储能XXXX

考虑局部再生与全局衰退特性的锂电池剩余使用寿命双流融合预测方法研究

朱刚强[1, 2]，李加强[1, 2*]
（[1]西南林业大学机械与交通学院，云南 昆明 650224；[2]云南省高校高原山区机动车环保与安全重点实验室，云南 昆明 650224）

摘 要：针对锂电池退化过程中容量局部波动与长期衰退特征并存，以及传统单一网络难以充分提取多尺度退化特征的问题，提出一种基于改进灰狼优化和交叉注意力的双流时空特征锂电池剩余使用寿命（Remaining useful life, RUL）预测方法。首先，从电池充放电过程的电压、电流和温度数据中提取5种间接健康因子，并通过皮尔逊相关系数和斯皮尔曼等级相关系数分析健康因子与容量之间的相关性，筛选出3种相关性较强的健康因子作为模型输入。其次，构建由时间卷积网络（Temporal Convolutional Networks, TCN）和Transformer组成的双流网络，分别提取健康因子序列中映射的局部退化波动特征和全局时序依赖，并引入交叉注意力机制实现两类特征的动态交互与融合。在此基础上，采用改进灰狼优化算法对模型关键超参数进行优化。利用NASA和CALCE锂电池数据集进行验证，结果表明，所提方法能够有效跟踪电池容量退化过程，在NASA数据集B0005、B0006、B0007和B0018电池上的RMSE分别为0.0138、0.0170、0.0100和0.0098，在CALCE数据集CS_35和CS_36电池上的RMSE分别为0.0074和0.0070，均表现出较高的预测精度。结果表明，双流时空特征提取与交叉注意力融合能够有效增强模型对局部退化波动和长期退化趋势的表征能力，改进灰狼优化进一步提升了模型的预测性能和泛化能力。

关键词：锂电池；剩余使用寿命；双流时空特征；交叉注意力机制；改进灰狼算法
doi：10.19799/j.cnki.2095-4239.2026.0689
中图分类号：TM 911.4　　文献标志码：A　　文章编号：2095-4239（XXXX）XX-1-17

A Dual-Stream Fusion Prediction Method for the Remaining Useful Life of Lithium Batteries Considering Local Regeneration and Global Degradation Characteristics

ZHU Gangqiang[1, 2], LI Jiaqiang[1, 2*]
([1]School of Mechanical and Transportation Engineering, Southwest Forestry University, Kunming 650224, Yunnan, China; [2]Key Laboratory of Environmental Protection and Safety of Motor Vehicles in Plateau Mountainous Areas, Yunnan Provincial Universities, Kunming 650224, Yunnan, China)

Abstract: To address the coexistence of local capacity fluctuations and long-term degradation characteristics in lithium-ion batteries and the difficulty of conventional single-stream networks in extracting multi-scale degradation features, a remaining useful life prediction method based

收稿日期：2026-08-09；修改稿日期：2026-09-21。
基金项目：国家自然科学基金资助项目（51968065）；云南省科技厅科技计划项目（202301BD070001-077）。
第一作者：朱刚强（1998—），男，硕士研究生，研究方向为锂电池寿命预测和电池管理系统设计。E-mail：3185198028@qq.com；通信作者：李加强（1977—），男，博士，副教授，研究方向为车辆排放机理研究和电池管理系统设计；E-mail：lijiaqiang@swfu.edu.cn。
引用本文：朱刚强, 李加强. 考虑局部再生与全局衰退特性的锂电池剩余使用寿命双流融合预测方法研究[J]. 储能科学与技术, XXXX, XX(XX): 1-17.
Citation：ZHU Gangqiang, LI Jiaqiang. A Dual-Stream Fusion Prediction Method for the Remaining Useful Life of Lithium Batteries Considering Local Regeneration and Global Degradation Characteristics[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-17.

on improved grey wolf optimization and cross-attention-based dual-stream spatiotemporal feature extraction is proposed. Five indirect health factors are first extracted from voltage, current, and temperature data during battery charge and discharge processes. Pearson correlation coefficient and Spearman rank correlation coefficient are then used to analyze the correlations between the health factors and battery capacity, and three highly correlated health factors are selected as model inputs. A dual-stream network consisting of a temporal convolutional network and a Transformer is constructed to extract local degradation features and global temporal dependencies, respectively, from health factor sequences; a cross-attention mechanism is introduced to facilitate the dynamic interaction and fusion of these two types of features, and an improved Grey Wolf Optimization algorithm is employed to optimize key model hyperparameters. Experiments are conducted using lithium-ion battery datasets from NASA and CALCE. The results show that the proposed method effectively tracks battery capacity degradation. The RMSE values for batteries B0005, B0006, B0007, and B0018 in the NASA dataset are 0.0138, 0.0170, 0.0100, and 0.0098, respectively, while those for batteries CS_35 and CS_36 in the CALCE dataset is 0.0074 and 0.0070, respectively. These results demonstrate that dual-stream spatiotemporal feature extraction and cross-attention fusion enhance the representation of local degradation fluctuations and long-term degradation trends, while improved grey wolf optimization further improves the prediction performance and generalization capability of the proposed model.

Keywords: lithium-ion battery; remaining useful life; dual-stream spatiotemporal features; cross-attention; improved grey wolf optimization

0 引 言

锂电池因自身具有高能量密度、长循环寿命和低自放电率等显著优势，已成为新能源汽车、航空航天与大规模储能系统的核心动力[1-3]。而锂电池的剩余使用寿命（Remaining Useful Life，RUL）作为衡量电池健康状态的关键指标，对其准确的预测对于预防系统故障、优化运维策略和降低全生命周期成本具有重要意义[4]。然而，锂电池的容量老化过程是复杂的与非线性时变的，除了由SEI膜增厚和活性锂损失导致的长期不可逆容量衰减，还存在由静置恢复效应引起的容量再生现象[5-6]。因此，对电池RUL的精确预测已经成为当前电池管理系统面临的巨大挑战。

现有的锂电池RUL预测方法主要分为基于物理模型的方法和基于数据驱动的方法[7-9]。基于物理模型方法通过解析电池内部的电化学机理来对电池RUL进行预测。Schimpe等提出了一种综合的半经验模型，将电池的内部参数集与容量的衰退函数相结合，在循环寿命和日历寿命的基础上开展实验。结果表明该模型所预测的寿命与实际值的误差要低于1%[10]。Sadabadi等设计了一种基于增强单颗粒模型参数估计的RUL预测算法，通过单颗粒模型估计电池阻抗，从而得到电池的健康状态预测值，再通过粒子滤波算法预测RUL[11]。Liu等基于等效电路模型对电池的动态外部电学特性进行近似计算，结合前馈补偿方法来提高开路电压识别的精度，并采用改进的自适应扩展卡尔曼滤波算法来对锂电池荷电状态进行估计[12]。但是，基于物理模型的RUL预测方法对模型的构建比较困难，且模型参数辨识非常依赖特定的实验环境，很难适应实车运行中复杂多变动态的工况，严重限制了实时应用能力。相较而言，基于数据驱动方法主要通过挖掘历史监测数据中的非线性退化规律实现RUL预测。早期的研究多采用粒子滤波[13]、支持向量机[14]、相关向量机[15]和高斯过程回归[16]等浅层机器学习算法，其在特定场景下有效，但在处理高维时序数据时存在局限。而随着深度学习的发展，长短期记忆网络及其变体由于其优异的时序建模能力而备受关注。Li等提出了一种深度长短时记忆网络的锂离子

电池容量在线估计模型，实现了最佳平均绝对误差率0.76%，并且在处理输入噪声时极为稳健[17]。张浩等提出了一种多状态影响下基于Bi-LSTM网络的锂电池剩余寿命预测方法，直接实现三种电池状态至RUL的预测[18]。Li等提出了一种基于变分模态分解（Variational Mode Decomposition, VMD）融合麻雀搜索算法（Sparrow Search Algorithm, SSA）和长短期记忆网络的预测方法，用于锂电池RUL的估计，有效提高了预测的准确性与鲁棒性[19]。高德欣等针对传统RUL预测方法在精确度和稳定性方面的不足，融合卷积神经网络和双向长短时记忆网络的优势，设计一种基于CNN-BiLSTM的锂离子电池RUL预测方法[20]。岳家辉等通过引入健康特征信息量加权机制，进一步提升了神经网络的解释性与精度，其预测MAE和RMSE分别控制在0.0027~0.0035 mAh和0.0031~0.0042 mAh范围内[21]。然而，RNN类网络固有的串行计算机制导致其并行效率受限。为此，基于自注意力机制的Transformer架构应运而生。耿鑫月等提出了一种基于Transformer网络的双时间尺度的RUL预测模型，能够有效地降低锂电池容量退化的长期依赖性对预测模型的影响[22]。

尽管混合神经网络模型在一定程度上弥补了单一网络的缺陷，但现有的融合策略大多采用静态的特征拼接。而这样的融合方式忽略了电池在不同老化阶段特征的时变差异，难以实现多特征的深层交互和自适应权重分配。针对上述问题，本文提出了一种基于改进灰狼优化算法（Gold-panning-based Grey Wolf Optimization，GGWO）的双流时空特征提取和交叉注意力融合（TCN-Transformer-crossAttention）的锂电池RUL预测方法。主要创新点如下：

（1）提出基于异构双流架构的时空多尺度特征解耦提取框架。针对容量序列中局部再生现象和长期衰退规律的强耦合特性，构建TCN和Transformer并行的异构网络。利用TCN的因果膨胀卷积有效捕捉局部时域突变，利用Transformer的自注意力机制有效建模全局时序依赖，克服单一网络在局部敏感度和全局感受野之间的固有矛盾。

（2）构建基于交叉注意力机制的动态特征融合模型。摒弃传统的静态向量拼接策略，引入交叉注意力机制建立局部特征和全局特征之间的深层语义映射。通过TCN提取健康因子序列中映射的局部状态和Transformer提取全局规律，实现以局部检索全局的动态交互，赋予模型在非平稳退化工况下的动态特征加权能力。

（3）设计多策略改进的离线全局超参数寻优算法。针对深度混合模型面临的参数敏感性和早熟收敛问题，提出改进的灰狼优化算法。该算法耦合Tent混沌映射的遍历性初始化、非线性收敛因子的动态调节策略和淘金算法中的探矿者迁移算子，增强算法的跳出局部极值能力，实现在高维解空间下模型的关键超参数的快速寻优。

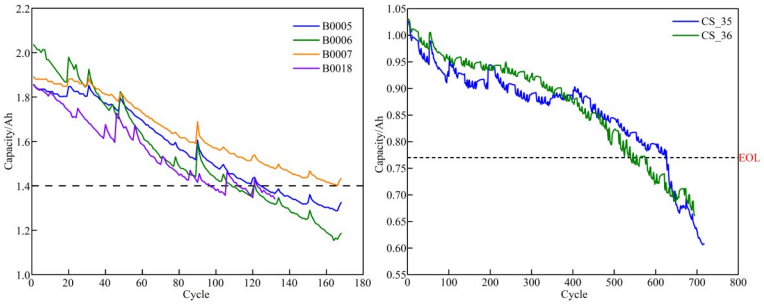
1 锂电池的健康因子选取

1.1 实验数据集介绍

为了评估RUL预测模型对电池容量的局部波动和长期衰退趋势的捕捉能力，本文选取了NASA数据集[23]和CALCE数据集作为研究对象[24]。选用NASA的B0005、B0006、B0007和B0018四组18650型锂电池，其额定容量为2 Ah，且在室温24℃下进行老化测试实验[25]。充电阶段采用恒流-恒压充电方式，即先采用1.5 A的恒流充电至4.2 V，而后采用恒压充电直到充电电流到20 mA。放电阶段采用恒流放电方式，即2 A恒流放至2.7 V[26]。当电池容量降至初始容量的70%（即1.4 Ah）时视为失效。由于实验过程中包含不定期的静置环节，电池内部的活性物质得以重新分布，致使电池表现出显著的容量再生现象。如图1（a）所示，导致容量衰退曲线呈现出显著的容量再生现象和剧烈的局部非线性波动。选用马里兰大学CALCE中心的CS_35和CS_36电池，以验证模型的跨工况泛化能力。该系列的电池正极材料为钴酸锂（$LiCoO_2$），采用标准的恒流恒压充电方式，先采用0.5 C的电流充电至4.2 V，再以4.2 V恒压充电，直到充电电流降到0.05 A，除了特殊情况，电池的放电电流按1 C放电至2.7 V。如图1（b）所示，与NASA相比，CALCE的容量衰退轨迹较为平滑，局部噪声干扰较小，体现了电池的长期电化学老化规律。

1.2 健康因子选取

锂电池的老化是一个复杂的电化学演变过程，常伴随容量的衰减和内阻的增大，而且难以直接获取其内部退化状态。因此，常通过电池在充放电过



(a) NASA (b) CALCE

图1 锂电池容量衰退变化曲线

Fig.1 Lithium Battery Capacity Degradation Curves

程中的外部特性曲线来间接获取电池的健康状态信息。如图2所示，以B0005电池为例，为其在第1、5、60、100和160次循环中的充放电特性曲线变化规律。而随着充放电循环次数的增加，电池内部的活性锂离子发生损失和活性材料的消耗引起电池极化效应的加剧，从而使充放电特性曲线呈现出明显的单调变化趋势。因此，本研究从电压、电流和温度变化曲线中提取了5种间接健康因子。

如图2（a）所示，随着老化程度加深，电池内部极化阻抗增大，导致充电过程中端电压上升速率显著加快，曲线整体向左上方偏移。因此，本文提取充电阶段电压从3.9 V上升至4.1 V所需的时间间隔作为健康因子HF1。同时，如图2（b）所示，在CC-CV充电模式下，随着电池容量的衰减，恒流充电阶段能够维持的时间逐渐缩短，电池更早达到截止电压。因此，提取恒流充电阶段的持续时间作为健康因子HF2，该特征直接反映了电池当前的存储电荷能力。在放电过程中，如图2（c）所示，老化导致电压跌落速度加快，选取放电电压从4.0 V下降至3.9 V所经历的时间作为健康因子HF3，以表征电池放电能力的退化。随着电池老化，欧姆内阻和极化内阻均显著增加，导致充放电过程中的产热速率加快。如图2（d）和（e）所示，无论是充电还是放电阶段，电池表面的温度峰值均随着循环次数的增加而呈现上升趋势。因此，分别提取放电阶段和充电阶段的温度最大值，作为健康因子HF4和HF5，用于表征电池内部的热失控风险和阻抗演变特性。5种健康因子的名称如表1所示。

1.3 相关特性分析

输入特征的维度过低会导致关键老化信息缺失，引致模型欠拟合。而输入特征维度过高，则会增加计算复杂度并引入噪声，导致模型过拟合，降低泛化能力。因此，必须对所提取的健康因子（HF1-HF5）与电池容量之间的相关性进行定量评估，以筛选出最具表征能力的特征子集。考虑到电池退化过程包含线性衰退与非线性波动，单一的评价指标可能存在偏差。为此，本文同时引入皮尔逊相关系数（Pearson Correlation Coefficient, PCC）和斯皮尔曼等级相关系数（Spearman's Rank Correlation Coefficient, SCC）。其中，PCC用于衡量变量间的线性相关程度，SCC用于评估变量间的单调相关性。计算的公式如下：

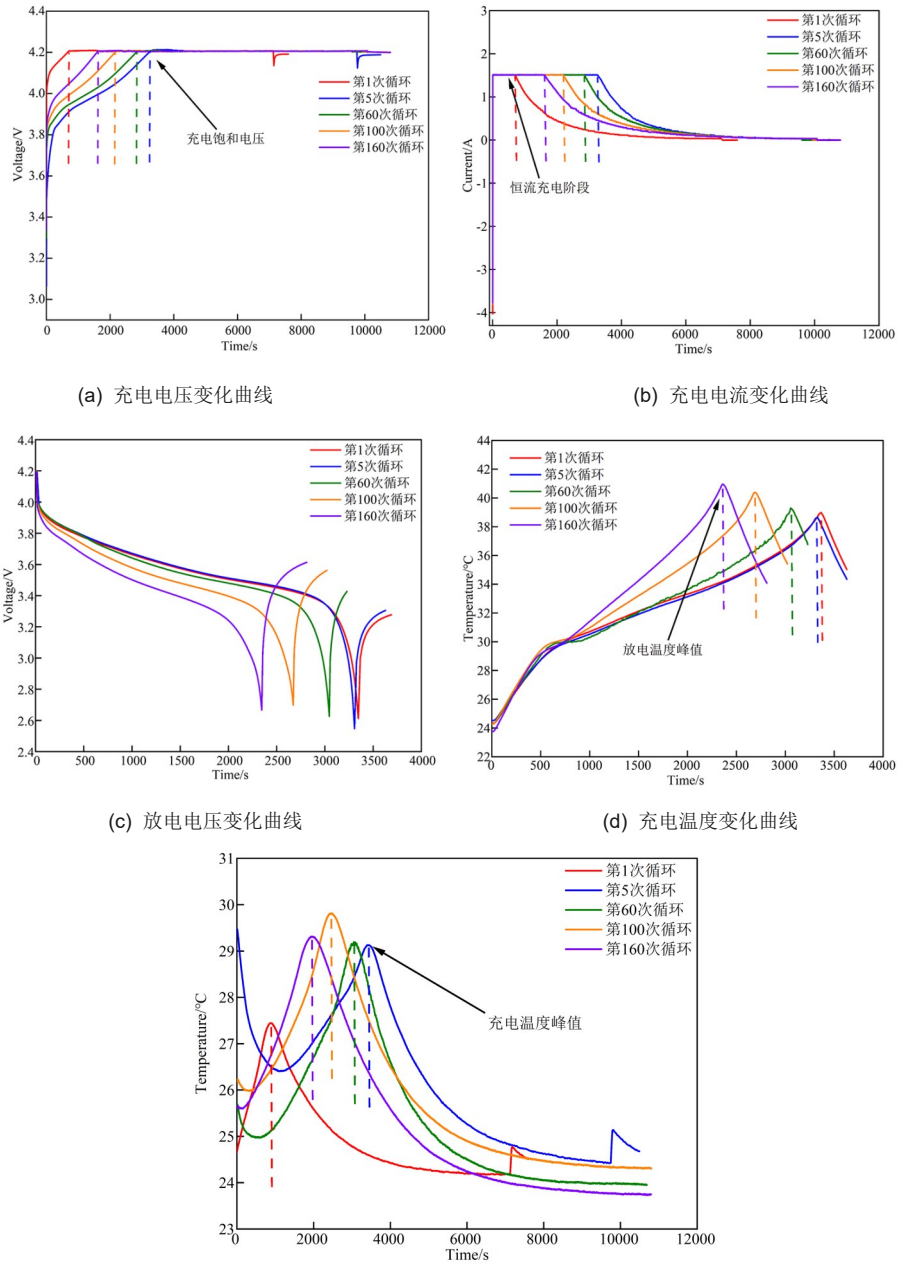
$$r = \frac{\sum\left(X_i - \overline{X}\right)\left(Y_i - \overline{Y}\right)}{\sqrt{\sum\left(X_i - \overline{X}\right)^2 \cdot \sum\left(Y_i - \overline{Y}\right)^2}} \tag{1}$$

$$\rho = 1 - \frac{6\sum d_i^2}{n\left(n^2 - 1\right)} \tag{2}$$

式中：X_i和Y_i分别为健康因子和电池容量的样本观测值；$\overline{X}$和$\overline{Y}$分别为健康因子和电池容量的样本均值；$d_i = R\left(X_i\right) - R\left(Y_i\right)$表示健康因子和电池容量的样本秩之差；$R\left(X_i\right)$和$R\left(Y_i\right)$分别表示健康因子和电池容量的样本秩次；n表示样本数量。相关系数r和ρ的取值范围均为[−1,1]，其绝对值越接近1，表明相关性越强；通常认为绝对值大于0.9为极强相关。

为了验证特征的有效性，分别对NASA数据集的B0005电池为例和CALCE数据集的CS_35电池为例进行了相关性分析。如图3所示。

如图3（a）和（b）所示，在B0005电池中，HF1，HF2和HF3呈现出极高的相关性。如表2所示，HF1、HF2和HF3的PCC值分别达到0.9946、0.9980和0.9714，SCC值也均在0.94以上，说明



(a) 充电电压变化曲线

(b) 充电电流变化曲线

(c) 放电电压变化曲线

(d) 充电温度变化曲线

(e) 放电温度变化曲线

图2 B0005电池充放电电流、电压和温度变化曲线

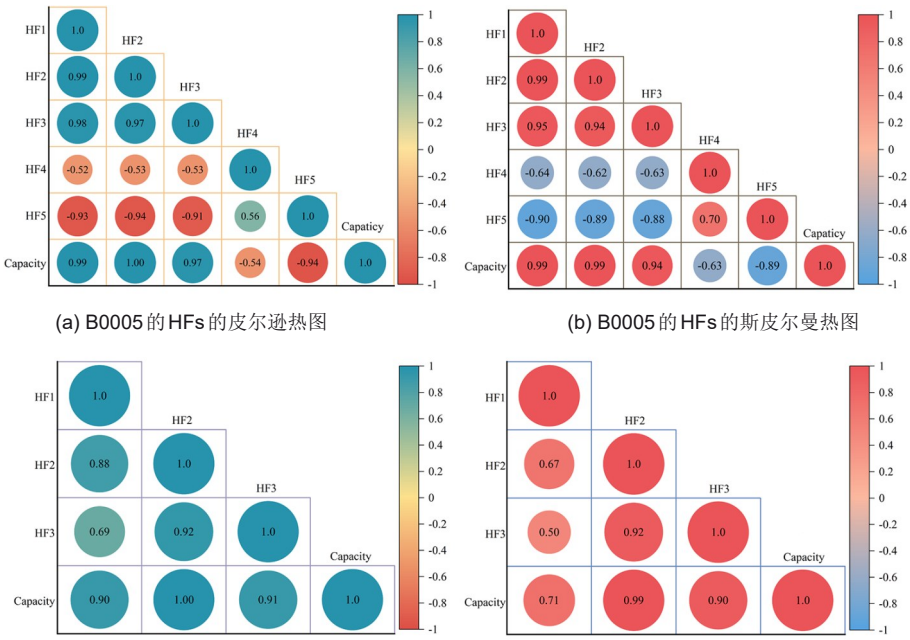
Fig. 2 B0005 Battery Charge and Discharge Current, Voltage, and Temperature Variation Curves

表1 锂电池的健康因子

Table 1 Health Factors of Lithium Batteries

序号	健康因子	名称
1	HF1	等压升充电时间
2	HF2	恒流充电时间
3	HF3	等压降放电时间
4	HF4	放电循环温度峰值
5	HF5	充电循环温度峰值

这三个特征可以精确的反映电池容量的衰退轨迹。相比之下，HF4和HF5的相关性较弱。如图3（c）和（d）所示，在CS_35电池中，HF1、HF2和HF3依然保持了极强的相关性，尤其是恒流充电时间HF2，其相关系数接近1。进一步说明HF1-HF3作为老化指标具有良好的跨工况鲁棒性，不依赖于具体的电池体系。因此，最终选取HF1、HF2和HF3作为RUL预测模型的输入特征。



(a) B0005的HFs的皮尔逊热图　　(b) B0005的HFs的斯皮尔曼热图

(c) CS_35的HFs的皮尔逊热图　　(d) CS_35的HFs的斯皮尔曼热图

图3　B0005电池和CS_35电池的相关性热图

Fig. 3　B0005 Battery and CS_35 Battery Correlation Heat Map

表2　B0005电池的HFs和电池容量的相关系数

Table 2　Correlation Coefficient Between HFs and Battery Capacity for B0005 Battery

相关性	HF1	HF2	HF3	HF4	HF5
Pearson	0.9946	0.9980	0.9714	-0.5381	-0.9405
Spearman	0.9911	0.9938	0.9449	-0.6349	-0.8944

2　RUL预测模型

2.1　模型总体架构

针对锂电池RUL预测中存在的局部容量再生与全局衰退趋势难以兼顾的问题，本文提出了一种基于GGWO优化的双流时空特征提取与交叉注意力融合模型。该模型不依赖于在线参数更新，而是通过物理网络与算法寻优的相互配合来实现对电池退化轨迹的映射。如图4所示，该模型采用并行处理架构，主要包含以下三个核心模块，首先，利用TCN网络提取健康因子序列中映射的局部退化波动特征，同时利用Transformer编码器提取长时序特征。其次，通过交叉注意力融合模块计算TCN特征与Transformer特征之间的注意力权重，实现局部波动特征与时序特征的增强融合。最终，通过改进的灰狼算法GGWO实现对TCN-Transformer-crossAttention模型的超参数进行全局寻优，以便于进一步提高模型的预测精度。

2.2　TCN-Transformer-crossAttention预测模型

2.2.1　时间卷积网络（TCN）

时间卷积网络（TCN）是由白邵杰等人提出的一种基于因果卷积和空洞卷积的特化网络结构[27]。该网络通过因果卷积确保t时刻输出仅依赖于当前及历史输入，严格遵守序列预测的时序约束。利用空洞卷积引入膨胀系数d，在不增加参数量的前提下实现感受野的指数级扩展，其卷积运算定义为：

$$F(s)=(X*_d f)(s)=\sum_{i=0}^{k-1} f(i)\cdot X_{s-d\cdot i} \tag{3}$$

同时结合残差连接机制有效缓解深层网络的梯度消失问题。在本模型中，TCN被专门用于精准健康因子序列（HFs）中映射的局部退化波动特征的提取，挖掘短时高频的老化信息。

2.2.2　Transformer网络

Transformer网络是由Vaswani 等人于2017年提出的一种基于注意力机制的深度神经网络架构，最初用于解决自然语言处理任务，随后在时间序列预测领域表现出卓越的性能[28]。Transformer摒弃了循环和卷积操作，通过多头自注意力机制并行处理输入序列。自注意力机制通过计算Q与K的点积来衡量不同时刻特征的相关性，再经过Softmax归

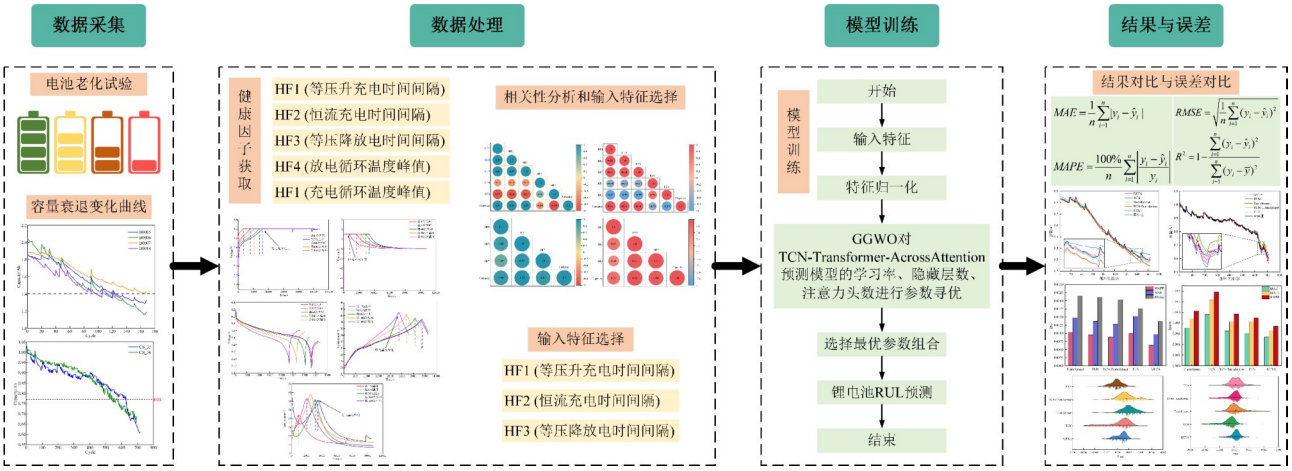


图4 RUL预测框架

Fig. 4 RUL Prediction Framework

一化后对V进行加权求和，其计算公式定义为：

$$Attention(Q,K,V) = soft\max\left(\frac{QK^T}{\sqrt{d_k}}\right)V \tag{4}$$

式中，d_k为缩放因子，用于防止点积数值过大导致的梯度消失。此外，由于Transformer本身不具备处理序列顺序的能力，网络引入了位置编码，将绝对或相对位置信息注入输入向量，从而确保模型能够感知时间序列的时序逻辑。

2.2.3 交叉注意力融合机制

现有的混合神经网络模型在处理多特征时，大多采用简单的特征拼接策略。这种静态的融合方式忽略了不同特征在电池不同退化阶段的重要性差异，难以实现时空特征的深层交互。为了解决这一问题，本文设计了交叉注意力融合模块，建立局部波动特征与全局时序特征之间的动态语义映射。如图5所示。

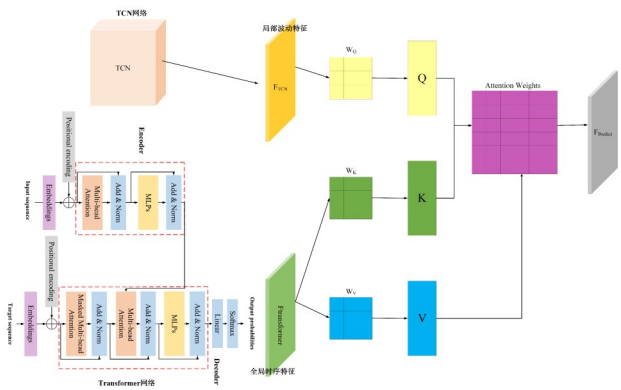


图5 TCN-Transformer-crossAttention结构图

Fig. 5 TCN-Transformer-crossAttention Architecture Diagram

2.2.4 融合淘金算子的改进灰狼优化算法

由于传统的灰狼优化算法在面对高维非线性空间时极易陷入局部最优，易出现早熟收敛现象。为此，本文设计了融合淘金算子的改进灰狼优化算法（Gold-panning-based Grey Wolf Optimization, GGWO）来实现模型超参数的全局寻优。其算法流程框图如图6所示。GGWO的改进策略主要体现在三个方面，第一，在种群初始化阶段引入Tent混沌映射，利用其遍历性使初始解在搜索空间内均匀分布，提高了种群的初始多样性；第二，设计了余弦非线性收敛因子替代原有的线性递减因子，使算法在前期能够大步长全局探索，在后期能够小步长精确开发，平衡了全局探索与局部开发的矛盾；第三，在每次迭代后期引入淘金迁移算子，对处于停滞状态的个体施加强制逃逸动能，赋予种群跳出局部极值陷阱的能力。

为了验证GGWO算法的寻优性能，选取Sphere（单峰）、Ackley（多峰）及Rastrigin（极多峰）基准函数开展对比实验。如图7(a)与(b)所示，得益于Tent混沌映射对初始种群遍历性的增强以及余弦非线性收敛因子的动态调节，GGWO在单峰及多峰函数上展现出卓越的收敛速度与挖掘精度。特别是在表征局部开发能力的Sphere函数上，GGWO呈现出无停滞的线性收敛特性，最终误差远超标准GWO[29]及PSO[30]，表明改进策略有效消除了算法在搜索后期的震荡现象，实现了对全局最优解的有效逼近。

在面对充斥密集局部极值陷阱的Rastrigin函数

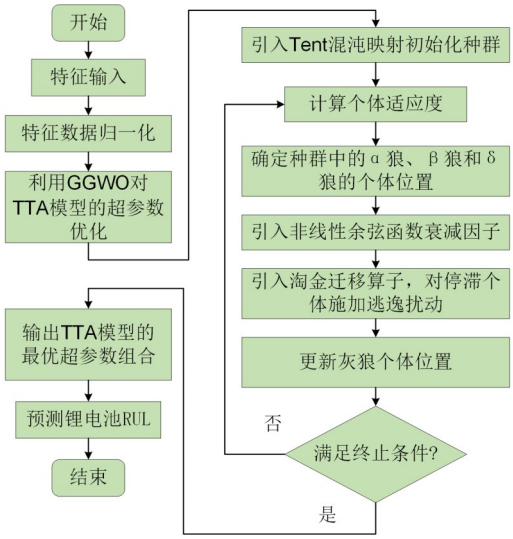


图6 GGWO算法流程图

Fig. 6 Flowchart of GGWO algorithm

时，如图7(c)，传统PSO与GWO算法均陷入严重的早熟收敛，而GGWO呈现出显著的下降特征，且在迭代后期仍能实现适应度值的垂直骤降。说明引入的融合淘金迁移算子与随机扰动机制赋予了种群在停滞状态下的强制逃逸动能，使其能够有效跳出局部最优。总之，GGWO在收敛精度、速度及鲁棒性上的综合优势，能够为后续RUL预测模型中高维超参数的精准寻优提供良好的参数基础。

3 实验结果验证分析

3.1 实验环境与数据划分

本实验硬件环境采用Intel Core i5-14600KF CPU和NVIDIA GeForce RTX 4060 GPU进行加速计算。考虑到电池老化数据的强时序依赖性，为避免信息泄露，本文采用时序隔离策略划分数据。数据集依序按7:3划分为训练集与测试集；其中，前70%的训练数据进一步按7:3划分为纯训练集与内部验证集。内部验证集专用于监控过拟合，并作为GGWO算法寻优超参数的适应度评估基准。后30%的测试集在训练与寻优阶段被严格物理隔离，仅用于模型最终泛化性能的盲测评估。输入数据采用滑动窗口法，滑动窗口大小设置为4，滑动步长设置为1。该较小窗口的设定旨在避免长序列带来的平滑效应，从而保留局部容量再生特征。同时，连续4个循环的状态变化已足以提供短期的退化梯度信息，支撑Transformer分支通过局部梯度演化映射出全局的退化趋势，契合实车BMS计算资源受限且难以获取完整寿命历史数据的端到端部署需求。批量大小为16，优化器选用Adam，最大迭代轮数为300，Dropout比率为0.1。为避免全局参数搜索导致的维度爆炸与计算开销，本文采取“固定结构参数、寻优敏感参数”的降维策略。基于经验与局部网格搜索，TCN模块的基础参数预设为：卷积核大小k=3，膨胀因子d={1, 2, 4}，网络层数为3层，Dropout比率设为0.1。除此之外，利用GGWO算法对TCN-Transformer-crossAttention模型中三个超参数进行寻优，分别为模型的学习率、Transformer隐藏层维度和多头注意力头数。三个参数的搜索空间分别约束为0.0001~0.1、16~128和1~16，以确保模型在复杂解空间中收敛至全局最优配置。GGWO种群规模设为20，最大迭代次数设为20。针对模型超参数寻优过程，GWO与GGWO在TTA模型寻优时适应度收敛对比曲线如图8所示。

3.2 评价指标

本研究的RUL预测任务，是以获取电池全生

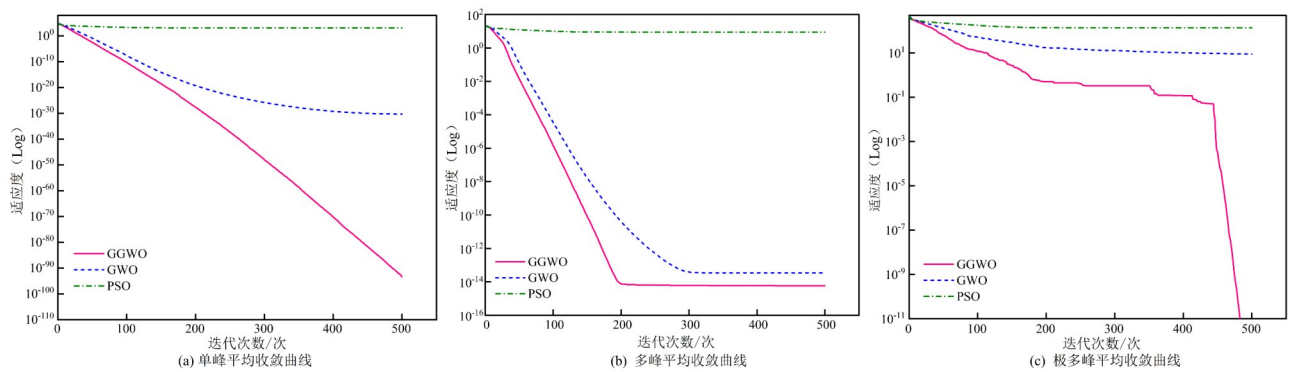


图7 不同算法在典型基准函数上的寻优收敛曲线对比

Fig. 7 Comparison of Convergence Curves for Different Algorithms on Typical Benchmark Functions

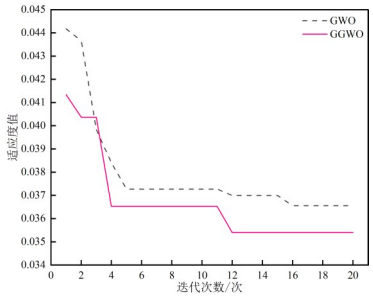


图8 GWO与GGWO在TTA模型寻优时适应度收敛对比曲线

Fig. 8 Comparison of fitness convergence curves between GWO and GGWO in TTA model optimization

命周期高精度容量退化轨迹为核心前置任务。在实际工程应用中，通过判定模型所预测的容量衰退曲线何时下穿失效阈值（如70%额定容量），即可推算出电池的RUL。因此，本文选取了四种通用的统计学评价指标：均方根误差（Root Mean Square Error，RMSE）、平均绝对误差（Mean Absolute Error，MAE）、平均绝对百分比误差（Mean Absolute Percentage Error, MAPE）以及决定系数（R^2）。其中，RMSE可以有效衡量模型的鲁棒性与稳定性，MAE是反映了预测误差的实际平均水平，直观体现预测精度，MAPE是消除了数据量纲的影响，便于评估模型在不同容量量级下的相对误差，R^2则表征模型对电池全寿命周期容量衰退趋势的拟合优度，其值越接近1表明拟合效果越好[31]。各指标的计算公式如下：

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i)^2} \tag{5}$$

$$MAE = \frac{1}{N}\sum_{i=1}^{N}|y_i - \hat{y}_i| \tag{6}$$

$$MAPE = \frac{1}{N}\sum_{i=1}^{N}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \times 100\% \tag{7}$$

$$R^2 = 1 - \frac{\sum_{i=1}^{N}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{N}(y_i - \bar{y})^2} \tag{8}$$

式中，N为样本数量，y_i为容量的真实观测值，$\hat{y}_i$为模型预测值，$\bar{y}$为真实值的均值。

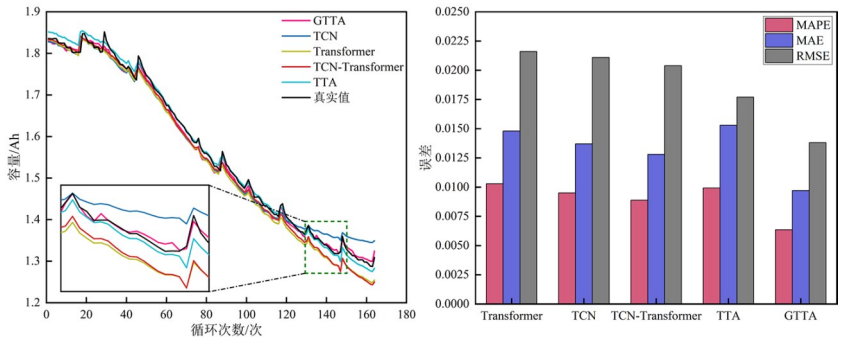
3.3 基于NASA数据集的模型精确性验证与消融实验分析

为了验证所提GTTA模型（即GWO-TCN-Transformer-crossAttention）在处理具有剧烈局部波动特征时的鲁棒性和精确性，本文选用NASA数据集中的B0005、B0006、B0007和B0018四组电池进行实验。将Transformer、TCN、TCN-Transformer和TTA四种模型与GTTA模型的预测性能进行对比。

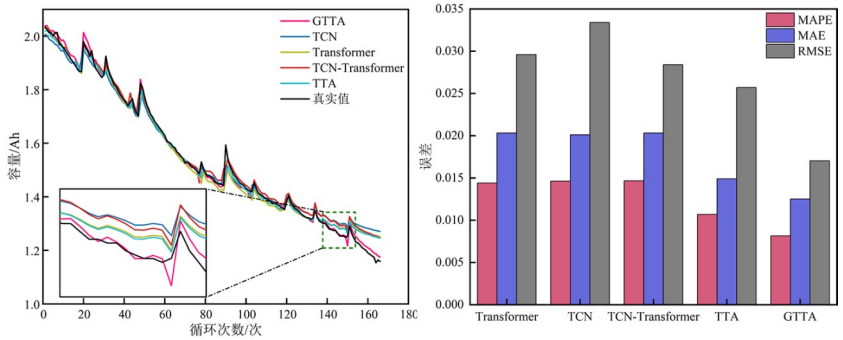
如图9所示，Transformer模型由于自注意力机制可以较好地拟合容量的衰退趋势，但对局部容量跳变的响应存在显著滞后。TCN模型对高频波动敏感，但在长期预测中易受噪声干扰导致趋势发散。相比之下，GTTA模型表现出不错的动态捕捉能力。在局部放大图所示的剧烈波动区间，GTTA模型可以很好地响应容量的瞬时回升变化，且在测试集的失效阶段可以较好地拟合电池RUL衰减。直观地证明了模型内部的交叉注意力机制成功实现了局部波动特征和全局趋势特征的动态校准，有效克服了传统模型在复杂工况下的适应性难题。

如表3至表6所示，在融合策略层面，引入交叉注意力机制的TTA模型在整体误差趋势上优于简单拼接的TCN-Transformer模型，但部分指标（如B0005的MAE）仍存在波动。以B0006电池为例，TTA模型的RMSE为0.0257，较拼接模型的0.0284降低了约9.5%。这说明动态融合优于静态拼接，crossAttention机制赋予了模型自适应关注的能力，使其能够根据当前的局部波动状态，自动调整对全局历史信息的权重分配，从而在物理层面解决了特征割裂的问题。其次，在算法优化层面，对TTA模型因参数空间复杂而导致的局部指标波动问题，对比TTA与GTTA可知，经过GGWO全局寻优后，模型的预测精度实现了较好的提升。在B0005电池上，GTTA模型的RMSE进一步降至0.0138，R^2提升至0.9947。这证实了改进灰狼算法凭借Tent混沌映射及淘金迁移算子，成功搜索到了适配该高维非线性模型的高质量的超参数组合，有效激发了深度网络的拟合潜力。

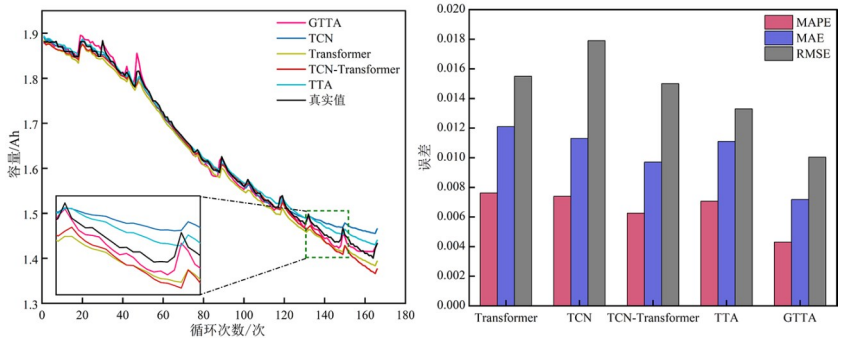
如图10所示，从云的部分来看，GTTA模型的误差表现出显著的高峰度、窄截尾的特征，其密度峰值极高且严格中心化于零误差线。这表明模型的预测残差高度收敛，绝大多数样本点的预测偏差较小。相比之下，TCN和Transformer模型的密度曲线较为扁平且宽阔，表现出明显的厚尾特征，也就说明这两个模型在容量剧烈跳变点容易产生较大的离群误差，抗干扰能力较弱。从雨的部分来看，GTTA模型的箱体宽度最为狭窄，且中位数点几乎



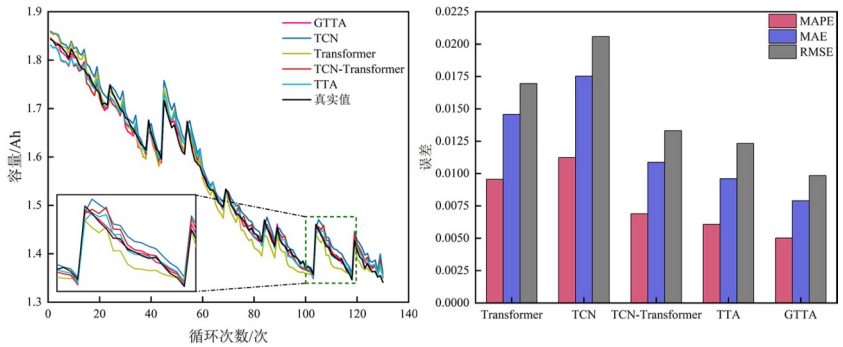
(a) B0005



(b) B0006



(c) B0007



(d) B0018

图9 NASA四组电池的预测结果对比图和误差对比图

Fig. 9 Comparison Chart of Prediction Results and Error Comparison Chart for NASA's Four Battery Sets

与零刻度线重合，表现出较好的无偏性与一致性。这也说明其不存在系统性的高估或低估倾向，也说明其在处理非平稳锂电池退化数据时的较好鲁棒性。

表3 B0005电池的各模型预测误差

Table 3 Prediction Errors for Different Models of B0005 Battery

模型名称	MAE	MAPE	RMSE	R^2
TCN	0.0137	0.0095	0.0211	0.9876
Transformer	0.0148	0.0103	0.0216	0.9870
TCN-Transformer	0.0128	0.0089	0.0204	0.9884
TTA	0.0153	0.0096	0.0177	0.9912
GTTA	0.0097	0.0064	0.0138	0.9947

表4 B0006电池的各模型预测误差

Table 4 Prediction Errors for Different Models of B0006 Battery

模型名称	MAE	MAPE	RMSE	R2
TCN	0.0201	0.0146	0.0334	0.9818
Transformer	0.0204	0.0144	0.0296	0.9857
TCN-Transformer	0.0203	0.0147	0.0284	0.9868
TTA	0.0149	0.0107	0.0257	0.9892
GTTA	0.0125	0.0081	0.0170	0.9953

表5 B0007电池的各模型预测误差

Table 5 Prediction Errors for Different Models of B0007 Battery

模型名称	MAE	MAPE	RMSE	R^2
TCN	0.0113	0.0074	0.0179	0.9875
Transformer	0.0121	0.0076	0.0155	0.9905
TCN-Transformer	0.0097	0.0063	0.0150	0.9912
TTA	0.0111	0.0071	0.0133	0.9920
GTTA	0.0072	0.0043	0.0100	0.9961

表6 B0018电池的各模型预测误差

Table 6 Prediction Errors for Different Models of B0018 Battery

模型名称	MAE	MAPE	RMSE	R^2
TCN	0.0175	0.0112	0.0206	0.9817
Transformer	0.0146	0.0095	0.0169	0.9876
TCN-Transformer	0.0109	0.0069	0.0133	0.9923
TTA	0.0096	0.0061	0.0123	0.9935
GTTA	0.0079	0.0050	0.0098	0.9958

3.4 基于CALCE数据集的模型泛化能力验证

为了进一步评估模型的泛化能力，采用CALCE数据集的CS_35和CS_36电池的衰退数据进行测试。如图11所示，TCN模型由于过度关注局部卷积特征，在平滑曲线上反而容易受到微小测量噪声的干扰，致使预测轨迹出现不必要的抖动；而Transformer模型虽能拟合大致趋势，但在退化后期的非线性加速阶段跟踪能力不足。而GTTA模型却表现出较好的适应性，对于早期的线性衰退和末期的非线性加速，预测曲线可以与真实值高度贴合，且在误差柱状图中保持了最低的RMSE水平。GTTA模型内部的交叉注意力机制具备工况适应性。在平滑工况下，注意力权重自动向Transformer分支提取的全局趋势特征倾斜，从而有效抑制了局部噪声对预测精度的负面影响。

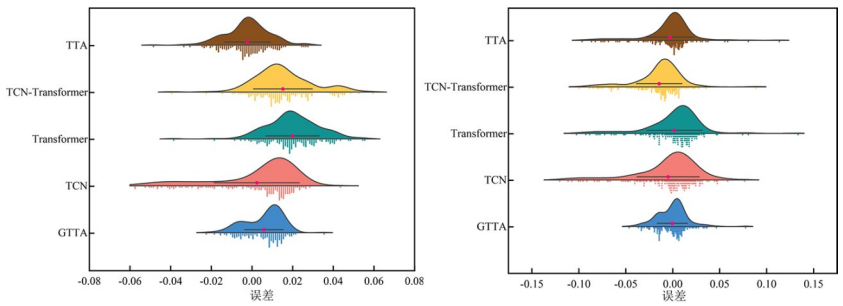
如表7至表8所示，在训练数据分布差异巨大的情况下，GTTA模型依然保持了稳健的预测性能。以CS_35电池为例，TCN模型的RMSE为0.0138，R^2为0.9759，表现弱于Transformer模型，这说明了卷积网络在处理长程平滑序列时的局限性。然而，GTTA模型通过双流特征的动态互补，将RMSE进一步压低至0.0074，MAE仅为0.0054，R^2高达0.9930。这一结果优于TCN-Transformer，也就说明了静态特征堆叠无法充分挖掘异构特征的潜在价值，而crossAttention机制通过建立局部与全局特征的映射，实现了对不同退化模式的解耦与重构，赋予了模型较强的泛化能力。

如图12所示，从云层分析，GTTA模型呈现出典型的尖峰态分布，其概率密度峰值高于对比模型，且分布区间收敛于零误差轴。即该模型对绝大多数样本的预测偏差被控制在较小范围内，具备较高的置信度。反观TCN与Transformer模型，其密度曲线相对低平且向两侧延展，反映出较大的误差离散度，难以有效抑制容量突变点产生的离群值。从雨分析，GTTA模型的四分位距（IQR）最为紧凑，且中位数标记精准定位在零刻度线上，说明了模型在全寿命周期预测中保持了较好的零均值特性，未出现系统性偏差。进一步说明GTTA模型在应对非平稳时序数据时具有较好的稳定性与鲁棒性。

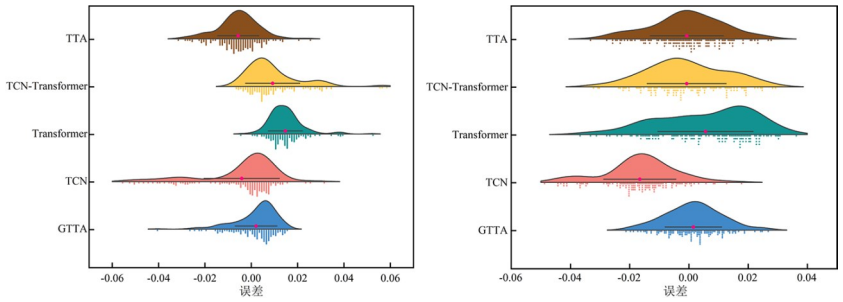
3.5 不同模型结构与算法对比实验

本节分别选取NASA数据集中的B0005电池与CALCE数据集中的CS_35电池进行不同模型结构的对比实验。以CNN-LSTM、TTSA（即TCN-Transformer-SelfAttention）、GWO-TTA和PSO-TTA与本文模型GTTA进行交叉注意力机制和不同优化算法的对比验证。

从图13的预测曲线图来看，GTTA模型在两个



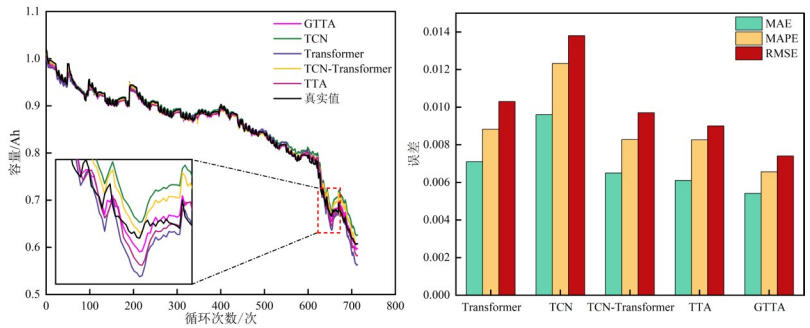
(a) B0005 (b) B0006



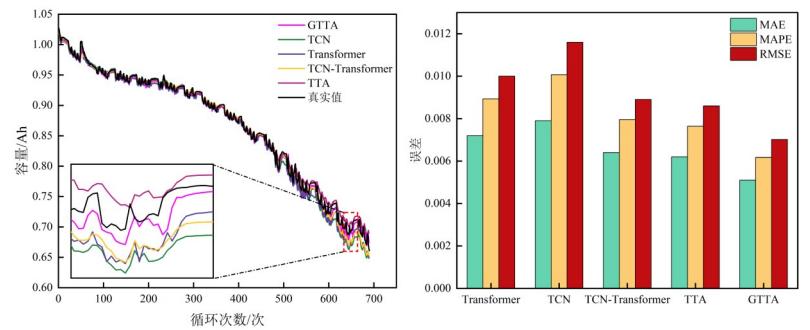
(c) B0007 (d) B0018

图10 NASA四组电池的误差云雨图

Fig. 10 NASA's Four-Set Battery Error Cloud-Rain Diagram



(a) CS_35



(b) CS_36

图11 CALCE的CS_35和CS_36的预测结果对比图和误差对比图

Fig. 11 Comparison of Prediction Results and Error Comparison for CALCE's CS_35 and CS_36

数据集的整个生命周期预测中，其预测曲线最紧密地贴合真实值曲线；在局部放大的容量再生波动区间，GTTA的拟合能力比其他基线模型更强。从误差对比图和表9来看，对于B0005电池，GTTA的MAE为0.0097，MAPE为0.0064，RMSE为0.0138。相较于传统基础模型CNN-LSTM，其

表7 CS_35电池的各模型预测误差

Table 7 Prediction Errors for Different Models of CS_35 Battery

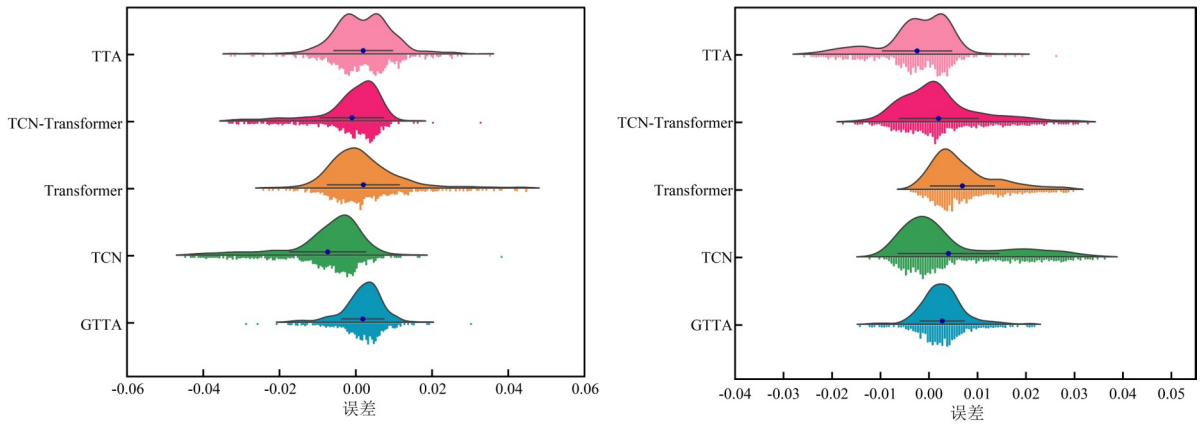
模型名称	MAE	MAPE	RMSE	R^2
TCN	0.0096	0.0123	0.0138	0.9759
Transformer	0.0071	0.0088	0.0103	0.9865
TCN-Transformer	0.0065	0.0083	0.0097	0.9880
TTA	0.0061	0.0083	0.0090	0.9897
GTTA	0.0054	0.0066	0.0074	0.9930

表8 CS_36电池的各模型预测误差

Table 8 Prediction Errors for Different Models of CS_36 Battery

模型名称	MAE	MAPE	RMSE	R^2
TCN	0.0079	0.0101	0.0116	0.9848
Transformer	0.0072	0.0089	0.0100	0.9888
TCN-Transformer	0.0064	0.0080	0.0089	0.9909
TTA	0.0062	0.0076	0.0086	0.9917
GTTA	0.0051	0.0062	0.0070	0.9944

RMSE 误差降低了约54.3%；与GWO-TTA相比，其RMSE依然下降了0.0027。对于CS_35电池，GTTA模型的MAE为0.0054，MAPE为0.0066，RMSE为0.0074。对比CNN-LSTM模型，GTTA的均方根误差降低了约67.4%；对比GWO-TTA，RMSE缩减了0.0028。



(a) CS_35 (b) CS_36

图12 CS_35和CS_36电池的误差云雨图

Fig. 12 Error Cloud Diagram for CS_35 and CS_36 Batteries

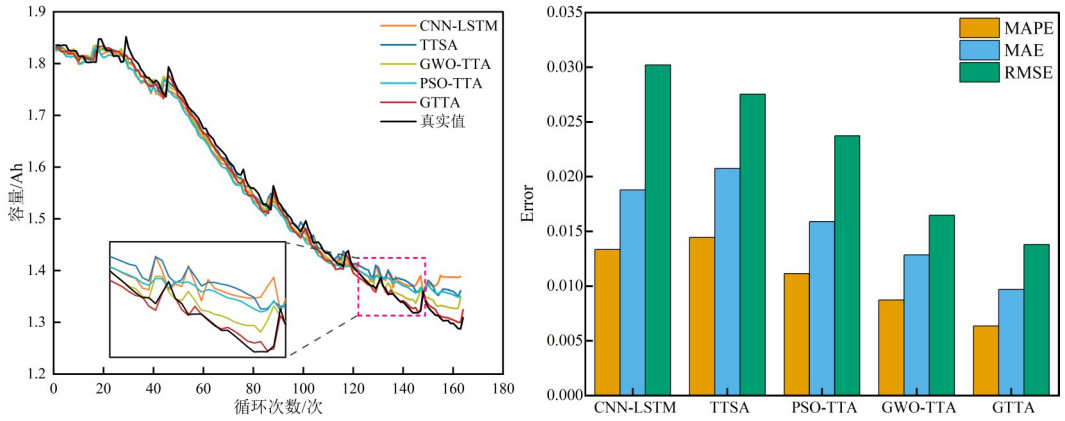
3.6 基于输入噪声扰动的模型鲁棒性验证

在实际的电池管理系统中，因传感器精度和电磁干扰，采集到的电压、电流和温度等原始信号往往包含明显的测量噪声，这直接影响提取出的HFs的质量。为了验证所提GTTA模型在真实工程环境下的抗噪鲁棒性，本文对测试集的输入特征叠加不同等级的噪声进行扰动实验。选取NASA数据集中的B0005电池测试集数据，向其输入的健康因子序列中人为叠加高斯白噪声。通过控制信号与噪声的功率比，分别设置信噪比（Signal-to-Noise Ratio, SNR）为30 dB和20 dB。将GTTA模型与未引入动态权重的TCN-Transformer拼接模型在带噪数据上进行对比，预测误差结果如表10所示。

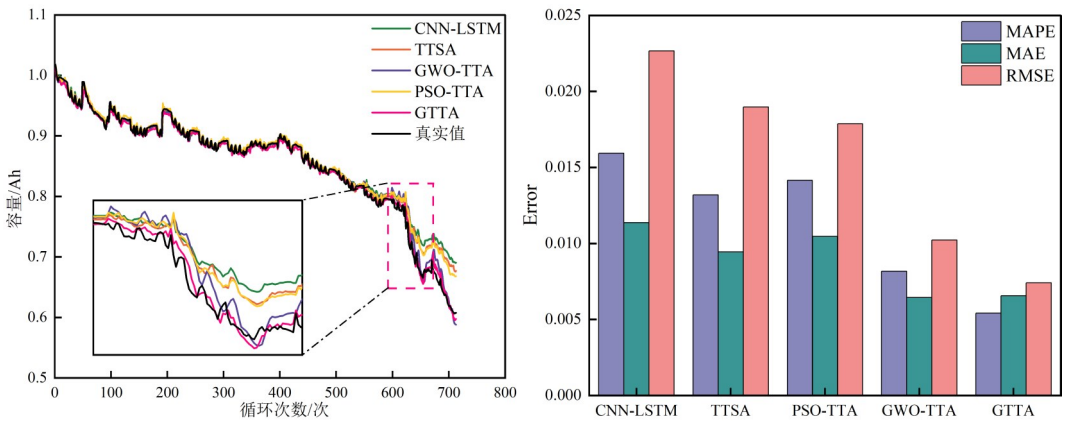
由表10可知，随着输入端高斯噪声的引入和噪声强度的增加，未引入动态权重的TCN-Transformer模型的各项误差指标呈现出恶化的趋势。例如，当处于SNR=20 dB时，其RMSE相比无噪环境提高了约47.1%，MAE则增加了约85.9%。这说明传统的静态特征拼接方式容易接收局部高频噪声并将其放大，导致预测轨迹发生偏离。而GTTA模型在同等强度的严重噪声干扰下，GTTA的RMSE的增幅仅为7.2%，各项误差指标保持在较低的水平。实验表明，在健康因子序列受到高斯噪声干扰时，GTTA模型的误差增幅小于静态拼接的TCN-Transformer模型。这说明引入crossAttention机制后，模型能够调节不同特征源的交互状态，使其对输入健康因子的噪声扰动具有较强的容错能力和鲁棒性。

3.7 不同比例的数据集划分的敏感性分析

为验证GTTA模型对不同比例的训练样本的依赖程度和在小样本条件下的泛化性能，对NASA的B0005电池数据集进行了不同比例的划分并实验。



(a) B0005



(b) CS_35

图13 B0005与CS_35电池预测结果对比图和误差对比图

Fig. 13 Comparison Chart of B0005 and CS_35 Battery Prediction Results and Error Comparison Chart

表9 B0005与CS_35电池的不同模型结构的对比误差

Table 9 Comparison of error in model structures between B0005 and CS_35

	B0005			CS_35		
模型名称	MAE	MAPE	RMSE	MAE	MAPE	RMSE
CNN-LSTM	0.0188	0.0133	0.0302	0.0114	0.0159	0.0227
TTSA	0.0207	0.0145	0.0275	0.0094	0.0132	0.0190
PSO-TTA	0.0159	0.0111	0.0237	0.0105	0.0141	0.0179
GWO-TTA	0.0128	0.0087	0.0165	0.0082	0.0082	0.0102
GTTA	0.0097	0.0064	0.0138	0.0054	0.0066	0.0074

表10 B0005电池在不同高斯噪声干扰下的预测误差对比

Table 10 Prediction errors of B0005 battery under different Gaussian noise interferences

模型名称	噪声环境	MAE	MAPE	RMSE
TCN-Transformer	原始无噪	0.0128	0.0089	0.0204
	SNR=30dB	0.0234	0.0176	0.0290
	SNR=20dB	0.0238	0.0179	0.0300
GTTA	原始无噪	0.0097	0.0064	0.0138
	SNR=30dB	0.0125	0.0094	0.0147
	SNR=20dB	0.0129	0.0096	0.0148

即分别将训练集数据占比设置为50%、70%和80%，并在相同超参数配置下对模型进行重新训练与评估。不同数据规模下的预测误差对比结果如表11和其误差图14所示。

由表11和图14可知，训练集比例从50%增加至70%，GTTA的各项预测误差呈轻微下降趋势。然而，当比例提升至80%时，其RMSE指标高于

表11 B0005电池在不同训练集划分比例下的预测误差对比

Table 11 Prediction errors of B0005 battery under different training set division ratios

模型名称	训练集比例	MAE	MAPE	RMSE
B0005	50%	0.0183	0.0128	0.0241
	70%	**0.0097**	**0.0064**	**0.0138**
	80%	0.0095	0.0061	0.0144

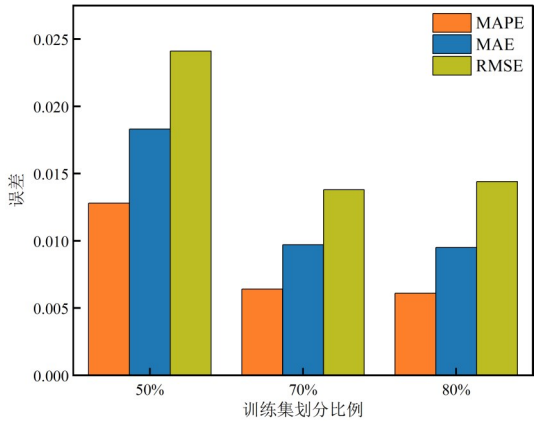


图14　B0005电池在不同比例的训练集时GTTA的预测误差

Fig. 14　GTTA prediction error for the B0005 battery with different training set ratios

70%工况。这是由于电池在生命周期末期的老化轨迹会伴随高度非线性的容量跳水与内部极化噪声。过多的末期波动数据参与训练，反而会干扰模型对全局衰退主趋势的拟合，导致泛化误差小幅震荡。因此，考虑到工程实用性与计算成本的平衡，本文在主要对比实验中采用70%的划分比例是合理的。

4　结　论

针对锂电池剩余使用寿命预测中存在的局部容量再生和全局长期衰退特征难以兼顾，以及模型的超参数寻优困难等问题，本文提出了一种基于改进灰狼优化算法的双流时空特征提取和交叉注意力融合的锂电池RUL预测方法，即GTTA。通过理论性建模和多数据集对比实验，得出以下结论：

（1）双流异构架构实现了时空特征的深度解耦。实验表明，利用TCN的因果膨胀卷积能够敏锐捕捉健康因子序列中映射的局部退化波动特征，而Transformer的自注意力机制则能准确建模健康因子序列中映射的全寿命周期的长程衰退趋势。从模型结构上克服了单一网络在局部敏感度与全局视野之间的固有矛盾。

（2）交叉注意力机制有效解决了特征融合层面特征割裂问题。crossAttention机制赋予了模型动态关注的能力。在NASA数据集的剧烈波动区间，模型能够自动增加对局部特征的权重分配。在CALCE数据集的平稳衰退期，则侧重于全局趋势。这种动态加权机制显著提升了模型在非平稳工况下的鲁棒性。

（3）融合淘金算子的GGWO算法突破了参数寻优瓶颈。通过引入Tent混沌映射初始化和非线性收敛因子，并结合淘金迁移算子重构位置更新策略，改进算法在保持全局搜索能力的同时提升了收敛精度，成功实现了对高维非线性模型超参数的高效配置。

（4）模型在面对不同化学体系与老化轨迹的数据集测试时，展现出了稳健的特征适应性与鲁棒性。在NASA和CALCE数据集上，GTTA模型的预测精度优于CNN-LSTM、TCN-Transformer等混合模型，验证了所提双流架构与离线全局策略的有效性。此外，受限于电池材料与充放电协议带来的物理域分布差异，当前模型在未经微调的跨数据集直接迁移预测中仍存在一定局限。未来研究将引入域适应与迁移学习机制，以进一步攻克跨域复杂工况下的电池SOH与RUL联合预测难题。

参 考 文 献

[1] 吴青峰, 杨艺涛, 刘立群, 等. 基于 GA-SA-BP 神经网络的锂电池健康状态估算方法[J]. 电力系统保护与控制, 2024, 52(19): 74-84.
WU Q F, YANG Y T, LIU L Q, et al. Estimation Method for Lithium Battery Health Status Based on GA-SA-BP Neural Network[J]. Protection and Control of Electric Systems, 2024, 52(19): 74-84.

[2] 郭喜峰, 王凯泽, 单丹, 等. 多角度基于CEEMDAN-CNN-BiLSTM模型的锂离子电池RUL预测[J]. 太阳能学报,2024,45(07):181-189.
GUO X F, WANG K Z, SHAN D, et al. Multi-Angle RUL Prediction of Lithium-ion Batteries Based on the CEEMDAN-CNN-BiLSTM Model [J]. Chinese Journal of Solar Energy, 2024, 45(07): 181-189.

[3] 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.
YIN J, LIU B, SUN G B, et al. Residual Life Prediction of Lithium-ion Batteries Based on Transfer Learning and Noise-Reducing Autoencoder-Long Short-Term Memory [J]. Transactions of the Chinese Institute of Electrical Engineers, 2024, 39(1): 289-302.

[4] Feng M G, YI B L, XING X J, et al. A review on state of health estimations and remaining useful life prognostics of lithium-ion batteries [J]. Measurement, 2021, (prepublish):109057-.

[5] 刘斌, 吉春霖, 曹丽君, 等. 基于自适应噪声完全集合经验模态分解与 BiLSTM-Transformer 的锂离子电池剩余使用寿命预测[J]. 电力系统保护与控制, 2024, 52(15): 167-177.
LIU B, JI C L, CAO L J, et al. Residual Life Prediction of Lithium-ion Batteries Based on Adaptive Noise Complete Set Empirical Mode Decomposition and BiLSTM-Transformer [J]. Protection and Control of Electric Systems, 2024, 52(15): 167-177

[6] 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(03):1182-1195.

XIONG Q, DI Z G, JI S C. Review of Research Progress on Health Status Estimation and Lifespan Prediction of Lithium-ion Batteries [J]. High Voltage Technology, 2024, 50(03): 1182-1195.

[7] 刘勇, 于怀汶, 刘大鹏, 等. 基于 ABC-LSTM 模型的锂离子电池剩余使用寿命预测[J]. 储能科学与技术, 2025, 14(1): 331.
LIU Y, YU H W, LIU D P, et al. Remaining useful life prediction of lithium-ion batteries based on the ABC-LSTM model [J]. Energy Storage Science and Technology, 2025, 14(1): 331.

[8] 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: 9017-17.
LI Y S, KAN H D, GUO Z N, et al. Residual Life Prediction of Lithium-ion Batteries Based on Data Preprocessing and VMD-LSTM-GPR [J]. Transactions of the Chinese Institute of Electrical Engineers, 2024: 9017-17

[9] 邹红波, 柴延辉, 杨钦贺, 等. 基于混合 ISSA-LSTM 的锂离子电池剩余使用寿命预测[J]. 电力系统保护与控制, 2023, 51(19): 21-31.
ZOU H B, CHAI Y H, YANG Q H, et al. Residual Life Prediction of Lithium-ion Batteries Based on Hybrid ISSA-LSTM [J]. Protection and Control of Electric Systems, 2023, 51(19): 21-31

[10] SCHIMPE M, KUEPACH V E M, Naumann M, et al. Comprehensive Modeling of Temperature-Dependent Degradation Mechanisms in Lithium Iron Phosphate Batteries[J]. ECS Transactions, 2017, 80(10): 147-170.

[11] SADABADI K K, JIN X, RIZZONI G. Prediction of remaining useful life for a composite electrode lithium-ion battery cell using an electrochemical model to estimate the state of health[J]. Journal of Power Sources, 2021, 481: 228861.

[12] LIU Z, DANG X, JING B. A Novel Open Circuit Voltage Based State of Charge Estimation for Lithium-Ion Battery by Multi-Innovation Kalman Filter[J]. IEEE Access,2019,749432-49447.

[13] 焦自权, 范兴明, 张鑫, 等. 基于改进粒子滤波算法的锂离子电池状态跟踪与剩余使用寿命预测方法[J]. 电工技术学报, 2020, 35(18): 3979-3994.
JIAO Z Q, FAN X M, ZHANG X, et al. Method for Tracking the State of Lithium-ion Batteries and Predicting Their Remaining Service Life Based on an Improved Particle Filter Algorithm [J]. Transactions of the Chinese Institute of Electrical Engineering, 2020, 35(18): 3979-3994

[14] 王萍, 张吉昂, 程泽. 基于最小二乘支持向量机误差补偿模型的锂离子电池健康状态估计方法[J]. 电网技术, 2022, 46(2): 613-623.
WANG P, ZHANG J, CHENG Z. Lithium-ion Battery State-of-Health Estimation Method Based on Least-Squares Support Vector Machine Error Compensation Model [J]. Power System Technology, 2022, 46(2): 613-623

[15] 何畏, 罗潇, 曾珍, 等. 利用 QPSO 改进相关向量机的电池寿命预测[J]. 电子测量与仪器学报,2020,34(06):18-24.
HE W, LUO X, ZENG Z, et al. Battery Life Prediction Using QPSO-Enhanced Correlation Vector Machine [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(06): 18-24.

[16] 张然, 刘天宇, 金光. 基于核自构建-高斯过程回归的锂离子电池剩余使用寿命预测[J]. 系统工程与电子技术,2023,45(08):2623-2633.
ZHANG R, LIU T Y, JIN G. Residual Life Prediction of Lithium-ion Batteries Based on Kernel Self-Organizing Regression and Gaussian Process Regression [J]. Systems Engineering and Electronics, 2023, 45(08): 2623-2633.

[17] WEI H L, Neil S, Philipp D, et al. Online capacity estimation of lithium-ion batteries with deep long short-term memory networks [J]. Journal of Power Sources,2021,482228863-.

[18] 张浩, 胡昌华, 杜党波, 等. 多状态影响下基于 Bi-LSTM 网络的锂电池剩余寿命预测方法[J]. 电子学报,2022,50(03):619-624.
ZHANG H, HU C H, DU D B, et al. A Bi-LSTM Network-Based Method for Predicting the Remaining Life of Lithium Batteries Under Multi-State Influence [J]. Chinese Journal of Electronics, 2022, 50(03): 619-624.

[19] 李嘉波, 王志璇, 田迪等. 变模态分解下 SSA-LSTM 组合的锂离子电池剩余使用寿命预测方法[J]. 储能科学与技术, 2025, 14(02): 659-670.
LI J B, WANG Z X, TIAN D, et al. A Residual Life Prediction Method for Lithium-ion Batteries Based on SSA-LSTM Combination under Variable Modal Decomposition [J]. Energy Storage Science and Technology, 2025, 14(02): 659-670.

[20] 高德欣, 刘欣, 杨清. 基于卷积神经网络与双向长短时融合的锂离子电池剩余使用寿命预测[J]. 信息与控制,2022,51(03):318-329+360.
GAO D X, LIU X, YANG Q. Residual Life Prediction of Lithium-ion Batteries Based on Convolutional Neural Networks and Bidirectional Long-Short Term Fusion [J]. Information and Control, 2022, 51(03): 318-329+360.

[21] 岳家辉, 夏向阳, 吕崇耿, 等. 计及健康特征信息量的锂离子电池健康状态与剩余寿命预测研究[J]. 电力系统保护与控制, 2023, 51(22): 74-87.
YUE J H, XIA X Y, LV C G, et al. Research on Lithium-ion Battery Health Status and Remaining Life Prediction Incorporating Health Feature Information [J]. Protection and Control of Electric Systems, 2023, 51(22): 74-87

[22] 耿鑫月, 胡昌华, 郑建飞, 等. 双时间尺度下基于 Transformer 的锂电池剩余寿命预测[J]. 空间控制技术与应用,2023,49(04):119-126.
GENG X Y, HU C H, ZHENG J F, et al. Transformer-Based Prediction of Lithium Battery Remaining Life Under Dual Time Scales [J]. Space Control Technology and Applications, 2023, 49(04): 119-126.

[23] 孙立明, 余涛. 考虑噪声影响的电动汽车动力电池 SOH 和 RUL 联合估计[J]. 电力系统保护与控制,2025,53(23):49-62.
SUN L M, YU T. Joint Estimation of SOH and RUL for Electric Vehicle Power Batteries Considering Noise Effects [J]. Power System Protection and Control, 2025, 53(23): 49-62.

[24] 向铭, 何怡刚, 张慧. 基于改进集成经验模态分解和高斯过程回归的锂离子电池剩余容量及寿命预测方法[J]. 电测与仪表,2023,60(09): 27-33.
XIANG M, HE Y G, ZHANG H. A Method for Predicting the Remaining Capacity and Lifespan of Lithium-ion Batteries Based on Improved Integrated Empirical Mode Decomposition and Gaussian Process Regression [J]. Electrical Measurement and Instrumentation, 2023, 60(09): 27-33.

[25] 史永胜, 施梦琢, 丁恩松等. 基于多退化特征的锂离子电池剩余寿命预测[J]. 电源技术,2020,44(06):836-840.
SHI Y S, SHI M Z, DING E S, et al. Residual Life Prediction of Lithium-ion Batteries Based on Multi-Degradation Features [J]. Power Supply Technology, 2020, 44(06): 836-840.

[26] Pinson B M, Bazant Z M. Theory of SEI Formation in Rechargeable Batteries: Capacity Fade, Accelerated Aging and Lifetime Prediction [J]. Journal of the Electrochemical Society, 2013, 160(2): A243-A250.

[27] Bai S. An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling[J]. arXiv preprint arXiv:1803.01271, 2018.

[28] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [J]. Advances in neural information processing systems, 2017, 30.

[29] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer[J]. Advances in engineering software, 2014, 69: 46-61.

[30] Kennedy J, Eberhart R. Particle swarm optimization[C]// Proceedings of ICNN'95-international conference on neural networks. IEEE, 1995, 4: 1942-1948.

[31] 黄阿敏,董海鹰,孙娜.融合多尺度混合卷积及倒置Informer的燃料电池性能衰减预测方法[J/OL].控制理论与应用,1-16[2025-12-24].
HUANG A M, DONG H Y, SUN N. A Multi-Scale Hybrid Convolutional Neural Network and Inverted Informer-Based Method for Predicting Fuel Cell Performance Degradation [J/OL]. Control Theory and Applications, 1-16 [2025-12-24].