oriented Electrochemical Battery Model and Its Application for State of Charge Estimation at Various Operating Conditions[J]. Journal of Power Sources, 2020, 470: 228153.

[13] BRUCH M, MILLET L, KOWAL J, et al. Novel Method for the Parameterization of a Reliable Equivalent Circuit Model for the Precise Simulation of a Battery Cell's Electric Behavior [J]. Journal of Power Sources, 2021, 490: 229513.

[14] HAN X, WANG Z, WEI Z. A Novel Approach for Health Management Online-monitoring of Lithium-ion Batteries Based on Model-data Fusion [J]. Applied Energy, 2021, 302: 117511.

[15] RICHARDSON R R, OSBORNE M A, HOWEY D A. Gaussian Process Regression for Forecasting Battery State of Health[J]. Journal of Power Sources, 2017, 357: 209-219.

[16] ZHOU D, YIN H, FU P, et al. Prognostics for State of Health of Lithium-ion Batteries Based on Gaussian Process Regression [J]. Mathematical Problems in Engineering, 2018, 2018(1): 8358025.

[17] ALI M U, ZAFAR A, MASOOD H, et al. A Hybrid Data-driven Approach for Multistep Ahead Prediction of State of Health and Remaining Useful Life of Lithium-ion Batteries [J]. Computational Intelligence and Neuroscience, 2022, 2022(1): 1575303.

[18] ZHANG M, YIN J, CHEN W. SOH Estimation and RUL Prediction of Lithium Batteries Based on Multidomain Feature Fusion and CatBoost Model[J]. Energy Science & Engineering, 2023, 11(9): 3082-3101.

[19] WU C, FU J, HUANG X, et al. Lithium-ion Battery Health State Prediction Based on VMD and DBO-SVR [J]. Energies, 2023, 16(10): 3993.

[20] WANG K, GAO Q, PANG X, et al. Estimating the Health State of Lithium-ion Batteries Using an Adaptive Gated Sequence Network and Hierarchical Feature Construction[J]. Batteries, 2024, 10(8): 278.

[21] SALEK F, RESALATI S, AZIZI A, et al. State of Health Prediction of Electric Vehicles' Retired Batteries Based on First-life Historical Degradation Data Using Predictive Time-series Algorithms[J]. Mathematics, 2024, 12(7): 1051.

[22] HE W, WILLIARD N, OSTERMAN M, et al. Prognostics of Lithium-ion Batteries Based on Dempste-shafer Theory and the Bayesian Monte Carlo Method[J]. Journal of Power Sources, 2011, 196(23): 10314-10321.

（编辑　袁兴玲）

作者简介：马　峰*（通信作者），男，1989年生，副教授、博士研究生导师。研究方向为绿色低碳制造、资源高值化利用。E-mail：MF0425@163.com。

本文引用格式：

马峰，王海磊，黄顺虎，等. 考虑储能工况的退役动力电池退化建模与剩余寿命预测[J]. 中国机械工程，2026，37(10)：2492-2501.

MA Feng, WANG Hailei, HUANG Shunhu, et al. Degradation Modeling and Remaining Useful Life Prediction of Retired Power Batteries Considering Energy Storage Conditions[J]. China Mechanical Engineering, 2026, 37(10): 2492-2501.