

# 基于注意力增强 Uniformer 的锂电池 剩余使用寿命预测\*

廖列法<sup>1,2</sup> 刘映宝<sup>1</sup> 占玉敏<sup>1</sup>

(1. 江西理工大学信息工程学院, 赣州 341000; 2. 江西现代职业技术学院, 南昌 330095)

**【摘要】**针对锂离子电池的剩余使用寿命(RUL)预测时常面临数据的动态变化和老化数据有限的问题,提出注意力增强 Uniformer(AEUniformer)的RUL预测模型,通过 Uniformer 整合卷积神经网络(CNN)和自注意力机制的优势实现全面的信息感知;设计注意力引导机制(AGM)和 CoordAttention 实现强大的特征提取。试验结果表明, AEUniformer 可以实现仅需单个老化周期的准确快速的RUL预测,数据集的平均绝对百分比误差分别为2.7%和6.16%,证明了该方法的准确性。

**关键词:** 锂电池 剩余使用寿命预测 数据驱动 统一变形器 注意力引导机制 坐标注意力  
**中图分类号:** TM912 **文献标志码:** A **DOI:** 10.19620/j.cnki.1000-3703.20240396

## Remaining Useful Life Prediction of Lithium Battery Based on Attention Enhancement Uniformer

Liao Lief<sup>1,2</sup>, Liu Yingbao<sup>1</sup>, Zhan Yumin<sup>1</sup>

(1. School of Information Engineering, Jiangxi University of Science and Technology, Ganzhou 341000; 2. Jiangxi Modern Polytechnic College, Nanchang 330095)

**【Abstract】**To address the issue of dynamic changes in data and limited aging data in the Remaining Useful Life (RUL) prediction of lithium-ion batteries, this paper proposes the RUL prediction model of Attention Enhancement Uniformer (AEUniformer) to realize comprehensive information perception by integrating the advantages of Convolutional Neural Network (CNN) and Self-Attention Mechanism through Uniformer. Attention Guiding Mechanism (AGM) and CoordAttention are designed to realize powerful feature extraction. Experimental results show that AEUniformer can achieve accurate and fast RUL prediction with only a single aging cycle, and the MAPE prediction errors of the 2 datasets are 2.7% and 6.16%, respectively, demonstrating the accuracy of the method.

**Key words:** Lithium-ion battery, Remaining Useful Life (RUL), Data-driven, Uniformer, Attention Guiding Mechanism (AGM), CoordAttention

**【引用格式】**廖列法,刘映宝,占玉敏.基于注意力增强 Uniformer 的锂电池剩余使用寿命预测[J].汽车技术,2025(6):36-44.

LIAO L F, LIU Y B, ZHAN Y M. Remaining Useful Life Prediction of Lithium Battery Based on Attention Enhancement Uniformer[J]. Automobile Technology, 2025(6): 36-44.

## 1 前言

锂电池因其高能量密度、长循环寿命和低自放电率等特点而被广泛应用于储能和供电领域<sup>[1]</sup>。然而,随着使用时间的增加,电化学反应会导致电池内部成分的不断变化<sup>[2]</sup>。此外,电流倍增器、温度和放电深度等许多因素也会加速电池性能下降<sup>[3]</sup>,降低电池的使用寿命和安全性,因此精确、稳定地监测电池的健康状态具有重

要意义<sup>[4]</sup>。剩余使用寿命(Remaining Useful Life, RUL)为电池的容量衰减至失效阈值(通常为标称容量的80%)之前剩余的充放电周期次数,是衡量电池健康状态的重要指标之一。

数据驱动方法可以在不考虑内部电化学系统反应和失效机制的情况下从大量历史数据中学习电池退化规律,以此分析锂电池寿命特征参数与RUL之间的关系<sup>[5]</sup>。Severson等<sup>[6]</sup>使用结合线性模型和Elastic Net正则

\*基金项目:国家自然科学基金项目(71462018,71761018)。

通信作者:刘映宝(2001—),硕士研究生,研究方向为锂离子电池的剩余使用寿命预测,1875623857@qq.com。

化的机器学习方法预测电池的早期寿命,使用前 100 个周期数据的预测误差为 9.1%。Fei 等人<sup>[7]</sup>利用参数化注意力和周期性注意力,探讨由各种循环次数和参数组成的输入数据对模型性能的影响,改善对老化信息中关键特征的研究。

虽然神经网络可以从原始数据中自动提取复杂的隐藏特征,但现有方法仍存在一些局限性:首先,预测 RUL 往往面临数据的动态变化、老化数据有限的问题,且通常输入信号为长时间序列信号;其次,可用的电池数据通常较为有限;最后,模型的泛化性和扩展性较弱,许多研究的验证是基于使用相同工作条件的少量电池数据,对于训练场景之外和个性化的操作条件的预测精度明显降低。针对上述问题,提出注意力增强统一变形器(Attention Enhancement Uniformer, AEUniformer)。本文首先设计注意力引导机制(Attention Guiding Mechanism, AGM)和坐标注意力(CoordAttention)改进 Uniformer,无缝集成卷积和自注意力机制,解决锂电池退化信息的局部冗余和全局依赖关系问题,实现更好的特征提取和更全面的建模;其次开发深度学习驱动的预测框架,仅需要电池老化阶段 1 个循环的数据就可以实

现电池 RUL 快速准确的预测;最后在两个不同充放电配置的数据集上进行试验验证,证明了所提框架对多场景的电池寿命预测具有较好的泛化能力,而且能够直接扩展至其他的预测任务。

## 2 注意力增强 Uniformer

注意力增强 Uniformer 整体流程如图 1 所示,具体架构如图 2 所示。块嵌入(Patch Embedding)模块是对原始数据曲线进行降维和去噪,减少整体的计算复杂度,并由 Uniformer 块(Uniformer block)进行浅层和深层退化特征的融合,以解决数据中局部信息冗余和全局依赖问题,建立全面的信息感知能力,其中 4 个 Uniformer block 的 Transformer 层数分别是 3、4、8、3;注意力引导机制(包括维度变换层和模块残差注意力),可以弥补 Patch Embedding 下采样过程造成的信息损失并增强层之间注意力的信息流动;坐标注意力为输入的低、高级特征自适应分配不同权重,增强关键信息并去除无用噪声,进一步提高模型的特征提取能力。

### 2.1 块嵌入模块

为了充分学习不同充放电阶段的特征表示,块嵌入

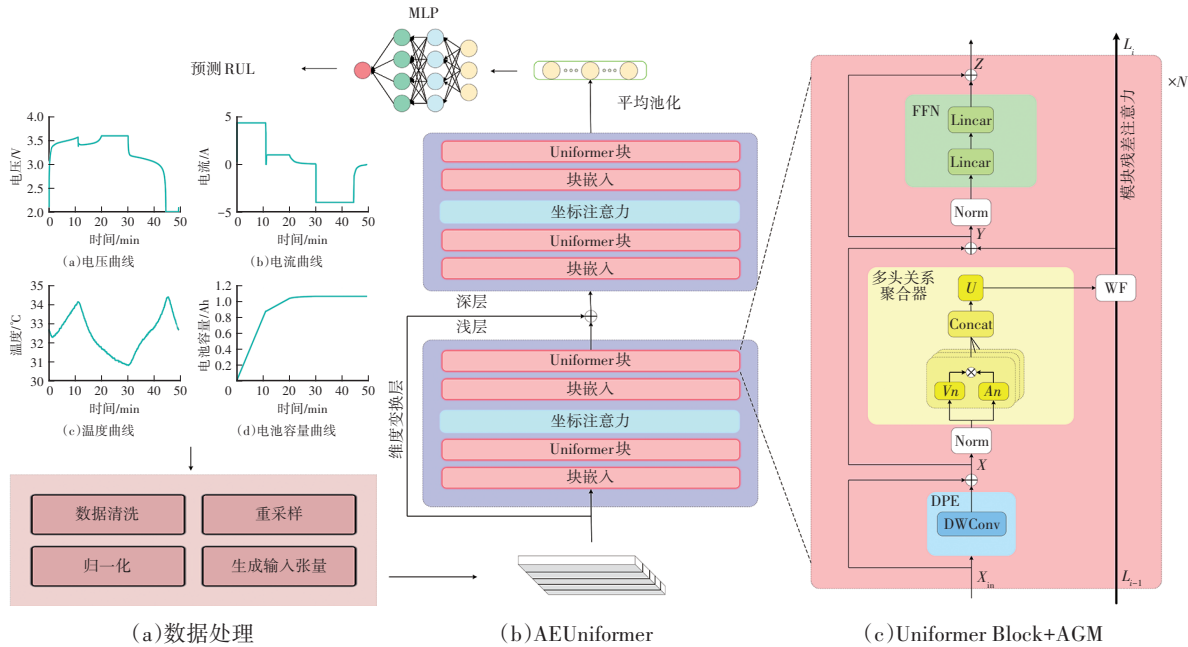


图 1 总体流程




图 2 AEUniformer 架构

模块使用核大小和步长相等的卷积操作对输入  $X$  进行下采样,通过降低 Uniformer block 的输入序列长度以降低模型的计算复杂度,具体公式如下:

$$N = (H / P_1) \times (W / P_2) \quad (1)$$

$$P = R(N(T(F(C(X)))))) \quad (2)$$

式中: $N$ 为输入  $X$  经过卷积之后的块(patch)数量, $P_1, P_2$  分别为卷积核和步长的大小, $H, W$  分别为输入  $X$  的高度、宽度, $C()$ 为卷积操作, $F()$ 为将 patch 在第二维展平, $T()$ 为第一维和第二维的转置操作, $N()$ 为层归一化(Layer Normalization, LN), $R()$ 为将二维向量重新转变为三维张量结构的转置归一化操作, $P$ 为 Patch Embedding 的输出。

Patch Embedding 可以捕捉不同时间的退化特征之间的关系,超越了传统循环神经网络的能力。

## 2.2 Uniformer 块

Uniformer block 能够实现聚合退化特征的局部上下文信息以滤除特征的突然变化,同时能够捕获全局的依赖关系。每个 Uniformer block 主要由 3 部分组成,如图 1c 所示,包含动态位置编码(Dynamic Position Embedding, DPE)、多头关系聚合器(Multi-Head Relation Aggregator, MHRA)及前馈层(Feedforward Neural Network, FFN)。公式如下:

$$X = U_{DPE}(X_{in}) + X_{in} \quad (3)$$

$$Y = U_{MHRA}(N(X)) + X \quad (4)$$

$$Z = U_{FFN}(N(Y)) + Y \quad (5)$$

式中: $X_{in}$ 为 Uniformer block 的输入; $N()$ 为层归一化; $U_{DPE}, U_{MHRA}, U_{FFN}$  分别为 DPE、MHRA、FFN 操作,在 Uniformer block 中分别将 DPE、MHRA、FFN 的输出  $X, Y, Z$  传入至下一层。

### 2.2.1 动态位置编码

位置信息是 Transformer 学习数据表征的重要因素。为了提高灵活性,使用深度卷积(DepthWise Convolution, DWC)进行局部建模,DWC 不仅能够动态适应任意的输入形状,让模型隐式编码位置信息,而且是轻量级的卷积操作,可以有效地降低计算量和参数量,提高模型的推理速度和运行效率,进而实现计算精度和速度之间的平衡。由此可以让 AEUniformer 灵活处理不同输入分辨率,提升识别性能,计算公式如下:

$$U_{DPE}(X_{in}) = D_{DWC}(X_{in}) = (X_{in} \times W_{depth}) \times W_{point} \quad (6)$$

式中: $W_{depth}$ 是长、宽、通道数分别为  $K, K, C$  的卷积核,针对每个输入通道独立进行空间特征提取; $W_{point}$ 是长、宽、通道数分别为  $1, 1, C$  的卷积核,用于通道间的线性组合,以此混合通道信息; $D_{DWC}$ 为 DWC 操作。

### 2.2.2 多头关系聚合器

关系聚合器(Relation Aggregator, RA)通过在浅层(前两层)和深层(后两层)的 Uniformer block 分别设计局部和全局的令牌(token)相关性,实现高效的表示学习。统一的 MHRA 以多分支的方式学习特征关系,公式如下:

$$R_n(X) = A_n V_n(X) \quad (7)$$

$$U_{MHRA}(X) = S(R_1(X); R_2(X); \dots; R_n(X))U \quad (8)$$

式中: $R_n()$ 为输入矩阵  $X$  的第  $n$  个 RA,每个 RA 由 token 的上、下文的线性编码  $V_n()$  和相关性  $A_n()$  组成; $U$  为集成  $n$  个 RA 的可学习参数矩阵; $S$  为将所有 RA 的参数矩阵堆叠,最后得到多头关系聚合器的输出  $U_{MHRA}$ 。

在浅层中,MHRA 使用卷积风格的可学习参数矩阵捕获局部 token 相关性,通过局部区域的上、下文聚合极大减少计算冗余。在深层中则继承自注意力风格,通过 token 相似度的比较学习全局的 token 相关性,自适应地构建整个循环周期的远程依赖,捕获电池使用模式的复杂性和时间依赖性。通过逐步分层地堆叠局部和全局的 Uniformer block,可以灵活地整合它们的协作能力,以充分利用不同尺度的退化特征,实现更准确的预测。局部和全局的相关性公式如下:

$$A_n^{local}(X_i, X_j) = a_n^{i-j}, \text{ where } j \in \Omega_i^{H \times W} \quad (9)$$

$$A_n^{global}(X_i, X_j) = \frac{e^{Q_n(X_i)^T K_n(X_j)}}{\sum_{j \in \Omega_{H \times W}} e^{Q_n(X_i)^T K_n(X_j)}} \quad (10)$$

式中: $A_n^{local}$ 为浅层中局部的 token 相关性计算结果, $A_n^{global}$ 为深层中全局的 token 相关性计算结果, $\Omega$ 为当前位置  $i$  的局部邻域, $X_i$ 为当前 token, $X_j$ 为当前 token 的任何相邻 token, $a_n$ 为自适应的可学习参数, $(i-j)$ 为 token 之间的相对位置, $Q_n$ 及  $K_n$ 为线性变换。

### 2.3 注意力引导机制

为了增强相邻 AEUniformer 层之间特征级别的信息流以提高特征多样性,提出模块残差注意力(Block Residual Attention, BRA),如图 1c 所示。采用一种新的残差连接引导注意力在同一层高效传播,学习提取新特征表示,同时考虑之前提取的特征表示。为了避免传播积累的特征表示所占比重过大导致模型难以学习到深层表示,设计一个可学习的加权特征(Weighted Feature, WF)函数,平衡聚合过程中从前一个 MHRA 传输到当前 MHRA 的残差注意力,公式如下:

$$L_i = \begin{cases} U_{MHRA_i} & i = 1 \\ WF(U_{MHRA_i}, L_{i-1}) = \alpha \cdot U_{MHRA_i} + (1 - \alpha) \cdot L_{i-1} & \text{其他} \end{cases} \quad (11)$$

式中: $i$ 为第  $i$  层 Uniformer block 模块; $WF()$ 为加权特征  
汽车技术

融合函数;  $\alpha$  为可学习的权重参数;  $L_i$  为第  $i$  层 Unifomer block 中 MHRA 的最终输出,当  $i=0$  时,当前的 MHRA 正常正向传播,反之则与上一层中的 MHRA 输出进行加权融合,以此来传播前一层的特征之间聚合信息的注意力。

#### 2.4 坐标注意力

输入的三维张量结构  $X$  包括特征参数、充放电阶段、老化周期数信息,这些因素对电池 RUL 预测的贡献各异,而标准卷积和自注意力机制难以学习到作为通道的电池参数关系<sup>[8]</sup>,因此,在浅层和深层 Unifomer block 之间引入 CoordAttention。如图 3 所示,该机制能够将循环阶段和老化周期信息嵌入到特征参数注意力中,其主要方式是将参数注意力分解为两个沿着循环阶段和老化周期方向聚合特征的一维特征编码过程,由此可以沿着循环阶段方向保留精确的位置信息,还可以沿着老化周期方向捕获长程依赖,随后将生成的特征图分别编码,形成一个对方向感知且对位置敏感的特征图,二者可以互补地应用到输入特征图来增强对感兴趣目标的表示。

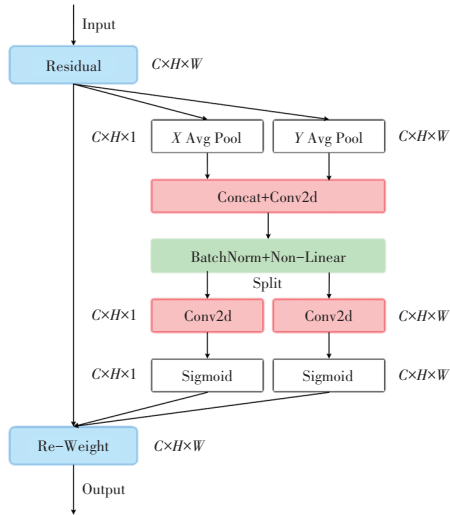


图 3 CoordAttention 架构

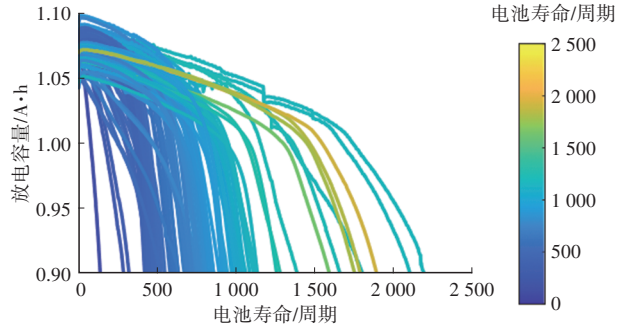
### 3 试验

#### 3.1 数据处理


为了评估不同工况下的电池 RUL 预测准确性,本研究选取目前可获取的、规模最大的不同充电策略和放电策略<sup>[9]</sup>的老化数据集进行试验,分别来自麻省理工大学 (Massachusetts Institute of Technology, MIT) 和华中科技大学 (Huazhong University of Science and Technology, HZUST),如表 1 所示。MIT 数据集中的电池多采用两步恒流快速充电策略,而 HZUST 数据集中的电池则采用不同的多级放电策略。两个数据集均在恒定 30 °C 的实验室中进行循环试验。电池容量衰减轨迹如图 4 所示。

表 1 充电和放电数据集概况

数据集	电池数量 / 个	电池寿命 / 周期	充电条件	放电条件
MIT	124	150-2 300	个性化	4C
HZUST	77	1 100-2 700	5C-1C-C/20	个性化



(a) MIT 数据集容量衰减曲线



(b) HZUST 数据集容量衰减曲线

图 4 数据集的电池容量衰减轨迹

MIT 数据集存在采样不稳定、测试提前停止、温度记录失败等问题,需要对数据进行清洗。首先删除极端寿命的电池以及异常电池,然后从原始电池数据中提取电压  $V$ 、电流  $I$ 、温度  $T$ 、容量  $Q$  和充放电时间  $t$  作为输入特征,使用绝对中位差将异常值替换为两端的线性插值,采用 Savitzky-Golay 滤波器进行平滑去噪。清洗后的特征变化曲线如图 5 所示,发现不同的充电策略对电池的电压曲线影响显著;随着循环次数的增加,不同电池的初始温度存在差异,但增长趋势相似;此外,较大的充电电流和较长的快速充电时间均可导致电池容量的快速衰减。由于 HZUST 数据集未记录温度,选择其余 4 个特征作为模型输入。


为了整合单个周期数据中包含的多维信息,使用滑动窗口将 5 个特征参数整合为一个三维的输入张量  $X \in \mathbf{R}^{C \times H \times W}$ ,其中  $C$ 、 $H$ 、 $W$  分别对应电池参数、循环阶段、老化周期,如图 1a 所示。使用线性插值将 MIT 数据集的周期数据重采样为定长的 500 个数据点。对于 HZUST 数据集,由于实际应用中难以收集个性化的放电特征曲线,因此选择充电阶段的数据作为输入并重采样为 100 个数据点。对特征做归一化处理保持输入数

据的稳定性和一致性。归一化公式如下。


$$\mathbf{x}' = \frac{\mathbf{x} - \mathbf{x}_{\min}}{\mathbf{x}_{\max} - \mathbf{x}_{\min}} \quad (12)$$

式中: $\mathbf{x}_{\max}$ 、 $\mathbf{x}_{\min}$ 分别为输入向量 $\mathbf{x}$ 的最大值、最小值。

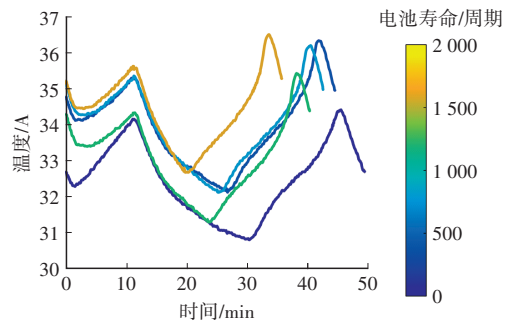
MIT数据集分为92个电池的训练集和23个电池的测试集。HZUST数据集分为55个电池的训练集和22个电池的测试集。




(a)电压曲线



(b)电流曲线



(c)温度曲线



(d)电池容量曲线

图5 MIT数据集

### 3.2 评价指标

使用平均绝对误差(Mean Absolute Error, MAE)、平

均绝对百分比误差(Mean Absolute Percent Error, MAPE)、均方根误差(Root Mean Square Error, RMSE)和决定系数 $R^2$ 作为评价指标。计算公式如下:

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (13)$$

$$E_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (14)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (15)$$

$$E_{R^2} = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

式中: $E_{MAE}$ 、 $E_{MAPE}$ 、 $E_{RMSE}$ 、 $E_{R^2}$ 分别为MAE、MAPE、RMSE、 $R^2$ 的计算结果, $\hat{y}_i$ 为RUL的预测值, $y_i$ 为真实值, $\bar{y}$ 为真实值的平均值, $n$ 为样本的总长度。

### 3.3 特征选择实验

为了评估各个电池参数对RUL预测的影响,基于原始电池参数,即 $V$ 、 $I$ 、 $T$ 、 $Q$ 、 $t$ 构建多种参数组合作为模型的输入。对比结果如表2所示。

表2 不同参数组合输入的预测结果

参数组合					MAE/周期	RMSE/周期	$R^2$
V/V	I/A	T/°C	Q/A·h	t/s			
√					42.719 5	49.897 6	0.941 0
	√				35.327 5	44.623 3	0.953 0
		√			52.100 3	63.637 6	0.908 4
			√		36.088 9	47.700 1	0.942 4
				√	189.328 4	236.135 9	-0.427 8
√	√				38.742 4	46.452 6	0.946 7
√	√			√	28.761 4	35.5441 1	0.965 9
√	√	√			27.953 4	35.120 9	0.972 5
√	√	√	√		23.423 9	29.127 5	0.979 1
√	√	√	√	√	20.406 71 (最佳)	25.576 83 (最佳)	0.983 37 (最佳)

观察预测结果可以发现,考虑全部的电池参数能够实现最佳的预测性能,其中 $R^2$ 达到最高值为0.983,MAE和RMSE也分别达到最优值,证明了本方法的准确性和有效性。尽管单独使用特征 $V$ 、 $I$ 、 $T$ 、 $Q$ 作为输入会导致相对较大的误差,但其对数据量的要求却大幅降低,且仅使用单个周期的情况下,该模型仍然能够达到可接受的性能水平<sup>[10]</sup>,MAE和RMSE分别为40个和50个周期左右,这也从侧面证明了该模型的鲁棒性;而单独将 $t$ 作为输入的预测效果较差,说明单独的 $t$ 并不能体现电池的退化趋势,需要和其他参数一同组合输入;

组合  $V$  和  $I$  作为输入的结果没有明显的提升,说明  $V$  和  $I$  包含较多相同的信息,因为充放电过程中  $I$  的激励会直接导致  $V$  产生相同的趋势变化;组合特征  $V, I, t$  作为输入可达到较好的预测结果,3个评价指标分别为28个周期、35个周期和0.966,在添加体现内阻变化的  $T$  或者表征健康状态的  $Q$  之后预测结果大幅提升,说明温度和容量都能够反映电池的退化趋势,可以和电流、电压互补。由此说明,单周期数据已经包含足够的退化信息,能够高精度地预测基本的电池特性。

在实际应用中,受限于传感器测量精度、环境干扰等客观因素,温度  $T$  和容量  $Q$  往往难以达到理想的精密度。为了准确地评估测量误差对 RUL 预测模型的影响,引入噪声模拟现实场景中的测量不确定性。具体而言,分别对  $T$  和  $Q$  的测量数据中单独添加标准差为0.1的高斯噪声,以及对  $T$  和  $Q$  同时添加标准差为0.1的高斯噪声。通过该方式量化噪声对预测模型性能的影响,从而评估预测模型在真实应用环境中的鲁棒性。试验结果如表3所示。

表3 不同特征引入噪声后的预测结果

噪声特征	MAE/周期	RMSE/周期	$R^2$
	20.406 7	25.576 8	0.983 3
$T$	22.956 2	29.120 4	0.978 6
$Q$	27.052 5	34.632 5	0.969 2
$T, Q$	21.073 6	25.647 4	0.982 8

当仅在特征  $T$  中引入噪声后,预测结果呈现轻微下降,MAE、RMSE、 $R^2$  分别由20个周期、25个周期、0.983降至22个周期、29个周期、0.978,这表明尽管存在测量误差,但模型仍能维持较高的预测性能。当仅在  $Q$  中添加相同高斯噪声后,预测性能下降幅度更大,但相比于  $V, I, t$  的组合而言,其预测效果依旧更优。相比于  $T$ , 特征  $Q$  的噪声对模型性能的影响更为显著,这是由于特征  $Q$  对 RUL 预测的重要性更高,其噪声对模型特征的扰动更强。而同时在  $T, Q$  特征中添加噪声时,预测的效果相对最佳,  $R^2$  低于0.001,这归因于噪声的叠加效应,模型对多特征噪声具有特定的鲁棒性,能够通过数据之间内在的复杂关系来削弱噪声的影响。这充分表明 AEUniformer 在实际应用中具有较强的鲁棒性,能够有效应对测量误差和噪声干扰,从而在真实应用环境中依然能够保持较高的预测准确性。

### 3.4 消融试验

为了观察 AGM、CoordAttention 模块的实际贡献,构建4个独立的网络模型,分别是 Uniformer、AGM+Uniformer、CoordAttention+Uniformer 和 AEUniformer。

输入为5个电池参数特征组合而成的三维张量结构,预测结果如表4和图6所示。试验结果可以验证 AEUniformer 模型比基准模型 Uniformer 具有更好的预测精度,评估指标结果 MAE、RMSE、 $R^2$  分别为20个周期、25个周期、0.983,均达到最优水平。而且所引入的额外参数量仅为 Uniformer 的0.33%。本文所设计的 AGM、CoordAttention 模块对基准模型的性能提升效果显著。其中 Uniformer 的预测结果波动最为剧烈,最大 MAE 为121个周期,最小 MAE 为12个周期,整体表现最差,且有7个电池的误差高于40个周期,尤其是测试集中编号为16、22、23中的3个电池,这归因于特殊循环条件和长寿命电池训练样本的稀缺性,导致数据分布不平衡。AGM+Uniformer 通过有效地加强模型自注意力机制的特征流动,增强深层与浅层之间多尺度特征的全局维度交互,MAE 下降近35%,RMSE 下降近26%, $R^2$  提升近0.03; CoordAttention+Uniformer 通过加强模型对参数、老化周期和循环阶段的信息建模,对输入特征图中包含重要电池寿命信息的关键区域提取有价值的信息,MAE 下降10个周期, RMSE 下降9个周期,  $R^2$  提升近0.02。当添加 AGM 或 CoordAttention 模块后整体的 MAE 明显下降,工况复杂、寿命长、误差较大的电池的预测结果显著提升,证明两个模块可以在不增加计算复杂度的情况下,降低信息损失并提高模型的特征提取能力,从而实现电池老化阶段任何单个周期的 RUL 预测。

表4 不同模块+Uniformer 的预测结果

模型	参数量/个	MAE/周期	RMSE/周期	$R^2$
Uniformer	1 156 545	35.182 5	42.664 5	0.948 6
AGM+Uniformer	1 158 177	25.293 9	31.006 7	0.975 3
CoordAttention+Uniformer	1 158 673	29.895 3	33.927 5	0.970 2
AEUniformer	1 160 305	20.406 7	25.576 8	0.983 4

### 3.5 对比试验

为了进一步验证 AEUniformer 的精度和鲁棒性,与先前先进方法进行比较,结果如表5所示。Elastic Net 提取前100个周期的容量方差曲线和放电容量相关特征,没有考虑到退化的时序信息,预测效果较差;膨胀卷积神经网络(Dilated CNN)方法<sup>[11]</sup>通过连接4个周期的老化数据获得更高分辨率的输入特征,使用 Dilated CNN 学习原始数据中的时间模式和电池参数之间的相关性,效果相比 Elastic Net 有所提升,但未实现老化信息的全局依赖;梯度提升回归树(Gradient Boosting Regression Tree, GBRT)方法<sup>[12]</sup>构建并探索各种高成本

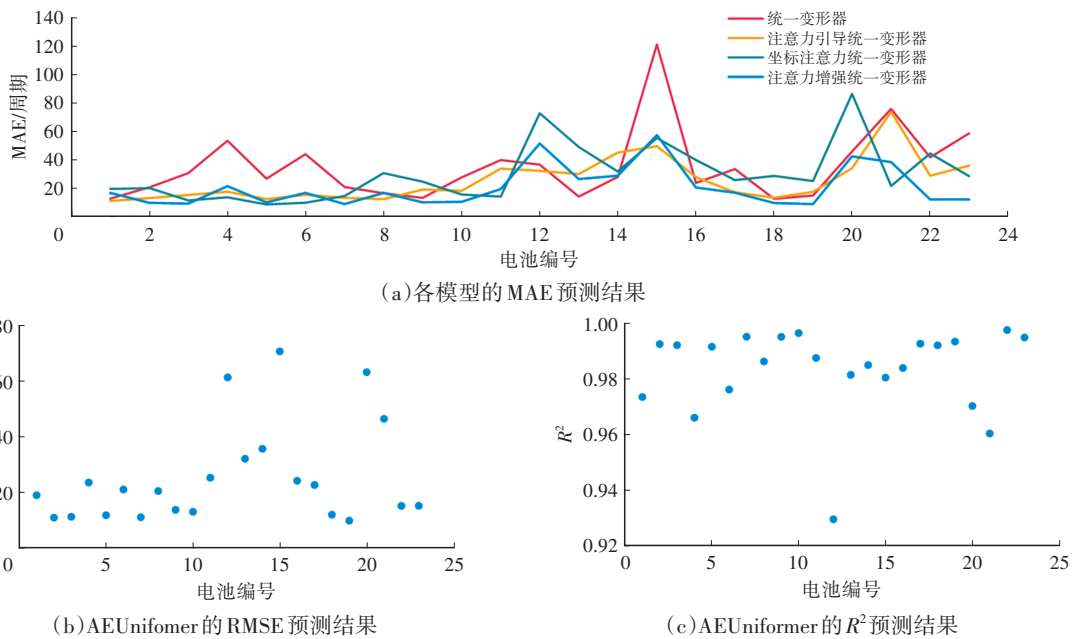


图6 不同模型的MAE预测结果和AEUnifomer的RMSE、R<sup>2</sup>结果

高性能的特征,包括电压、容量和温度的相关特征,利用GBRT建立复杂的非线性电池动态模型以实现有效的寿命预测;迁移学习并行混合方法(Transfer Learning Parallel Hybrid, TLPH)<sup>[13]</sup>使用基于图像的输入和健康指标的复杂特征工程组合来改进现有的方法,但需要7 366 445个参数量实现MAE为47个周期的预测结果,接近本文方法的7倍,而本文提出的模型从单个周期原始循环数据中获取关键知识,而不依赖于高成本的手工特征,通过注意力增强机制更好地适应不同场景下的数据复杂度和突然扰动性,从有限的數據中高效地提取特征,最佳情况时可以实现MAE为20个周期和RMSE为25个周期,分别比现有模型降低58%~70%和61%~88%,MAPE提升8%~17%,同时参数量减少2~6倍,实现了预测精度和成本的最佳平衡。

表5 与先进方法的对比结果

模型	周期数 /个	训练参数量 /个	MAE /周期	MAPE /%	RMSE /周期
Elastic Net	100			10.7	214.00
Dilated CNN	4	2 393 468	65	19.7	
GBRT	1		54.93	7.0	64.45
TLPH	1	7 366 445	47.67	12.02	73.35
AEUnifomer	1	1 160 305	20.41	2.70	25.58

AEUnifomer在使用寿命分别近500、800、1 200、1 600个周期的部分测试电池的预测结果如图7所示。对于1 600个周期的长寿命电池而言,单个周期的退化通常并不显著,难以提供足够的信息用于精准预测,而AEUnifomer能够从局部和全局的时空视角提取序列

特征信息,抗干扰能力强,其注意力引导机制和CoordAttention可以进一步提升特征提取能力,使得电池整个生命周期的预测误差均维持在较低水平。99%的低于1 200个周期的中短寿命电池的预测误差均小于40个周期,这充分证明了本文的方法和模型可以准确地预测工况复杂的电池RUL,尤其在退化后期,随着锂电池运行周期和工作时长的增加,退化特征不断增强,模型的预测精度更高。这些结果充分证明所提方法在不同充电策略下对整个有效寿命范围内的RUL预测具有较高的精度和较强的鲁棒性,针对不同运行工况和寿命范围的电池均有较好的预测结果,可为电池管理系统提供有效的健康保护参考依据。

### 3.6 泛化试验

为了验证所提出模型的鲁棒性和泛化性,使用放电策略个性化的HZUST数据集进行试验验证,试验结果如表6所示。与深度迁移框架CNN-LSTM-TL及Elastic Net做对比,AEUnifomer可以从充电数据中自动提取有价值的特征,使用锂电池任意老化阶段的30个周期数据作为模型的输入,实现了在任何充、放电周期下的实时个性化健康状况预测,达到了MAPE为8.72%和RMSE为186个周期的预测结果,3个评价指标结果均优于Elastic Net,而且无需复杂的特征工程。而本文提出的AEUnifomer同样不需要高性能的手工特征,仅使用最少的5个老化周期就可以实现RMSE为52个周期,同时MAPE和R<sup>2</sup>分别是6.16%和0.91的最优预测结果,充分证明了本文所提模型的泛化性和鲁棒性。

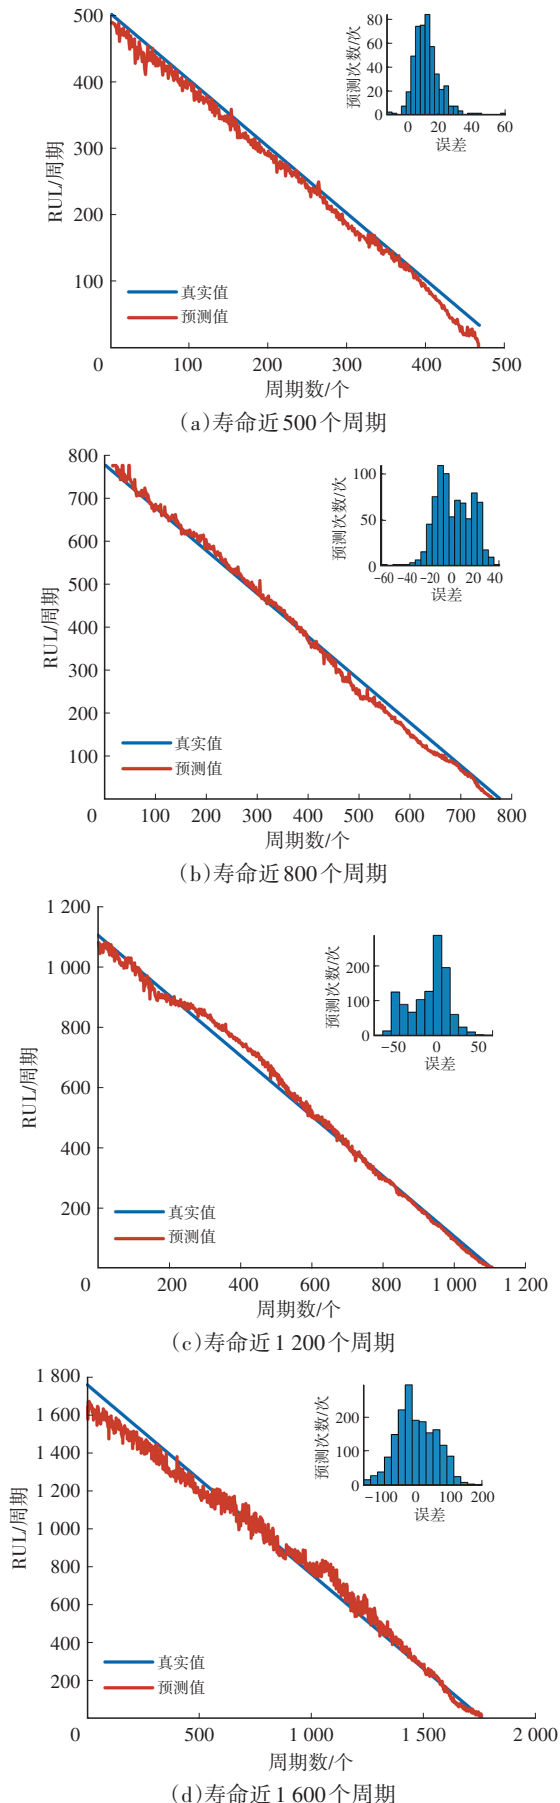


图7 短、中、长寿命电池的预测结果和误差统计

表6 放电数据集的对比试验结果

模型	周期数/个	MAPE/%	RMSE/周期	$R^2$
CNN-LSTM-TL	30	8.72	186	0.804
Elastic Net	30	8.84	192	0.795
AEUnifomer	5	6.164	52.964	0.913

### 3.7 早期寿命预测试验

以上试验结果表明,AEUnifomer在使用任何老化阶段的数据预测电池 RUL 任务中具有优越性和实用性,与此同时,最新研究可以根据一定范围内的初始循环数据评估电池的总使用寿命,实现批量估计和电池寿命筛选,对于加速电池技术发展、降低生产和维护成本、提高系统的安全性至关重要。因此,本文设计早期电池寿命预测试验验证 AEUnifomer 在实际应用场景中的稳定性和可靠性,与 3 种先进方法进行比较。Elastic Net 方法根据电压作为容量函数的曲线,从前 100 次循环的退化数据中提取包括直接、演变和统计方面的 18 个手工制作的特征,并输入到 Elastic Net 中进行早期电池寿命预测。GBRT 方法构建并探索各种特征,包括电压、容量和温度相关特征,研究关键的超参数以实现最佳的 GBRT 预测。多阶段时间序列处理框架 (Multi-Stage Time Series Processing Framework, MSTSPF) 方法<sup>[14]</sup>针对周期内的电压、电流、温度和跨周期的放电容量提出一种基于注意力机制的 MSTSPF,采用交叉注意力机制对特征进行融合,进一步提高预测性能,试验结果如表 7 所示。

表7 早期寿命预测对比试验结果

模型	预测位置/周期	MAE/周期	MAPE/%	RMSE/周期
Elastic Net	100		10.7	214.0
GBRT	100	77.0	11.0	118.0
MSTSPF	100	45.0	6.40	67.0
AEUnifomer	1	29.3	3.9	40.5

观察试验结果发现对于电池的早期寿命预测任务,所提出的框架具有更高的预测精度和更早的预测点,而且仅需使用早期的第 1 个测试周期的退化数据。在测试集上实现了 MAE 为 29 个周期,与其他 3 个方法相比降低了 36%~63%,RMSE 为 40 个周期,与其他 3 个方法相比降低了 59%~82%,MAPE 降低了 40%~65%。

## 4 结束语

本文提出了一种用于锂电池 RUL 预测的深度学习网络,鉴于锂电池退化信息存在局部冗余和全局依赖关系问题,该网络只需要退化过程中任意一个循环周期的

数据就可以实现准确快速的预测。首先,将充放电过程的单个周期数据组合成三维张量的输入结构,利用卷积操作的归纳偏置原理有效降低充放电阶段的局部信息冗余;其次,利用 Transformer 的自注意力捕获长距离依赖关系。通过注意力引导机制增强注意力内部的信息流动并最小化局部空间信息损失,使用 CoordAttention 模块对特征参数、充放电阶段、老化周期信息进行动态加权,实现对特征关系的全面建模。通过不同充电策略和不同放电策略的数据集进行验证,证明了 AEUniformer 具有更高的准确性,更快和更早的预测,以及更好的泛化性,在加速锂电池的设计优化、在线诊断和回收领域具有强大的潜力。

#### 参 考 文 献

- [1] ZHANG S Z, ZHAI B Y, Guo X, et al. Synchronous Estimation of State of Health and Remaining Useful Lifetime for Lithium-Ion Battery Using the Incremental Capacity and Artificial Neural Networks[J]. *Energy Storage*, 2019, 26.
- [2] YANG X G, LENG Y J, ZHANG G S, et al. Modeling of Lithium Plating Induced Aging of Lithium-Ion Batteries: Transition From Linear To Nonlinear Aging[J]. *Power Sources*, 2017, 360: 28-40.
- [3] ZHAO B, ZHANG W G, ZHANG Y R, et al. Research on the Remaining Useful Life Prediction Method for Lithium-Ion Batteries by Fusion of Feature Engineering and Deep Learning[J]. *Applied Energy*, 2024, 358.
- [4] 段慧云, 夏威, 邵杰, 等. 基于充电健康因子优化和数据驱动的锂电池剩余使用寿命预测[J]. *汽车技术*, 2024(1): 20-26.
- DUAN H Y, XIA W, SHAO J, et al. A Data-Driven Remaining Useful Life Prediction Approach for Lithium-Ion Batteries Based on Charging Health Feature Optimization[J]. *Automobile Technology*, 2024(1): 20-26
- [5] ZHANG C F, DONG M X, OTA K R. Enabling Computational Intelligence for Green Internet of Things: Data-Driven Adaptation in LPWA Networking[J]. *IEEE Comput. Intell. Mag.* 2020, 15 (1): 32-43.
- [6] SEVERSON K A, ATTIA P M, JIN N, et al. Data-Driven Prediction of Battery Cycle Life Before Capacity Degradation[J]. *Nature Energy*, 2019, 4(5): 383-391.
- [7] ZHAO W J, DING W, ZHANG S J, et al. A Deep Learning Approach Incorporating Attention Mechanism and Transfer Learning for Lithium-Ion Battery Lifespan Prediction[J]. *Journal of Energy Storage*, 2024, 75.
- [8] HOU Q B, ZHOU D, FENG J. Coordinate Attention for Efficient Mobile Network Design[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville TN USA. Nashville, IEEE, 2021: 13713-13722.
- [9] MA G J, XU S, JIANG B, et al. Real-Time Personalized Health Status Prediction of Lithium-Ion Batteries Using Deep Transfer Learning[J]. *Energy & Environmental Science*, 2022, 15(10): 4083-4094.
- [10] HSU C W, XIONG R, CHEN N Y, et al. Deep Neural Network Battery Life and Voltage Prediction by Using Data of One Cycle Only[J]. *Applied Energy*, 2022, 306.
- [11] HONG J, LEE D H, JEONG E R, et al. Towards the Swift Prediction of The Remaining Useful Life of Lithium-Ion Batteries with End-To-End Deep Learning[J]. *Applied Energy*, 2020, 278.
- [12] YANG F F, WANG D, XU F, ET al. Lifespan Prediction of Lithium-Ion Batteries Based on Various Extracted Features and Gradient Boosting Regression Tree Model[J]. *Journal of Power Sources*, 2020, 476.
- [13] COUTURE J, LIN X K. Image-and Health Indicator-Based Transfer Learning Hybridization for Battery RUL Prediction[J]. *Engineering Applications of Artificial Intelligence*, 2022, 114.
- [14] GAO M X, FEI Z C, GUO D X, et al. A Multi-Stage Time Series Processing Framework Based on Attention Mechanism for Early Life Prediction of Lithium-Ion Batteries[J]. *Journal of Energy Storage*, 2024, 84.

(责任编辑 王 一)

修改稿收到日期为 2024 年 6 月 6 日。