储能XXXX

基于健康特征增强与TCN-ASSA的锂离子电池RUL预测

王馨璐[1]，高治军[2]，郭喜峰[2]，宁　一[2]，刘毅杨[2]
（[1]沈阳建筑大学机械工程学院，辽宁 沈阳 110168；[2]沈阳建筑大学电气与控制工程学院，辽宁 沈阳 110168）

摘　要：针对锂离子电池在循环老化过程中存在容量再生、局部波动及噪声干扰等问题，导致剩余使用寿命（Remaining Useful Life，RUL）预测精度下降，本文提出一种基于健康特征增强与时间卷积网络（Temporal Convolutional Network，TCN）-自适应稀疏自注意力（Adaptive Sparse Self-Attention，ASSA）的锂离子电池RUL预测方法。首先，基于充电阶段增量容量曲线，采用萨维茨基-戈莱滤波对原始曲线进行平滑增强，并提取峰值、峰值对应电压及特定电压区间包络面积等特征；同时结合等间隔充电时间和循环次数，构建多维健康特征集合，以提升对电池退化状态的表征能力。其次，构建融合TCN-ASSA的预测模型，利用TCN捕捉容量退化过程中的长期时序依赖关系，借助ASSA突出关键退化信息、抑制无关扰动和异常波动影响，从而提高RUL预测精度与模型鲁棒性。最后，基于Oxford和NASA锂离子电池数据集进行实验验证。在Oxford数据集上，TCN-ASSA的均方根误差（Root Mean Square Error，RMSE）为2.2726，平均绝对百分比误差(Mean Absolute Percentage Error，MAPE)为0.3634。NASA数据集的RMSE低至0.00734，MAPE低至0.00486。所提方法在消融实验、对比实验和跨数据集泛化实验中均取得了较优表现。表明该方法能够更准确地跟踪电池容量衰退趋势，具有较好的预测精度、鲁棒性和跨数据集适应性，可为锂离子电池健康管理与安全预警提供有效支持。

关键词：锂离子电池；剩余使用寿命；机器学习；时间卷积网络；自适应稀疏自注意力；特征增强
doi：10.19799/j.cnki.2095-4239.2026.0345
中图分类号：TM 912　　文献标志码：A　　文章编号：2095-4239（XXXX）XX-1-13

LITHIUM-ION BATTERY RUL PREDICTION BASED ON HEALTH FEATURE ENHANCEMENT AND TCN-ASSA

Wang Xinlu[1], Gao Zhijun[2], Guo Xifeng[2], Ning Yi[2], Liu YiYang[2]
([1]School of Mechanical Engineering, Shenyang Jianzhu University, Shenyang 110168, Liaoning, China; [2]School of Electrical and Control Engineering, Shenyang Jianzhu University, Shenyang 110168, Liaoning, China)

Abstract: To address the decline in prediction accuracy of the remaining useful life (RUL) of lithium-ion batteries caused by capacity regeneration, local fluctuations, and noise interference during cyclic aging, this paper proposes a lithium-ion battery RUL prediction method based on health feature enhancement and Temporal Convolutional Network (TCN)-Adaptive Sparse Self-Attention (ASSA) framework. First, based on the incremental capacity curve during the charging process, Savitzky-Golay filtering is employed to smooth and

收稿日期：2026-04-21；修改稿日期：2026-05-28。
基金项目：国家自然科学基金（62273243），辽宁省基础研究项目（2025JH2/10130048）。
第一作者：王馨璐（1998—），女，博士研究生，研究方向为锂离子电池建模，E-mail：wangixnlu012@163.com；通信作者：高治军，教授，博士生导师，研究方向为建筑能源系统管控，E-mail：gzj@sjzu.edu.cn。
引用本文：王馨璐, 高治军, 郭喜峰, 等. 基于健康特征增强与TCN-ASSA的锂离子电池RUL预测[J]. 储能科学与技术, XXXX, XX(XX): 1-13.
Citation：Wang Xinlu, Gao Zhijun, Guo Xifeng, et al. LITHIUM-ION BATTERY RUL PREDICTION BASED ON HEALTH FEATURE ENHANCEMENT AND TCN-ASSA[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-13.

enhance the original curve, and features such as peak value, the corresponding peak voltage, and the envelope area within a specified voltage interval are extracted. Meanwhile, equal-interval charging time and cycle number are incorporated to construct a multidimensional health feature set, thereby improving the representation of battery degradation states. Subsequently, a predictive model integrating TCN and ASSA is developed, in which TCN is used to capture long-term temporal dependencies in the capacity degradation process, while ASSA is introduced to emphasize critical degradation information and suppress irrelevant disturbances as well as abnormal fluctuations, thereby enhancing both RUL prediction accuracy and robustness. Finally, experiments are conducted on the Oxford and NASA lithium-ion battery datasets. On the Oxford dataset, TCN-ASSA achieved root mean square error (RMSE) of 2.2726 and mean absolute percentage error (MAPE) of 0.3634. On the NASA dataset, RMSE was as low as 0.00734 and MAPE as low as 0.00486. The results demonstrate that the proposed method achieves superior performance in ablation studies, comparative experiments, and cross-dataset generalization tests, enabling more accurate tracking of battery capacity degradation trends. The method exhibits high prediction accuracy, robustness, and adaptability, and can provide effective support for lithium-ion battery health management and safety warning.

Keywords: Lithium-ion battery; remaining useful life; machine learning; time convolutional network; adaptive sparse self-attention; features enhancement

有限的化石燃料储备以及气候变化对可再生能源、智能电网和清洁交通系统的发展提出了严峻挑战。锂离子电池凭借其高能量密度、低自放电率、环境友好性及较长使用寿命等优势，已在上述领域得到广泛应用，并发挥着重要作用[1-2]。然而，在反复充放电循环过程中，电池阳极、电解质及阴极内部会持续发生多种电化学副反应，导致电池性能逐渐退化，进而引起其剩余使用寿命（Remaining Useful Life，RUL）的衰减[3-4]。这种退化不仅会显著影响电池的充放电性能，甚至可能导致其无法正常工作，严重情况下还可能引发安全事故。因此，准确预测电池RUL对于实现电池的定期维护与安全稳定运行具有重要意义，有助于降低高昂的维护成本并减少灾难性后果发生的概率[5]。

作为电池管理系统的核心功能之一，RUL预测近年来受到了广泛关注与深入研究[6]。该过程主要基于电池当前的健康状态及其正常运行条件，对其在达到失效阈值（Failure Threshold，FT）之前可完成的充放电循环次数进行估计[7]。目前，电池RUL预测方法主要可分为基于模型的方法和数据驱动的方法两大类[8]。

基于模型的预测方法通过构建能够表征电池退化行为的数学模型，以刻画电池性能衰减过程与影响其老化的关键性能指标之间的映射关系[9]。其中，基于等效电路的模型由于结构简化，难以全面反映电池的动态变化特性[10]；而电化学模型则基于电池内部反应机理进行建模，但由于其内部反应过程高度复杂，构建精确的退化模型仍面临较大困难[11]。因此，基于模型的方法在实际应用中存在诸多挑战，其预测精度有待提升[12]。相比之下，数据驱动方法能在一定程度上有效规避上述问题。

基于数据驱动方法无需考虑电池内部物理化学反应过程，直接使用历史监测数据来预测电池的退化趋势，这类方法多采用机器学习算法[13]。文献[14]提出了离散小波分解与支持向量回归（Support VectorRegression，SVR）融合的锂离子电池RUL预测方法，通过对容量多尺度分解结合K-均值聚类对不同尺度信号进行重构，提升了预测的鲁棒性。文献[15]提出多任务集成学习与改进轻量型梯度提升机的方法，通过融合增量容量（Incremental Capacity，IC）-差值电压曲线与电化学阻抗谱特征，并利用自适应鲁棒损失函数优化模型训练过程，有效提升了不同工况下锂离子电池RUL预测的精度与稳定性。随着人工智能的发展，基于深度

学习的RUL预测方法越来越受到人们的重视[16]。文献[17]通过结合时间卷积网络（Temporal Convolutional Networks，TCN）、交叉注意力与并行双向长短期记忆网络，强化多尺度退化特征与长短期依赖建模提升RUL预测准确性，但模型结构较复杂、参数较多。文献[18]通过变分模态分解降噪并融合多源特征实现高精度RUL预测，但模型复杂且计算开销较大。文献[19]通过双向长短期记忆网络与Transformer结合膝点起始策略实现了高精度且可解释的RUL预测，但模型结构复杂且主要在单一电池验证，其跨电池类型的泛化能力仍有待评估。文献[20]采用物理信息神经网络将经验退化模型与物理约束引入数据驱动框架，在小样本、跨电池与跨工况场景下表现出较高稳定性并具备一定可解释性。文献[21]提出一种基于分解容量序列并分别采用门控循环单元（Gated Recurrent Unit，GRU）和多元线性回归建模高低频特征，GRU主要用于对容量序列分解后的高频分量进行建模，通过其门控机制有效捕捉时间序列中的非线性动态特征，在减少参数量的同时提升模型收敛速度，从而提高RUL预测性能。

经上述分析，本文提出一种基于健康特征增强与TCN-自适应稀疏自注意力（Adaptive Sparse Self-Attention，ASSA）的锂离子电池RUL预测方法，主要创新点总结如下：

（1）针对锂离子电池容量退化中的容量再生与局部波动问题，提取经萨维茨基-戈莱（Savitzky-Golay，SG）滤波增强的IC特征，并结合充电时间和循环次数构建健康特征，提高对电池退化状态的表征能力。

（2）提出一种基于TCN-ASSA的锂离子电池RUL预测模型，利用TCN建模长期时序依赖，并通过ASSA突出关键退化信息、抑制噪声干扰，从而提升预测精度。

1 锂离子电池健康特征

1.1 电池数据集描述

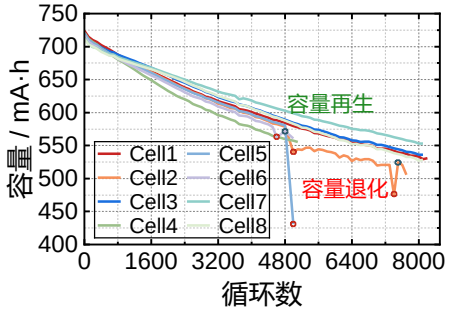
本文使用了来自牛津大学（Oxford）锂离子电池数据集[22]，由牛津大学电池智能实验室提供，包括来自8个Kokam SLPB533459H4锂离子软包电池Cell1-Cell8，正极材料是锂钴氧化物和锂镍钴氧化物的混合物，负极材料是石墨。标称容量为740 mA·h，在40℃下测试。8个电池分别进行恒压充电，充电电压最高可达4.2 V，随后采用由Urban Artemis城市道路行驶工况循环转换得到的动态放电电流进行放电，直至电池电压降至2.7 V，每100次循环进行表征测量以监测降解趋势。当电池容量达到额定容量的80%，即592mA·h时设置其寿命终止容量，Oxford电池的容量退化曲线如图1a所示，通过退化曲线可观察到电池老化过程中存在异常容量退化与容量再生现象。

电池在老化过程中出现容量突然退化和容量再生等异常变化，主要受到电化学反应、材料与结构特性以及外部工况条件三类因素的共同影响，其本质是活性锂与反应界面的短期可逆恢复，是电池“类自愈”现象，如图1b所示。电化学反应机制是容量再生最主要原因，包括锂金属释放、SEI膜变化和锂枝晶溶解。造成短期容量回升的原因是原本失效的活性锂重新可利用，是电池自愈作用的一种表现。材料与结构机制是容量再生的重要影响原因，包括活性物质激活、电解液渗透和隔膜裂缝。该现象的原因为结构重构导致新增活性界面与传输路径影响临时性能提升，是多次循环及休眠后再次工作时的常见现象。外部条件因素是容量再生的触发因素，包括温度变化、机械应力和循环充放电。在电池衰退曲线中出现局部“驼峰”、“反弹”或短期回升。容量再生是真实物理机理而非假信号。因此，如何削弱容量突变与再生现象对预测结果的不利影响，是提高锂离子电池RUL预测精度的关键问题。

图2以Cell3电池为例绘制不同循环下充电过程中的电压和温度曲线。由图2a可得，在恒流充电阶段，不同循环下电压曲线的整体变化趋势基本一致，但随着循环次数增加，曲线在局部区间的上升速率和持续时间存在一定差异；同时，由图2b可得，温度曲线在不同循环下也呈现出相似的变化趋势，并伴随局部幅值变化。上述现象表明，充电电压和温度信息能够在一定程度上反映电池循环老化过程中的状态变化。

1.2 健康特征提取

现有的大多研究方法仅使用单一特征来衡量锂离子电池容量变化，单一的特征虽然与容量变化的相关性较高，但是容易造成过于依赖唯一的特征而造成过拟合的问题。本研究基于多维数据时间、电



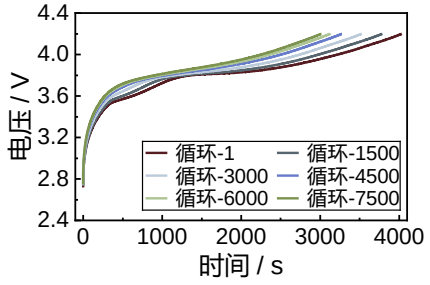
a. 容量退化曲线



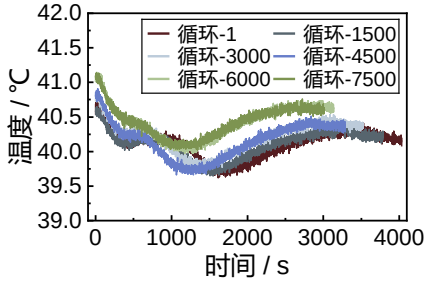
b. 非正常变化影响因素

图1 牛津电池退化曲线及影响因素

Fig. 1 Oxford battery degradation curve and influencing factors



a. 充电电压



b. 充电温度

图2 Oxford数据集在不同循环下的充电曲线

Fig. 2 Charging curves of the Oxford dataset under different cycles

压、温度、容量提出一种基于IC曲线，并将原始IC曲线由SG滤波平滑处理增强后提取IC曲线峰值及其位置用于表征电池内部状态变化。联合恒流充电时间和电池充放电循环次数构成电池健康特征（Health Features，HF）。为了防止特征冗余，使用皮尔逊相关系数（Pearson Correlation Coefficients，PCC）对特征进行相关性分析。

IC曲线通过建立数学模型来捕捉锂离子电池的外部特性与其内部电化学反应之间的关系，能够将电池的老化情况与电极内部锂离子在电极内的分离和嵌入之间建立联系，使特征信息更加直观。通过分析充电过程中容量和电压之间的差异关系，IC曲线可以有效评估锂离子电池健康状况，IC曲线由容量Q对电压V求导得到，数学上表示为：

$$\mathrm{IC} = d\left(\frac{Q}{V}\right) = \frac{dQ}{dV} = I \cdot \frac{dt}{dV} \approx \frac{\Delta Q}{\Delta V} \tag{1}$$

由于传感器的分辨率有限，差分操作也不可避免地会因采样而放大数据中的误差，造成IC曲线包含明显的噪声，采用SG滤波器平滑处理来减轻这种影响。为了减少计算量，选择基于时域中多项式最小二乘拟合的SG滤波器，SG滤波器是常用于平滑信号，保留曲线特征形状的数字滤波器。其表达式如下：

$$x_{smooth}(t) = \frac{1}{N}\sum_{i=-m}^{i=m} C_i\, x(t+i) \tag{2}$$

式中：x——原始时间序列数据；x_{smooth}——平滑后的时间序列数据；C_i——滤波系数，该系数通过最小二乘法拟合得出；N——滑动窗口中的数据点数量；m——窗口宽度，N=2m +1。

经过SG滤波增强处理后的IC曲线如图3所示。可以看出，平滑后的曲线具有较为明显的峰值特征，这些峰值通常对应电池内部特定的电化学反应过程。为充分挖掘IC曲线对电池退化状态的表征能力，本文针对充电阶段IC曲线提取了三个健康特征：峰值大小HF1、峰值对应电压HF2，以及3.8 V-4.1 V电压区间内IC曲线包络面积HF3。上述特征能够从不同角度反映电池电化学性能的衰退过程。

除IC曲线特征外，充电电压和温度曲线同样能够反映电池在老化过程中的状态变化。基于此，本文提取电池在充电过程中电压由3.8 V上升至4.2 V所需的时间，作为表征电池健康状态的等间隔充电电压时间特征，记为HF4。观察充电温度曲

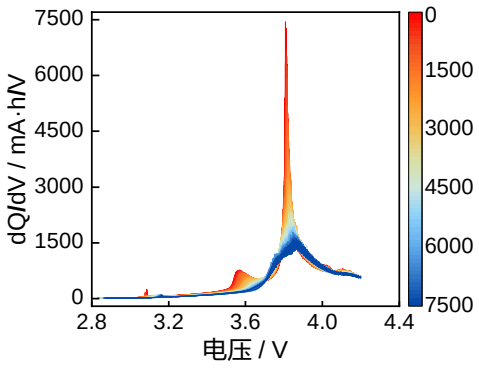


图3 Oxford数据集IC曲线

Fig. 3 IC curve of the Oxford dataset

线，不同循环间存在明显谷值，提取温度对应谷值记为HF5，同时，考虑到循环次数的增加必然伴随着电池性能的持续衰退，本文将充放电循环次数作为第六个健康特征，记为HF6。

PCC是一种常用的统计量，给出两个变量$\alpha=(\alpha_1, \alpha_2, \cdots, \alpha_n)$和$\beta=(\beta_1, \beta_2, \cdots, \beta_n)$，即可通过计算$\alpha$和$\beta$间的协方差和标准差来确定其两者的关联程度。取值范围在−1到1之间，当结果r接近1时，表示两个变量之间存在强正相关；当r接近-1时，表示两个变量之间存在强负相关；当r接近0时，表示两个变量之间几乎没有任何线性相关关系。PCC计算公式如公式（3）所示，E为期望值。

$$r=\frac{E(\alpha\beta)-E(\alpha)E(\beta)}{\sqrt{E(\alpha)^2-E^2(\alpha)}\sqrt{E(\beta)^2-E^2(\beta)}} \tag{3}$$

表1为各电池容量与健康特征之间的相关系数。结果计算表明，所提取的六个健康特征与电池容量除HF5外均具有较高相关性，说明这些特征能够较好地反映电池退化过程中的关键变化信息。因此，本文提取的健康特征HF1，HF2，HF3，HF4和HF6能够从不同维度有效表征锂离子电池的容量退化行为，并为后续RUL预测模型提供具有较高判别能力的输入信息。

表1 各电池容量与健康特征的皮尔逊相关性值

Table 1 PCC between Battery Capacity and Health Features

	HF1	HF2	HF3	HF4	HF5	HF6
Cell1	0.927451	-0.933356	0.998685	0.995126	-0.688746	−0.985529
Cell2	0.855238	-0.914431	0.994499	0.999236	-0.569657	−0.987786
Cell3	0.936082	-0.928187	0.998993	0.996015	-0.709994	−0.990571
Cell4	0.947117	-0.945264	0.997507	0.998579	-0.005033	−0.990374
Cell5	0.949776	-0.945110	0.998604	0.986462	-0.289417	−0.994584
Cell6	0.816960	-0.874084	0.996535	0.999578	-0.292426	−0.995993
Cell7	0.943423	-0.929556	0.998640	0.999837	-0.079157	−0.993816
Cell8	0.914990	-0.924044	0.998372	0.999127	-0.020569	−0.995511
平均值	0.911380	-0.924254	0.997729	0.996745	-0.331874	−0.991771

2 TCN-ASSA模型建立

锂离子电池RUL预测面临退化过程非线性强、长期依赖显著以及局部容量再生与异常波动并存等难点。传统时序建模方法在长距离依赖捕获、关键退化片段识别以及抗噪能力方面存在不足。为此，本文将TCN与ASSA相结合，构建TCN-ASSA预测模型。

2.1 时间卷积网络

TCN是一种基于卷积神经网络的序列建模方法，其结构如图4所示。该模型通过膨胀因果卷积与残差连接相结合，实现对时间序列的长依赖建模。

设输入时间序列为$X=\{x_1, x_2, \cdots, x_T\}$，TCN通过因果卷积保证模型满足时间顺序约束，即输出y_t仅依赖于历史信息，k为卷积核大小，$f(i)$为卷积核参数：

$$y_t=\sum_{i=0}^{k-1}f(i)x_{t-i} \tag{4}$$

为扩大感受野，引入扩张机制，得到扩张因果卷积形式：

$$H(t)=\sum_{i=0}^{k-1}f(i)x_{t-d\cdot i} \tag{5}$$

式中：d——膨胀因子。通过设置$d=2^l$（第l层），模型的感受野呈指数增长，从而有效捕获长时间依赖关系。

在网络结构上，TCN由多个残差块堆叠而成。每个残差块包含两层扩张因果卷积及归一化与正则

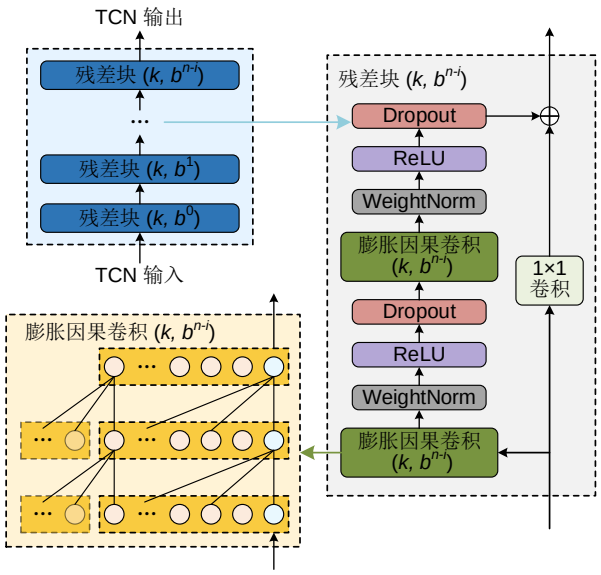


图4 TCN结构图

Fig. 4 TCN Structure Diagram

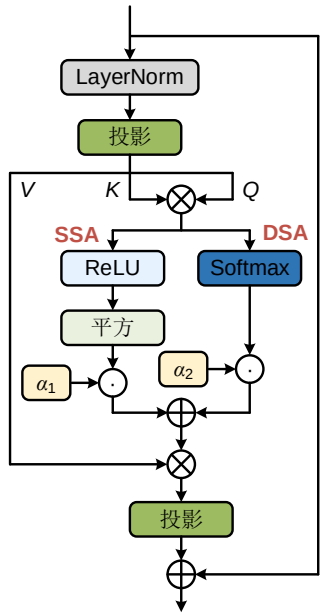


图5 ASSA结构图

Fig. 5 ASSA Structure Diagram

化操作，其中$F(\cdot)$表示两层卷积及非线性变换组合，$\sigma(\cdot)$为激活函数Relu。当输入输出维度不一致时，引入1×1卷积W_s进行维度匹配：

$$Z_i = \sigma\left(F(Z_{i-1}) + W_s Z_{i-1}\right) \tag{6}$$

通过堆叠多个残差块，TCN能够在保持计算效率的同时，构建大感受野结构，实现对序列的高效建模。最终输出通过线性映射得到预测结果：

$$\hat{y}_t = W_o Z_t^{(L)} + b_o \tag{7}$$

综上，TCN通过膨胀卷积和残差连接的结构设计，在避免信息泄露的前提下，有效提升了模型对长时间依赖关系的建模能力。

2.2 自适应稀疏自注意力模块

ASSA是一种双分支注意力机制，其核心思想是在同一注意力单元内同时引入稀疏自注意力分支（Sparse Self-Attention，SSA）与稠密自注意力分支（Dense Self-Attention，DSA），并通过可学习的自适应权重对两类分支进行动态融合，从而在抑制无效信息干扰的同时，尽可能保留序列中的关键时序依赖关系。其结构如图5所示。

对于序列输入$X\in\mathbb{R}^{T\times C}$，首先将序列划分为$T/M$个互不重叠的时间窗口，其中每个窗口包含$M$个token。经过线性投影后，得到查询（Query）、键（Key）和值（Value）表示Q，K，$V\in\mathbb{R}^{(T/M)\times M\times d}$。每个窗口内的注意力得分计算为：

$$S = \frac{QK^{\top}}{\sqrt{d}} + B \tag{8}$$

式中：Q——查询矩阵；K——键矩阵；d——特征维度；B——可学习的位置偏置项，用于显式建模窗口内不同时间位置之间的相对位置信息。该项的引入使注意力机制不仅能够度量特征相似性，还能够感知时间顺序结构。在得到注意力得分矩阵S，ASSA将其送入两个并行分支。ASSA将其送入两个并行分支。DSA分支采用Softmax函数对注意力得分矩阵S进行归一化处理，以获得稠密注意力分支输出；SSA分支采用平方ReLU函数对注意力得分矩阵进行稀疏化处理，平方操作的具体对象为注意力得分矩阵S经ReLU激活后的输出结果，即对每个窗口内的注意力得分S先执行ReLU操作，再对其输出进行平方：

$$\begin{cases} A_D = \mathrm{Softmax}(S) \\ A_S = \mathrm{ReLU}^2(S) \end{cases} \tag{9}$$

由于Softmax会将所有位置映射为非负且归一化的权重，因此DSA分支能够较完整地保留上下文信息，适合捕获较为平滑且分布广泛的时序依赖关系。SSA分支更加关注窗口内部对当前预测更具贡献的关键时间位置，因此能够在一定程度上过滤无关扰动，强模型对局部显著变化和关键依赖关系的表征能力。

考虑到单独使用DSA容易保留过多冗余信息，而单独使用SSA又可能因过度稀疏导致上下文信息缺失，ASSA引入自适应融合机制，对两个分支

的输出进行加权组合。最终的自适应稀疏注意力表示为：

$$A = \alpha_1 A_S + \alpha_2 A_D \tag{10}$$

其中，自适应权重α_i定义为：

$$\alpha_i = \frac{e^{\alpha_i}}{\sum_j e^{\alpha_j}} \tag{11}$$

在得到融合后的注意力矩阵A后，再与值矩阵V相乘，以完成加权聚合，并通过输出映射与残差连接形成模块最终输出：

$$\begin{cases} Y = AV \\ X_{out} = X + YW_O \end{cases} \tag{12}$$

式中：W_O——输出投影矩阵，用于将注意力聚合后的特征映射回原始特征空间。残差连接则有助于缓解梯度消失问题，同时保留输入序列中的原始信息，使更新后的特征表达兼具稳定性与判别性。

综上，ASSA模块通过DSA保留全局，SSA强化关键依赖，自适应权重有效提升了时间序列建模中对复杂依赖关系的提取能力，从而提高预测的准确性和效率。

在TCN与ASSA的协同作用下，所构建的TCN-ASSA模型能够同时兼顾电池退化的长期趋势建模与关键局部特征捕获。其中，TCN主要负责从HF序列中提取具有层次性的时序表示，学习容量衰退过程中的动态规律；ASSA则对TCN提取的深层特征进行重加权分配，突出与RUL相关性更强的关键特征响应，抑制由测量噪声或异常波动引起的无效干扰，削弱容量再生中非退化相关的局部扰动成分。因此，该模型不仅能够更准确地表征锂离子电池退化过程中的长期演化趋势，还能够提高对局部关键退化信号的识别能力，从而实现更精确的RUL预测。

3 实验结果与分析

本文TCN-ASSA模型采用串联结构，其中TCN作为主干网络提取健康特征序列中的多尺度时序信息，ASSA模块连接于TCN输出端，对深层退化特征进行自适应重加权。为验证模型超参数设置的合理性，本文采用控制变量法开展超参数灵敏度分析。选取学习率、残差块数、注意力头数和Dropout系数作为主要分析对象，在每组实验中仅改变一个超参数，其余模型结构和训练参数保持不变，并采用均方根误差（Root Mean Squared Error，RMSE）评价模型预测性能。实验结果表明，学习率、残差块数对预测性能影响相对明显，但在本文所选参数邻近范围内，模型误差变化较为平稳。综合预测精度、训练稳定性和模型复杂度，本文最终选取TCN部分设置3个残差块，卷积核大小为3，通道数分别为32、64和64，膨胀因子依次为1、2和4，激活函数采用ReLU，Dropout设为0.2。ASSA设置1层多头自注意力结构，注意力头数为4，每头维度为16，总隐藏维度为64，局部窗口长度设为8，注意力输出后的Dropout设为0.1。模型输出端采用全局平均池化和全连接层得到最终预测值。训练过程中采用Adam优化器，初始学习率为0.001，批大小为32，最大训练轮数为100。本文采用均方误差（Mean Squared Error，MSE）损失函数作为模型训练的优化目标，MSE梯度随误差减小而减小，有助于在训练后期更精确地逼近最优解，同时MSE公式直观计算效率高，RMSE和MSE定义如下：

$$\mathrm{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \tag{13}$$

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \tag{14}$$

式中：y_i——电池容量的真实值；$\hat{y}_i$——电池容量的预测值；i——电池充放电次数；n——总充放电次数。

为了验证本文所提模型的预测性能与准确性，本研究采用绝对误差（Absolute Error，AE）、均方根误差（Root Mean Squared Error，RMSE）和平均绝对百分比误差（Mean Absolute Percentage Error，MAPE）三个评估指标进行综合评价。其中，RMSE和MAPE用于衡量模型在真实容量与预测容量之间的误差程度，而AE用于反映真实循环次数与预测循环次数之间的绝对偏差。MAPE和AE定义如下。

$$\mathrm{MAPE} = \frac{1}{n}\sum_{i=1}^{n}\frac{|y_i - \hat{y}_i|}{y_i} \tag{15}$$

$$\mathrm{AE} = |C_{FT} - P_{FT}| \tag{16}$$

电池的RUL定义为电池容量在达到失效阈值之前可完成的充放电循环次数。C_{FT}为电池至寿命达到失效阈值前的充放电循环次数，P_{FT}为预测循环次数。本文中的失效阈值仅用于根据预测容量曲线确定寿命终止循环点，并进一步计算RUL预测

误差；模型训练阶段并未将失效阈值作为输入变量或优化约束，因此阈值设置主要影响RUL评价结果，而不直接影响容量预测模型的训练过程。

3.1 消融实验

为验证本文所提模型中各组成模块的有效性与必要性，基于Oxford数据集对8块电池开展消融实验，设置2000循环为预测起点，即前2000个循环为训练集，剩余循环为测试集预测电池容量，8块电池逐个独立训练。为验证TCN时序特征提取模块与ASSA注意力模块对模型预测性能的贡献，本文依据所提模型的主要组成结构，分别构建TCN、TCN-SA、MLR-SA和TCN-ASSA四种模型进行消融实验，并采用RMSE和MAPE作为评价指标，实验结果如表2所示。

与基础TCN模型相比，引入注意力机制后模型的评估指标得到明显改善。以TCN-SA为例，其在各电池上的RMSE和MAPE均有不同程度下降，表明在仅依靠时序卷积提取退化特征的基础上，加入注意力机制后，模型能够强化对关键时间步和重要特征维度的关注，从而减弱无关信息和局部波动对预测结果的干扰。对比MLR-SA与TCN-SA可发现，TCN-SA在全部8块电池上均取得了更低的RMSE和MAPE，说明在引入相同注意力机制的条件下，TCN比MLR具有更强的时序特征提取能力。TCN通过膨胀因果卷积和残差连接，能够从健康特征序列中提取多尺度时序信息，并有效捕捉长时间依赖关系，因此在退化趋势建模方面表现更优。这一结果表明，注意力机制还需要与更适合时序建模的主干网络相结合，才能充分发挥模型性能。

表2 消融实验评估指标RMSE和MAPE

Table 2 Evaluation Metrics RMSE and MAPE of the Ablation Experiments

Battery	Method	RMSE	MAPE	Battery	Method	RMSE	MAPE
Cell1	TCN	5.9194	0.9738	Cell5	TCN	5.4607	0.8828
	MLR-SA	5.3758	0.8827		MLR-SA	4.8565	0.7747
	TCN-SA	4.9486	0.8069		TCN-SA	3.6260	0.5680
	TCN-ASSA	2.9165	0.4731		TCN-ASSA	2.2223	0.3425
Cell2	TCN	5.9407	1.0132	Cell6	TCN	5.3944	0.8358
	MLR-SA	4.2087	0.7078		MLR-SA	4.2696	0.6853
	TCN-SA	3.1750	0.5366		TCN-SA	3.1225	0.5016
	TCN-ASSA	2.2177	0.3688		TCN-ASSA	2.1261	0.3379
Cell3	TCN	5.4720	0.8883	Cell7	TCN	5.7741	0.9241
	MLR-SA	4.1623	0.6781		MLR-SA	4.2911	0.6860
	TCN-SA	3.1916	0.5185		TCN-SA	2.2545	0.5197
	TCN-ASSA	2.0867	0.3271		TCN-ASSA	2.2103	0.3504
Cell4	TCN	6.1976	1.0234	Cell8	TCN	5.7258	0.9471
	MLR-SA	4.0457	0.6506		MLR-SA	4.5409	0.7446
	TCN-SA	3.1532	0.5076		TCN-SA	3.3240	0.5490
	TCN-ASSA	2.2322	0.3576		TCN-ASSA	2.1690	0.3497

将普通自注意力替换为自适应稀疏自注意力后，模型性继续提升。与TCN-SA相比，TCN-ASSA在8块电池上的平均RMSE由3.3494降至2.2726，平均MAPE由0.5635降至0.3634，分别下降约32.15%和35.51%。一方面，DSA分支能够保留较完整的上下文信息，使模型具备较好的全局依赖建模能力；另一方面，SSA分支通过稀疏化机制突出对预测贡献更大的关键时序位置，从而抑制容量再生、局部异常波动及测量噪声带来的干扰。再结合自适应融合权重，可根据不同样本的退化特征动态平衡稠密注意力与稀疏注意力的作用，因此在非平稳退化场景下表现出更高的预测精度。

3.2 对比实验

选取三种典型数据驱动方法作为对照模型，分别记为M1[14]、M2[15]和M3[23]，分别代表基于机器学习模型DWD-SVR（M1）、集成学习LightGBM模型（M2）和智能优化的组合模型GWO-SCN（M3），覆盖了当前电池RUL估计的主要数据驱动方法，能够较为全面地验证所提方法的有效性。在Oxford数据集8块电池上的容量预测结果如图6所

示，RUL预测结果及误差统计如表3所示。由图6可以看出，相较于其他对照模型，M4在各电池上的预测曲线与真实容量退化曲线整体拟合度更高，不仅能够较准确地跟踪电池容量衰减的整体趋势，而且在局部波动和容量再生区间仍保持较好的拟合能力，未出现明显的提前失效判断或滞后预测现象。这说明本文方法在处理锂离子电池容量退化过程中的非线性变化和局部异常波动时具有更强的适应能力。

结合表3分析可知，M4在8块电池上的预测终止循环次数均最接近真实失效循环次数C_{FT}，表现出最优的RUL预测精度。其中，在Cell3、Cell4、Cell6、Cell7和Cell8五组电池上，M4的预测终止循环次数P_{FT}与真实值完全一致，AE均为0，说明模型能够准确识别电池达到失效阈值的时刻；在Cell1、Cell2和Cell5上，M4的AE仅为100。从整体平均结果来看，M1、M2、M3和M4在8块电池上的平均AE分别为237.5、225.0、187.5和37.5。与M1相比，M4的平均AE下降约84.21%；与M2相比下降约83.33%；与M3相比下降约80.00%。这一结果表明，本文方法在RUL预测任务中具有显著优势。

3.3 泛化分析

为验证本文所提方法在不同数据集条件下的鲁棒性与泛化能力，选取NASA锂离子电池数据集开展泛化实验分析。与Oxford数据集相比，NASA数据集在电池材料体系、封装形式、额定容量以及充放电策略等方面均存在显著差异。NASA锂离子电池数据集由美国国家航空航天局提供，本文选取其中B0005、B0006、B0007和B0018共4块18650圆柱锂离子电池作为研究对象，额定容量为2 A·h，实验在约24 ℃室温条件下进行，充电阶段采用恒流-恒压策略，放电阶段采用恒流放电并设置不同截止电压，以加速电池老化过程。设定失效阈值为容量的70% 即1.4 A·h，由于B0007电池未达到1.4 A·h，故设定为1.45 A·h。分别设置不同预测起点，与Oxford设置一致，预测起点前的数据划分为训练集。为降低不同阈值设置对模型比较结果的影响，本文在同一数据集内部对所有对比模型采用完全一致的失效阈值和评价标准。因此，模型间RUL预测性能比较仍具有公平性和一致性。

图7给出本文所提TCN-ASSA模型在NASA数据集不同预测起点下的预测结果及评估指标。从图中可以看出，在不同预测起点条件下，本文所提模型均能够较好地跟踪NASA电池容量衰退的整体变化趋势，尽管NASA数据集中的容量退化过程同样存在局部波动和容量再生现象，但模型仍能够较准确地识别异常及后期衰减趋势，表明所提方法对非平稳退化特征具有较好的适应能力。

通过分析不同预测起点下的结果可以得出结

表3 对比实验评估指标

Table 3 Comparison experiment evaluation indicators

Battery	C_{FT}	Method	P_{FT}	ER	Battery	C_{FT}	Method	P_{FT}	ER
Cell1	4400	M1	4100	300	Cell5	4300	M1	4100	200
		M2	4800	400			M2	4500	200
		M3	4200	200			M3	4100	200
		M4	4500	100			M4	4400	100
Cell2	4200	M1	4000	200	Cell6	4000	M1	3900	100
		M2	4400	200			M2	4200	200
		M3	4100	100			M3	3900	100
		M4	4300	100			M4	4000	0
Cell3	4800	M1	4500	300	Cell7	5400	M1	5200	200
		M2	5000	200			M2	5700	300
		M3	4600	200			M3	5200	200
		M4	4800	0			M4	5400	0
Cell4	3500	M1	3200	300	Cell8	4800	M1	4500	300
		M2	3600	100			M2	5000	200
		M3	3300	200			M3	4500	300
		M4	3500	0			M4	4800	0

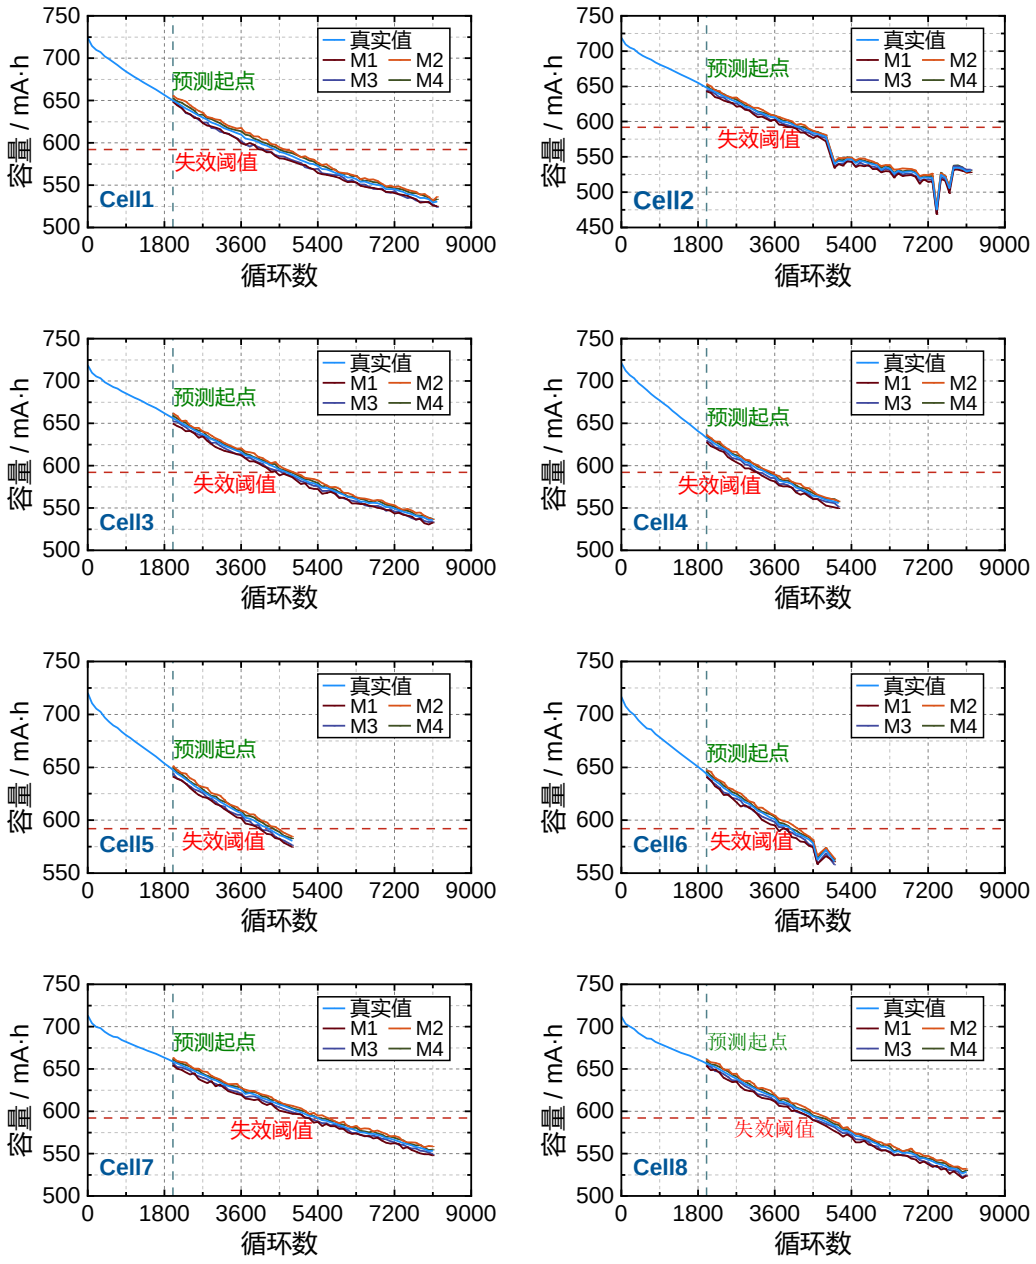


图6 对比实验容量预测曲线

Fig. 6 Capacity Prediction Curve for Comparative Experiments

论，随着预测起点向后移动，模型的预测误差整体呈减小趋势。这是因为当预测起点较早时，训练样本中包含的退化信息相对有限，模型对电池后期衰退规律的学习仍不充分，因此预测结果会存在一定偏差。而当预测起点适当后移后，模型能够利用更多退化历史信息建立更稳定的映射关系，从而获得更高的预测精度。

综上所述，NASA数据集上的泛化实验结果表明，本文所提方法在不同预测起点和不同数据分布条件下均能够取得较稳定的预测效果，体现出较好的鲁棒性与泛化能力。为后续面向复杂工况和多类型电池的RUL预测应用提供了可行的技术支撑。

4 结 论

本文提出一种基于健康特征增强与TCN-ASSA的锂离子电池RUL预测方法。通过对充电阶段IC曲线进行SG滤波处理增强特征，提取峰值、峰值

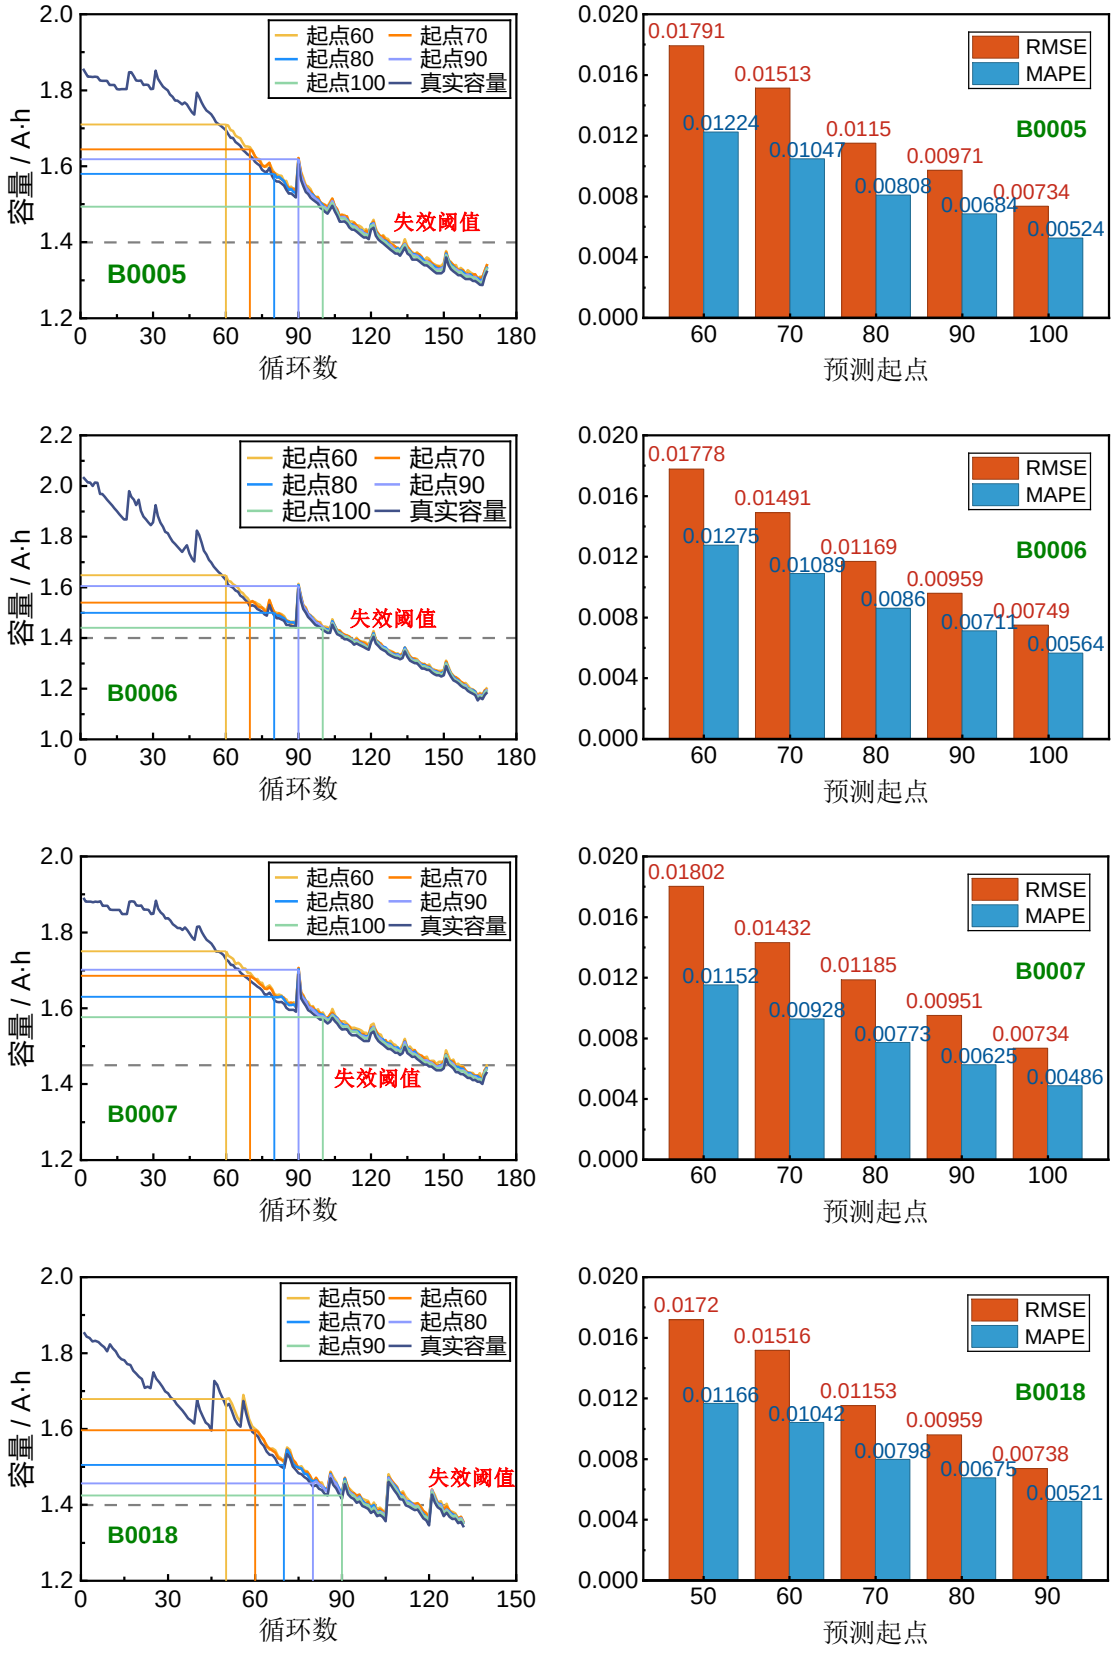


图7　NASA数据集不同起点的预测及评估指标

Fig. 7　Prediction and evaluation indicators for different starting points in the NASA dataset

位置、包络面积、充电时间和循环次数等HF，提高了对电池退化状态的表征能力。在此基础上，构建TCN-ASSA预测模型，利用TCN提取长期时序依赖关系，并结合ASSA突出关键退化信息、抑制局部波动和噪声干扰，从而提升RUL预测精度。基于Oxford和NASA数据集的实验结果表明，所提方法在消融实验、对比实验和泛化实验中均表现出较好的预测精度、鲁棒性和跨数据集适应能力。在Oxford数据集的8块电池中，5块电池所提方法AE为0，剩余3块电池的AE也仅为100个循环，平均AE为37.5个循环。在NASA数据集泛化实验中，不同预测起点下模型RMSE保持在0.01802以下，MAPE保持在0.01275以下，进一步验证了所提方法在不同电池类型和数据分布条件下的适应能力。由于本文所用健康特征主要来源于充电阶段电压、电流、温度及循环次数等BMS常规监测数据，且模型推理可在周期性健康诊断阶段完成，因此该方法在储能电站、电动汽车及梯次利用电池系统的RUL评估和安全预警中具有一定工程应用潜力。后续研究将进一步面向复杂工况、数据缺失和多类型电池场景开展模型轻量化、在线更新和不确定性评估研究。

参 考 文 献

[1] 李炳金, 韩晓霞, 张文杰, 等. 锂离子电池剩余使用寿命预测方法综述[J]. 储能科学与技术, 2024, 13(04): 1266-1276.
Li B J, Han X X, Zhang W J, et al. Review of the remaining useful life prediction methods for lithium-ion batteries[J]. Energy storage science and technology, 2024, 13(04): 1266-1276.

[2] Song K, Hu D, Tong Y, et al. Remaining life prediction of lithium-ion batteries based on health management: A review[J]. Journal of Energy Storage, 2023, 57: 106193.

[3] 周驰东, 李嘉宇, 余佩雯, 等. 机器学习在锂离子电池故障诊断中的应用综述[J]. 电池, 2025, 55(05): 1159-1165.
Zhou C D, Li J Y, Yu P W, et al. Review on application of machine learning in Li-ion battery fault diagnosis[J]. Dianchi (Battery Bimonthly), 2025, 55(05): 1159-1165.

[4] Luo K, Chen X, Zheng H, et al. A review of deep learning approach to predicting the state of health and state of charge of lithium-ion batteries[J]. Journal of Energy Chemistry, 2022, 74: 159-173.

[5] 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(01): 222-230.
Cheng Y, Wang J L, Wang P, et al. A review of early remaining life prediction methods for Li-ion battery[J]. Dianchi (Battery Bimonthly), 2026, 56(01): 222-230.

[6] 蔡艳平, 王新军, 姜柯, 等. 基于GRNN-GSA-ELM的在线锂离子电池RUL多步预测[J]. 机械工程学报, 2024,60(24): 296-308.
Cai Y P, Wang X J, J K, et al. Multi-step prediction of online lithium battery remaining useful life based on GRNN-GSA-ELM [J]. Journal of mechanical engineering, 2024,60(24): 296-308.

[7] 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(06): 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 energiae solaris sinica, 2025, 46 (06): 68-78.

[8] Zhou Y, Wang S, Xie Y, et al. Remaining useful life prediction and state of health diagnosis for lithium-ion batteries based on improved grey wolf optimization algorithm-deep extreme learning machine algorithm[J]. Energy, 2023, 285: 128761.

[9] 卢婷, 杨文强. 锂离子电池全生命周期内评估参数及评估方法综述[J]. 储能科学与技术, 2020, 9(03): 657-669.
Lu T, Yang W Q. Review of evaluation parameters and methods of lithium batteries throughout its life cycle[J]. Energy storage science and technology, 2020, 9(03): 657-669.

[10] 陈金荣, 孙跃东, 邵裕新, 等. 基于等效电路模型的云端动力电池寿命估计[J]. 重庆理工大学学报(自然科学), 2024, 38(06): 11-20.
Chen J R, Sun Y D, Shao Y X, et al. Battery life estimation of cloud-based based on equivalent circuit modeling[J]. Journal of Chongqing University of Technology (Natural Science), 2024, 38 (06): 11-20.

[11] 徐鹏飞, 张睿, 丁飞. 基于电化学-热耦合模型的锂离子电池日历老化研究[J]. 电源技术, 2025, 49(08): 1638-1649.
Xu P F, Zhang R Ding F. Calendar aging study of lithium-ion batteries based on electrochemical-thermal coupling model[J]. Power supply technology, 2025, 49(08): 1638-1649.

[12] Du Z, Zuo L, Li J, et al. Data-driven estimation of remaining useful lifetime and state of charge for lithium-ion battery[J]. IEEE Transactions on Transportation Electrification, 2021, 8(1): 356-367.

[13] Zhang Y, Li Y. Prognostics and health management of Lithium-ion battery using deep learning methods: A review[J]. Renewable and sustainable energy reviews, 2022, 161: 112282.

[14] 王小明, 何叶, 王路路, 等. 基于DWD-SVR模型的锂离子电池剩余使用寿命预测[J]. 太阳能学报, 2025, 46(02): 52-59.
Wang X M, He Y, Wang L L, et al. RUL prediction for lithium-ion batteries based on DWD-SVR model[J]. Acta energiae solaris sinica, 2025,46(02): 52-59.

[15] 王伟亮, 刘会巧, 张天宇, 等. 基于多任务集成学习的储能电池剩余使用寿命预测[J]. 电力建设, 2024, 45(11): 25-33.
Wang W L, Liu H Q, Zhang T Y, et al. Multi-task ensemble learning-based prediction of remaining useful life of energy-storage batteries[J]. Electric Power Construction, 2024, 45(11): 25-33.

[16] Li X, Yu D, Byg V, et al. The development of machine learning-based remaining useful life prediction for lithium-ion batteries[J]. Journal of Energy Chemistry, 2023, 82: 103-121.

[17] 余萍, 王浩年, 曹洁. 基于多尺度特征融合的并行神经网络剩余寿命预测方法[J]. 太阳能学报, 2026, 47(01): 785-796.
Yu P, Wang H N, Cao H, et al. Remaining useful life prediction method based on parallel neural networks with multi-scale feature fusion [J]. Acta energiae solaris sinica, 2026, 47(01): 785-796.

[18] 勇晔, 吴参林, 薛溟枫, 等. 基于多通道特征融合优化VMD-SCNN-LSTM的锂电池RUL预测[J]. 太阳能学报, 2025,46(12): 41-51.
Yong Y, Wu C L, Xue M F, et al. Multi-channel feature fusion-based VMD-SCNN-LSTM for lithiun-ion battery RUL prediction[J]. Acta energiae solaris sinica, 2025,46(12): 41-51.

[19] Gomez W, Wang F, Chou J. Li-ion battery capacity prediction using improved temporal fusion transformer model[J]. Energy, 2024, 296: 131114.

[20] Wang F, Zhai Z, Zhao Z, et al. Physics-informed neural network for lithium-ion battery degradation stable modeling and prognosis [J]. Nature Communications, 2024, 15(1): 4332.

[21] 武明虎, 岳程鹏, 张凡, 等. 多尺度分解下GRU-MLR组合的锂电池剩余使用寿命预测方法[J]. 储能科学与技术, 2023,12(07): 2220-2228.
Wu M H, Yue C P, Zhang F, et al. Combined GRU-MLR method for predicting the remaining useful life of lithium batteries via multiscale decomposition[J]. Energy storage science and technology, 2023,12(07): 2220-2228.

[22] Howey, D., and C. Birkl. Oxford Battery Degradation Dataset 1. University of Oxford, 2017. https://ora. ox. ac. uk/objects/uuid: 03ba4b01-cfed-46d3-9b1a-7d4a7bdf6fac

[23] Wang X, Gao Z, Guo X, et al. Prediction of the Remaining Useful Life of Lithium-Ion Batteries Based on Health Features Extraction and Improved Stochastic Configuration Networks[J]. Batteries, 2026, 12(4): 114.