

# 基于生成对抗 – 元迁移协同的锂离子电池剩余使用寿命动态预测

孟昌皓, 刘奕彤, 文佳睿, 王国强\*

上海工程技术大学 数理与统计学院, 上海 201620

DOI:10.61369/ASDS.2025100011

**摘 要 :** 锂离子电池剩余使用寿命 (Remaining Useful Life, RUL) 预测是保障设备运行安全与实现智能运维的关键技术挑战。然而, 现有方法仍面临小样本数据稀缺、特征提取高度依赖人工经验以及模型泛化能力不足等挑战。为此, 本文提出一种融合数据增强与深度学习的 RUL 预测框架, 旨在提升预测精度与模型鲁棒性。首先, 基于电池容量退化曲线的演化趋势, 采用模糊 C 均值聚类对退化模式进行划分, 并结合 Wasserstein 梯度惩罚生成对抗网络实现条件式数据增强, 生成与真实退化趋势一致的合成样本, 有效缓解小样本问题。其次, 设计基于元学习优化的自编码器, 通过动态调整学习率与动量参数, 提升特征提取的稳定性与鲁棒性, 克服传统自编码器收敛不稳定的问题。接着, 构建融合自适应注意力机制的双向长短期记忆网络, 利用层次化注意力机制聚焦关键时间步特征以增强时序建模能力。最后, 在 HNEI 和 CALCE 公开锂离子电池数据集上对所提方法进行验证。实验结果表明, 本文所提方法在提升锂离子电池 RUL 预测精度方面具有显著优势。

**关 键 词 :** 剩余使用寿命预测; 智能运维; WGAN-GP; BiLSTM; 元自编码器

## Dynamic Prediction of Lithium-Ion Battery Remaining Useful Life Based on Generative Adversarial-Meta Transfer Learning Collaboration

Meng Changhao, Liu Yitong, Wen Jiarui, Wang Guoqiang\*

School of Mathematics and Statistics, Shanghai University of Engineering Science, Shanghai 201620

**Abstract :** Predicting the Remaining Useful Life (RUL) of lithium-ion batteries represents a critical technical challenge for ensuring equipment operational safety and enabling intelligent operation and maintenance. However, existing methods still suffer from small-sample data scarcity, heavy reliance on handcrafted features, and poor model generalization performance. To address these issues, this paper proposes a RUL prediction framework integrating data augmentation and deep learning to enhance prediction accuracy and model robustness. First, Fuzzy C-Means (FCM) clustering is applied to categorize battery degradation patterns based on the evolution of capacity degradation curves, and the Wasserstein GAN with gradient penalty (WGAN-GP) is employed for conditional data augmentation, generating synthetic samples consistent with real degradation trends to effectively alleviate the small-sample data scarcity issue. Second, an autoencoder optimized through meta-learning is designed to dynamically adjust the learning rate and momentum parameters, thereby improving the stability and robustness of feature extraction and overcoming the convergence instability of traditional autoencoders. Subsequently, a Bidirectional Long Short-Term Memory (BiLSTM) network equipped with a hierarchical adaptive attention mechanism is constructed, which automatically focuses on key time-step features to enhance temporal modeling capability. Finally, the proposed method is evaluated on the publicly available NASA and CALCE lithium-ion battery datasets. Experimental results demonstrate that the proposed approach achieves significantly higher RUL prediction accuracy compared to baseline methods.

**Keywords :** remaining useful life prediction; intelligent operation and maintenance, WGAN-GP; BiLSTM; meta-autoencoder

基金项目: 国家自然科学基金“高维数据统计推断中协方差矩阵估计的优化模型与算法研究”(11971302)。

作者简介:

孟昌皓, 上海工程技术大学数理与统计学院, 本科, 研究方向为机器学习、深度学习、故障诊断与寿命预测;

刘奕彤, 上海工程技术大学数理与统计学院, 硕士研究生, 研究方向为故障诊断与寿命预测;

文佳睿, 上海工程技术大学数理与统计学院, 硕士研究生, 研究方向为剩余寿命预测。

通讯作者: 王国强, 上海工程技术大学数理与统计学院, 教授, 博士生导师, 研究方向为最优化理论与算法、高维数据统计推断、金融统计与风险管理、统计优化、信用评估、智能运维、机器学习和人工智能等。

## 引言

锂离子电池因其高能量密度、高输出电压、长循环寿命、较低自放电率及环境友好性，已广泛应用于多个领域，包括电网储能、电动汽车、通信基站等关键行业，并在航空、航天、航海及军事通信等高科技领域展现出重要的技术价值<sup>[1]</sup>。随着全球能源结构的转型，锂离子电池的市场需求持续增长，其应用场景不断扩展。电池在长期运行过程中，由于内部电化学反应的不可逆退化，其性能逐渐衰减，进而影响剩余使用寿命（Remaining Useful Life, RUL）和运行安全性<sup>[2]</sup>。准确预测 RUL 对于保障电池运行的安全性与可靠性、优化维护策略至关重要，有助于预防突发故障、降低安全隐患并减少资源浪费<sup>[3]</sup>。

近年来，锂离子电池的 RUL 预测已成为国内外研究的热点，并取得了显著进展。然而，现有预测模型仍然面临诸多挑战，包括如何构建高质量训练数据集、缓解小样本问题、精准表征电池退化特征并挖掘深层时序信息等<sup>[4]</sup>。目前，锂离子电池 RUL 预测方法主要分为机理模型、数据驱动和混合方法三大类：基于机理的预测方法主要依赖等效电路模型、电化学模型或经验退化模型，通过物理化学原理描述电池的衰退过程。然而，该类方法通常存在数学建模复杂、计算成本高、参数标定困难等问题。例如，基于粒子滤波的 RUL 预测方法能够较好地跟踪电池的非线性退化过程<sup>[5]</sup>，但在面对复杂工况时，其预测性能仍受限。数据驱动方法借助机器学习与深度学习技术，通过大规模电池退化数据学习预测模型，无需深入理解电池退化的物理机制，因此在适应性、计算效率及鲁棒性方面表现优异<sup>[6]</sup>。例如，支持向量机（Support Vector Machine, SVM）、高斯过程回归（Gaussian Process Regression, GPR）、循环神经网络（Recurrent Neural Network, RNN）及长短期记忆网络（Long Short-Term Memory, LSTM）等方法已成功应用于锂离子电池的 RUL 预测<sup>[7-10]</sup>。其中，GPR 能够有效量化预测的不确定性，而 LSTM 擅长捕捉时间序列中的长期依赖特征。此外，结合卷积神经网络（Convolutional Neural Network, CNN）与 LSTM 的混合模型，能够同时提取局部时序模式与全局依赖关系，进一步提升预测性能<sup>[11]</sup>。混合方法融合了机理模型和数据驱动方法的优势，在提高预测准确度的同时，增强了模型的泛化能力。例如，粒子滤波（Particle Filter, PF）结合神经网络的方法已被用于锂离子电池 RUL 预测<sup>[12]</sup>。此外，数据驱动方法的集成学习策略，如结合 CNN 与 LSTM 的多模态模型，能够提升预测的稳健性，降低数据噪声的影响<sup>[13、14]</sup>。

尽管混合方法的研究已取得突破，但现有研究仍面临数据稀缺性与模型泛化能力不足等关键问题。特别是，在历史数据有限或质量较低的情况下，预测模型的性能可能显著下降。针对这一挑战，本文提出一种基于梯度惩罚生成对抗网络（Wasserstein GAN with Gradient Penalty, WGAN-GP）的数据增强框架，用于提升模型输入特征的多样性，以改善 RUL 预测的泛化能力<sup>[15、16]</sup>。同时，考虑到复杂工程设备的 RUL 受多个相互关联部件的退化影响<sup>[16]</sup>，以及数据量的限制，本文进一步引入模糊 C 均值聚类（Fuzzy C-Means, FCM），结合 WGAN-GP 的条件生成机制，实现退化模式感知的数据增强，从而优化 RUL 预测性能。然而，现有方法在特征提取方面仍然高度依赖人工经验，导致模型训练受限、参数调节过程繁琐。为此，本文提出基于自编码器（Autoencoder）与元学习（Meta-Learning）的特征优化策略。该方法不仅能够高效学习数据的深层特征表示，还能在多任务环境下提升模型的适应能力。研究表明，双向长短期记忆网络（Bidirectional Long Short-Term Memory, BiLSTM）在序列预测任务中的表现优于单向 LSTM<sup>[17]</sup>，且引入注意力机制（Attention Mechanism）能够进一步提高预测精度。为此，本文结合 BiLSTM 与自适应注意力机制，并采用层次注意力策略，以缓解 Transformer 结构的计算复杂度问题，同时增强局部信息处理能力，从而进一步提升 RUL 预测的准确性<sup>[18]</sup>。

本文主要贡献如下：提出基于 WGAN-GP 的退化模式感知数据增强框架，通过模糊 C 均值聚类引导数据生成，提高 RUL 预测的泛化能力；构建融合自编码器与元学习的特征提取策略，优化数据表示能力以提升模型在多任务环境下的适应性；结合 BiLSTM 与自适应注意力机制，增强时间序列特征建模能力，有效提升 RUL 预测的准确性和稳健性。本文的研究工作为锂离子电池剩余寿命预测提供了一种高效且稳健的解决方案，为未来复杂工业系统的智能健康管理奠定了理论与实践基础。

## 一、基础模型介绍

### （一）自编码器模型框架

自编码器是一种无监督学习方法，其目标是通过编码器将输入数据映射到低维潜在空间（即编码过程），然后使用解码器从该低维空间重建原始数据。自编码器由两部分组成：编码器和解码器，其主要目标是最小化重构误差。下面简要回顾自编码器的模型框架，详细可参考<sup>[19]</sup>。

编码器：

$$Z = f_{\text{encode}}(X; \theta_{\text{encode}})$$

解码器：

$$\hat{X} = f_{\text{decode}}(Z, \theta_{\text{decode}})$$

损失函数：

$$L_{\text{reconstruction}} = \frac{1}{N} \sum_{i=1}^N \|X_i - \hat{X}_i\|^2$$

正则化项：

$$L_{\text{reg}} = \lambda \sum_j \|\theta_j\|^2$$

自编码器的总损失函数:

$$L_{\text{autoencoder}} = L_{\text{reconstruction}} + L_{\text{reg}}$$

其中:  $f_{\text{encode}}$  是编码器函数, 包含了多个全连接层和激活函数, 其参数为  $\theta_{\text{encode}}$ ;  $f_{\text{decode}}$  是解码器函数, 同样由多个全连接层和激活函数构成, 其参数为  $\theta_{\text{decode}}$ 。

## (二) 元学习器模型

元学习的目标在于使模型在遇到新任务时能够更快速地适应。其核心思想是通过优化过程来学习如何有效地进行模型优化。具体来说, 元优化器可以用于更新模型的超参数, 例如学习率和动量等, 其中关键特性之一便是动量优化。动量优化不仅考虑当前梯度, 还结合历史梯度信息来更新模型参数, 从而使参数更新过程更加平稳, 减少波动并加快收敛速度。在实际训练中, 元学习优化器会同时关注训练集和验证集上的共同损失, 以优化模型性能。下面简要回归元学习器模型, 详细可参考<sup>[20]</sup>。

训练集损失函数:

$$L_{\text{train}} = \frac{1}{N_{\text{train}}} \sum_{i=1}^N \|X_i - \hat{X}_i\|^2 + \lambda \sum_j \|\theta_j\|^2$$

验证集损失函数:

$$L_{\text{val}} = \frac{1}{N_{\text{val}}} \sum_{i=1}^N \|X_i - \hat{X}_i\|^2 + \lambda \sum_j \|\theta_j\|^2$$

动量优化的更新规则:

$$v_{t+1} = \beta_{v_t} + (1 - \beta) \nabla_{\theta} L_{\text{train}}$$

$$\theta_{t+1} = \theta_t - \eta v_{t+1}$$

共同损失函数:

$$L_{\text{meta}} = \alpha L_{\text{train}} + (1 - \alpha) L_{\text{val}}$$

其中:  $N_{\text{train}}$  和  $N_{\text{val}}$  分别是训练集和验证集的样本数量;  $X_i$  和  $\hat{X}_i$  分别是第  $i$  个样本的真实值和重构值;  $v_{t+1}$  表示当前时间步的动量,  $\beta_{v_t}$  是动量衰减因子, 控制历史梯度的影响;  $\nabla_{\theta} L_{\text{train}}$  是损失函数对模型参数的梯度,  $\eta$  是学习率。

## (三) BiLSTM 模型

BiLSTM 通过引入记忆单元来捕捉长期依赖关系, 其核心在于三个门控机制: 输入门、遗忘门和输出门。双向 LSTM 由两个 LSTM 层构成, 其中一个按时间顺序处理序列, 另一个则按逆时间顺序处理序列, 最终将两个方向的隐藏状态进行拼接。下面简要回顾 BiLSTM 的计算过程, 详细可参考<sup>[21]</sup>。

LSTM 单元的计算过程为:

$$f_t = \sigma(W_f \cdot [h_t - 1, x_t] + b_f)$$

$$i_t = \sigma(W_i \cdot [h_t - 1, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_t - 1, x_t] + b_c)$$

$$C_t = f_t * C_t - 1 + i_t * \tilde{C}_t$$

$$o_t = \sigma(W_o \cdot [h_t - 1, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

其中:  $f_t$  是遗忘门的激活值,  $i_t$  是输入门的激活值;  $\tilde{C}_t$  是候选记忆内容;  $C_t$  是当前记忆单元的状态;  $o_t$  是输出门的激活值;  $h_t$  是当前隐藏状态;  $W_f, W_i, W_c, W_o$  是权重矩阵;  $b_f, b_i, b_c, b_o$  是偏置向量;  $*$  是元素级乘法。

BiLSTM 的隐藏状态通过拼接前向和后向 LSTM 的隐藏状态得到:

$$h_t = [\bar{h}_t, \overrightarrow{h}_t],$$

其中,  $\bar{h}_t$  表示从第一个时刻到第  $t$  时刻的正向 LSTM 隐含状态,  $\overrightarrow{h}_t$  表示从最后一个时刻到第  $t$  时刻的反向 LSTM 隐含状态。

## (四) 注意力机制与残差连接

注意力层的核心思想是通过输入序列中每个时刻的隐藏状态进行加权求和, 从而生成一个上下文向量。具体来说, 注意力机制会根据每个时刻的输入信息对隐藏状态分配不同的权重, 这些权重是通过学习得到的。权重的大小决定了该时刻隐藏状态对生成上下文向量的贡献程度, 即某一时刻的隐含信息对于当前任务的重要性<sup>[22]</sup>。通过这种方式, 注意力层能够使模型聚焦于序列中最重要的部分, 从而提升模型在序列建模中的表现和准确性。

在该层中, 具体步骤如下:

首先, 给定输入序列的每个时刻的隐藏状态  $h_t$ , 通过加权矩阵  $W$  和偏置项  $b$  计算评分向量, 即

$$\text{score}_t = \tanh(W h_t + b)$$

其次, 通过权重矩阵  $V$  计算注意力权重, 即

$$\alpha_t = \text{softmax}(V^T \text{score}_t)$$

其中, 注意力权重  $\alpha_t$  表示每个时刻对最终输出的贡献程度。

最后, 对输入的隐藏状态加权求和, 得到上下文向量, 即

$$c = \sum_{t=1}^T \alpha_t h_t, \quad c \in R^{2d}$$

该上下文向量表示对输入序列的加权汇总, 包含了不同时间步的上下文信息。

在深度学习中, 残差连接用于将输入直接加到输出上, 从而缓解梯度消失问题, 并提升网络的训练效果<sup>[23]</sup>。在本文模型中, 残差连接的形式是将经过注意力层输出的上下文向量  $c$  与其经过全连接层后的输出相加, 具体表示为

$$\text{residual} = c + \text{Dense}(c)$$

其中:  $\text{Dense}(c)$  表示对上下文向量  $c$  进行一次全连接层的操作, 并使用 ReLU 激活函数。

## 二、模型改进

### (一) 基于元学习的自编码器模型

本文通过结合自编码器与元学习优化器的方法旨在提高模型训练的效率和泛化能力以及训练平稳性。自编码器通过将数据块

射到低维潜在空间,进行有效的降维与特征提取,而元学习优化器通过动态调整如学习率和动量等超参数,结合训练集与验证集的损失,优化模型更新策略。该结合能够加速收敛过程、避免过拟合,同时提高模型在未见数据上的表现。元学习优化器通过引入历史梯度信息和自适应更新机制,使得训练过程更加平滑、稳定,最终提升自编码器的训练效率和泛化能力。具体步骤如下:

步骤1 前向传播:给定输入数据  $X$ , 经过编码器映射得到低维表示  $Z$ , 然后通过解码器重构输入  $\hat{X}$ 。

步骤2 计算损失:自编码器的损失包括  $L_{reconstruction}$  和  $L_{reg}$ , 结合训练与验证集损失。

步骤3 梯度计算与优化:元学习优化器计算  $\nabla_{\theta} L_{train}$ , 并利用动量更新规则调整如学习率等模型参数。

步骤4 训练过程的迭代:通过  $L_{train}$  和  $L_{val}$  动态调整参数,最终使得自编码器能够有效地学习数据的低维表示。

为了验证元自编码器的优越性,本实验在 HNEI 数据集上进行了自编码器训练,并对训练损失的变化过程进行了对比分析,结果如图1、2所示。从图中可以看出,相较于传统自编码器,元自编码器在训练过程中收敛表现更稳定,损失下降更平滑,最终达到更优的收敛效果,表明其具备更强的泛化能力和鲁棒性。




图1: 自编码器训练损失曲线

Fig.1: Training Loss Curve of Autoencoder



图2: 元自编码器训练损失曲线

Fig.2: Training Loss Curve of Meta-Autoencoder

## (二) 基于注意力机制的 BiLSTM 模型改进

在文献24验证注意力机制在该类问题中有效性的基础上,本文提出了一种结合注意力层与层次化注意力层的多层次注意力机制,使 BiLSTM 能够更精准地聚焦于关键时间步的显著特征,从而进一步提升预测的精度与可解释性<sup>[24]</sup>。此外,残差连接的引入有效缓解了深层神经网络中的梯度消失问题,并在训练过程中增强了模型的稳定性。图3展示了包含两层次注意力机制的 BiLSTM 结构。




图3: 改进的 BiLSTM 的框架图

Fig.3: Framework of the Improved BiLSTM

为了验证引入注意力机制的 BiLSTM 模型的优势,本文于后文实验部分中列出了 BiLSTM 与引入的注意力机制的 BiLSTM 的相关指标对比情况。

BiLSTM 与注意力机制结合的具体步骤如下:

步骤1 输入: 序列数据  $X = (x_1, x_2, \dots, x_T)$ 。

步骤2 BiLSTM: 输出 BiLSTM 的  $h_t$  隐藏状态。

步骤3 自适应注意力层: 输出上下文向量  $c_1$ 。

步骤4 层次化注意力层: 输出上下文向量  $c_2$ 。

步骤5 拼接: 自适应注意力层与层次化注意力层的输出特征拼接。

步骤6 残差连接: 生成残差表示 *residual*。

步骤7 全连接层: 经过全连接层,得到最终的预测值。

## 三、实验过程与结果分析

在前文改进模型的基础上,本文基于两个不同来源的数据集进行了锂离子电池 RUL 预测实验证明改进模型有效性和泛化能力,实验过程包含以下关键阶段:首先对原始数据进行必要的预



处理。其次，实施特征工程，包括构建滚动窗口特征、小波包变换特征，以及利用元自编码器和模糊 C 均值聚类提取潜在健康因子，并生成聚类簇。接着，采用 WGAN-GP 进行数据增强以丰富样本多样性。为进一步优化模型性能并提升数据的丰富性，使用训练好的 WGAN-GP 生成器为每个聚类簇生成合成样本，并将其与真实数据结合。然后，通过滑动窗口方法将数据转换为序列形式，以满足时间序列建模的需求。数据集按照时间顺序划分为训练集和测试集，确保在模型训练过程中的数据独立性。最终，引入带有注意力机制的 BiLSTM 模型进行训练及性能评估。整体流程如图 4 所示。




图 4：总流程概述图

Fig. 4: Overview of the Overall Process

(一) 数据集与数据预处理

1. 数据集

本文采用 HNEI 和 CALCE 数据集，以验证本文提出的模型在锂离子电池 RUL 预测任务中的有效性与模型的泛化能力。

HNEI 数据集来源于夏威夷自然能源研究所 (Hawaii Natural Energy Institute)，包含 14 个 NMC-LCO 18650 型号锂离子电池的实验数据。这些电池的额定容量均为 2.8 Ah，在 25° C 恒温条件下，以 C/2 速率的恒流恒压 (CC-CV) 方式充电，并采用 1.5C 速率放电，循环测试超过 1000 次。

CALCE 数据集是由马里兰大学先进生命周期工程中心 (Center for Advanced Life Cycle Engineering, CALCE) 提供，本文选取其中的 CS2\_35 电池数据。

通过结合不同来源的数据，本文的方法不仅保证了实验的严谨性，还增强了模型在不同电池类型和使用条件下的适应性。多数据源的融合避免了模型仅在相同工况下训练，确保了锂离子电

池 RUL 预测的科学性与鲁棒性。

2. 数据预处理

本文综合考虑肯德尔相关系数、特征重要性分析以及锂离子电池的相关背景知识等<sup>[25、26]</sup>，选择以下健康因子，如表 1 和表 2 所示。

表 1：健康因子选择 (HNEI) Table 1: Selection of Health Factors (HNEI)	
Feature Columns	Description
Cycle_Index	Cycle index
Discharge Time (s)	Discharge time (in seconds)
Decrement 3.6–3.4V (s)	Decrement time for voltage range 3.6–3.4V
Max. Voltage Dischar.(V)	Max voltage during discharge
Min. Voltage Charg. (V)	Min voltage during charge
Time at 4.15V (s)	Time spent at 4.15V
Time constant current (s)	Time constant current is applied
Charging time (s)	Charging time (in seconds)
表 2：健康因子选择 (CALCE) Table 2: Selection of Health Factors (CALCE)	
Feature Columns	Description
Charge_Capacity(Ah)	Charge capacity in ampere-hours (Ah)
Current(A)	Current in amperes (A)
Voltage(V)	Voltage in volts (V)
Discharge_Capacity(Ah)	Discharge capacity in ampere-hours (Ah)
Charge_Energy(Wh)	Charge energy in watt-hours (Wh)
Discharge_Energy(Wh)	Discharge energy in watt-hours (Wh)
dV/dt(V/s)	Rate of change of voltage with respect to time in volts per second (V/s)
Internal_Resistance(Ohm)	Internal resistance of the battery in ohms ( $\Omega$ )

同时，本文对健康因子使用 Z-score 标准化，对于目标列采用最小 - 最大标准化。

(二) 特征工程

在特征工程阶段，本文采用多层次特征提取方法。首先，利用移动窗口技术对时间序列数据进行滑动处理。其次，引入小波包变换，并采用元自编码器对特征进行降维。最后，应用模糊 C 均值聚类算法。特征工程流程如图 5 所示。

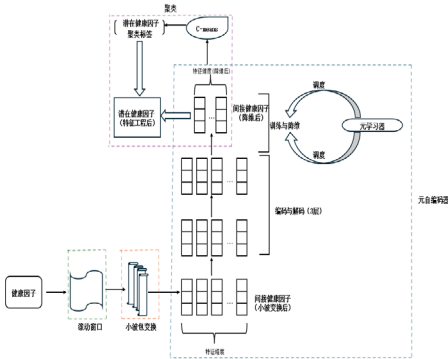


图 5：特征工程流程图

Fig.5: Feature Engineering Workflow

1. 滚动窗口技术

为了更精确地捕捉时间序列数据中的趋势和波动，本文通过对每个原始特征应用不同大小的移动窗口及统计量来构建新特征，具体细节如表3所示。这些滚动统计特征能够有效反映健康因子的短期波动与长期趋势，从而增强模型对健康因子动态特性的理解。此外，利用特定窗口大小的滚动平均值对数据进行平滑处理，有助于减少噪声，进而提升小波包变换的效果，使得特征提取过程更加平稳和稳定。

表3: 统计量与窗口大小 (共用)  
Table 3: Statistics and Window Size (Common)

特征名称	窗口大小	指标描述
Rolling Mean (15)	15	窗口大小为 15 的滚动平均值
Rolling Std (15)	15	窗口大小为 15 的滚动标准差
Rolling Max (15)	15	窗口大小为 15 的滚动最大值
Rolling Min (15)	15	窗口大小为 15 的滚动最小值
Rolling Mean (20)	20	窗口大小为 20 的滚动平均值
Rolling Std (20)	20	窗口大小为 20 的滚动标准差
Rolling Max (20)	20	窗口大小为 20 的滚动最大值
Rolling Min (20)	20	窗口大小为 20 的滚动最小值

2. 小波包变换

锂离子电池数据中常见的局部突变现象通常反映了电池状态的急剧变化，这对健康预测、RUL 估计及故障检测等任务具有重要意义<sup>[26, 27]</sup>。为了进一步增强特征的频域表示，本文采用小波包变换对增强后的特征进行频域分析。在选择小波基时，选用了 Daubechies 4 (db4) 小波基，因其在平滑性和局部化能力方面具有显著优势，能够更精确地捕捉信号中的细节特征，尤其适用于分析具有局部突变或快速变化的时间序列信号。

在小波包变换的层级选择上，考虑到数据点数与变换层级数之间的对数关系以及特征提取的需求，本研究将变换层级设置为 3。此设置既能充分揭示信号中的多频率信息，又在计算复杂度和频域分辨率之间取得了良好的平衡，从而提高了分析效率与准确性。通过 WPT，能够精确捕捉信号中的细节和周期性模式，进一步增强特征的频域表示，为后续元自编码器和聚类模型的学习提供更加丰富有效的特征支持。小波包变换的效果展示见图6和图7。




图6: 小波包变换效果对比图 (HNEI)  
Fig.6: Comparison of Wavelet Packet Transform Effects (HNEI)




图7: 小波包变换效果对比图 (CALCE)  
Fig. 7: Comparison of Wavelet Packet Transform Effects (CALCE)

3. 元自编码器

本文接下来对高维小波包变换特征进行降维处理。选取编码维度为 8，旨在有效降低特征维度的同时保留重要信息。表4详细列出了自编码器的参数选择及其理由。

表4: 参数选择及其选择理由 (共用)  
Table 4: Parameter Selection and Rationale (Common)

参数	选择理由
编码维度: 8	保留足够的信息以支持后续预测任务，同时降低维度。
隐藏层单元: 1024, 512	深层网络结构提升特征表达能力。
激活函数: LeakyReLU	防止“死亡神经元”问题，提高模型的非线性表达能力。
批归一化: 使用	加速训练过程，稳定模型收敛。

通过引入元自编码器模型并结合元学习框架，增强了自编码器的表达能力，使其能够通过非线性映射更精确地捕捉健康因子的潜在表示。在此过程中，元自编码器不仅保留了原始数据中的关键信息，还有效地减少了特征维度，提取了潜在健康因子，提升了模型的泛化能力，并降低了后续任务的计算复杂度。训练中的元学习优化器引导模型在不同数据集上快速适应，确保了自编码器在多任务中的稳定收敛。图8和图9展示了训练集和验证集上损失曲线的变化，进一步体现了训练效果。




图8: 元自编码器训练损失曲线图 (HNEI)  
Fig.8: Training Loss Curve of the Meta-Autoencoder (HNEI)




图9：元自编码器训练损失曲线图（CALCE）

Fig.9: Training Loss Curve of the Meta-Autoencoder (CALCE)

4. 模糊 C 均值聚类

本文采用模糊 C 均值聚类对降维后的特征进行聚类分析，从而有效揭示了数据的潜在结构。与传统的 K-Means 等硬聚类方法相比，其允许数据点同时隶属于多个簇，因此更适合处理具有模糊边界和复杂结构的数据。在本实验中，锂离子电池 RUL 相关的特征通常相互复杂且高度关联<sup>[28]</sup>，因此选择了软聚类方法。为了确定最佳聚类数，本文结合模糊分区系数、轮廓系数和 Calinski-Harabasz 指数等多种评价指标（详见表5和表6）。根据肘部法则的综合评估，HNEI 和 CALCE 的最佳聚类数均为3。最终，这些簇标签为后续 WGAN-GP 数据生成提供了条件支持，不仅增强了数据的多样性和覆盖范围，还作为 BiLSTM 模型的输入，帮助模型更好地识别不同时间段内锂离子电池的状态，进而提高了训练和预测效果。

表5：聚类数选择指标（HNEI）

Table 5: Cluster Number Selection Criteria (HNEI)

聚类数	模糊分区数	轮廓系数	Calinski-Harabasz 指数
2	0.8249	0.5079	11399.0814
3	0.7840	0.5864	14581.8557
4	0.6929	0.4628	11858.7251
5	0.6426	0.3934	10033.8812
6	0.6358	0.4091	10255.4739
7	0.5896	0.3700	9014.7011
8	0.5862	0.3752	8816.1670
9	0.5488	0.3351	8020.1542
10	0.5258	0.3195	7274.6745

表6：聚类选择指标（CALCE）

Table 6: Cluster Selection Criteria (CALCE)

聚类数	模糊分区数	轮廓系数	Calinski-Harabasz 指数
2	0.8274	0.5696	25937.8647
3	0.8439	0.6375	22636.0165
4	0.7782	0.5176	17094.1645
5	0.7810	0.5521	57612.9704
6	0.7270	0.4481	11172.8021
7	0.7314	0.4806	43681.6356
8	0.7145	0.4802	37992.6625
9	0.6625	0.3819	7049.3613

聚类数	模糊分区数	轮廓系数	Calinski-Harabasz 指数
10	0.6904	0.4577	38902.5276

从特征工程的训练过程和结果可以看出，采用元自编码器及其他特征工程技术能够有效挖掘数据中的潜在信息。通过这些技术的应用，模型不仅在数据表示学习方面获得了更为精确的特征表示，还在数据降维与噪声抑制方面取得了显著优化，特别是采用了平稳降维方法。这些特征工程技术协同作用，有效提升了数据质量，提取了潜在健康因子及其潜在标签，增强了后续模型的预测能力，从而为锂离子电池 RUL 预测提供了更加稳健和可靠的基础。

（三）数据增强：生成对抗网络

在 RUL 预测任务中，数据的数量和多样性对模型的预测性能至关重要。然而，在实际应用中常常面临数据量不足或数据分布不均衡的问题，这使得在不同状态下收集足够的锂离子电池数据进行训练变得困难，从而严重影响了模型的泛化能力和鲁棒性。特别是在锂离子电池领域，由于测试环境、测试周期及实际运行条件的限制，获取充足且多样化的数据往往面临较大挑战。与此同时，本实验通过模糊 C 均值聚类分析发现，HNEI 数据集在各聚类类别中的数据量分别为 7594、4452 和 2918，而 CALCE 数据集在不同聚类类别中的数据量分别为 29122、27770 和 7098，显然存在一定的差异。

为了克服这些挑战，本文提出应用一种基于 Wasserstein 生成对抗网络 (WGAN) 及其梯度惩罚 (Gradient Penalty, GP) 优化的生成对抗网络 (WGAN-GP) 模型进行数据增强。通过引入梯度惩罚项，WGAN-GP 显著提升了训练稳定性，有效缓解了传统生成对抗网络中常见的梯度消失和模式崩溃问题。与传统 GAN 模型相比，WGAN-GP 能够在更少的训练样本下，通过更高的训练稳定性生成质量更高的合成数据<sup>[29]</sup>。详细的流程如图10所示。

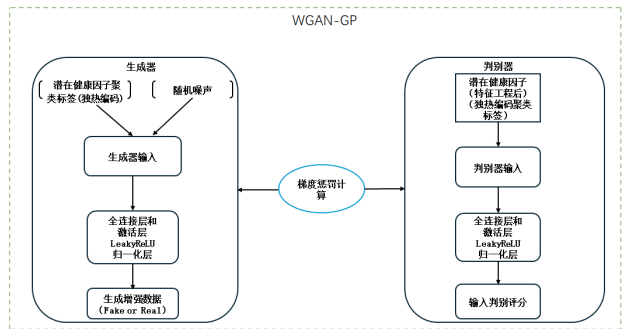


图10：数据增强流程图

Fig.10: Data Augmentation Workflow

具体而言，本文使用 TensorFlow 和 Keras 构建了 WGAN-GP 的生成器和判别器。生成器用于生成与真实锂离子电池数据分布相似的合成数据，而判别器则负责区分真实数据与生成数据。详细的流程和参数选择见图10和表7。

表7：WGAN-GP 参数设置

Table 7: WGAN-GP Parameter Settings

参数名称	值	说明
噪声维度	100	噪声向量的维度
条件维度	best_C	条件向量的维度（最佳聚类数）

参数名称	值	说明
数据维度	自动编码器 降维后特征 维度	生成器和判别器的输入 / 输出维度
批量大小	128	WGAN-GP 训练的批量大小
训练轮次	1000	WGAN-GP 的训练轮次数
判别器训练步数	2	每个生成器训练步骤中判别器 训练次数
梯度惩罚系数	10.0	梯度惩罚项的权重系数
学习率	0.0002	Adam 优化器的学习率
Beta_1 (beta_1)	0.5	Adam 优化器的 Beta_1 参数
Beta_2 (beta_2)	0.9	Adam 优化器的 Beta_2 参数

通过上述参数设置，WGAN-GP 在训练过程中能够稳定地生成高质量的合成数据。为了进一步提升训练效果，我们采用最大均值差异作为关键训练指标，并引入早停机制，确保模型在最优状态下停止训练。具体步骤如下：

首先，为了提升锂离子电池 RUL 预测模型的性能和数据多样性，我们利用训练好的 WGAN-GP 生成器为每个聚类簇生成 200 个合成样本，从而增加数据基数。这一过程包括生成随机噪声向量、构建对应的独热编码条件向量，并通过生成器生成合成的

表 8: BiLSTM 参数选择  
Table 8: BiLSTM Parameter Selection

参数	描述	设置值
输入维度	输入序列每个时间步的特量	30
隐藏层维度	LSTM 隐藏层的神经元数量	64, 32
层数	LSTM 层的堆叠数量	2
输出维度	模型输出的维度	1
Dropout 率	防止过拟合的 Dropout 比例	0.1
学习率	优化器的学习率	动态衰减
学习率衰减策略	学习率衰减策略	ExponentialDecay
训练周期数	模型训练的总周期数	200
批量大小	每次训练的样本数量	64

在 BiLSTM 模型的基础上，本文比较了标准 BiLSTM 与带有注意力转移机制的 BiLSTM 两种模型的效果。自适应注意力层通过学习权重，动态聚焦序列中对锂离子电池 RUL 预测至关重要的时间步，如充放电周期中的关键时刻，从而提高预测精度。层次注意力层在此基础上进一步引入第二层注意力机制，捕捉更深层次的特征关系，能够在不同层级识别锂离子电池 RUL 变化的复杂模式。此外，双重注意力机制相互结合，不仅提升了模型的表达能力和预测效果，还避免了复杂注意力转移机制可能导致的过拟合和效率低下的问题。

结果表明，引入混合注意力机制后，模型的各项评价指标（如决定系数、均方误差、均方根误差、平均绝对误差）均优于未使用注意力机制的模型。因此，采用该模型能够更有效地捕捉序列数据中的关键特征，从而提高 RUL 预测的准确性和鲁棒性。HNEI 数据集上两个模型的性能比较见表 9，图 11 展示了预测结果的示意图，直观地显示了实际值与预测值之间的差异。

表 9: 模型的性能比较表 (HNEI)

Table 9: Model Performance Comparison (HNEI)				
Model	MAE	MSE	RMSE	R <sup>2</sup>
BiLSTM	0.0221	0.0012	0.033	0.98
BiLSTM with Hybrid Attention	0.0211	0.0111	0.032	0.99

RUL 特征数据。同时，为这些合成数据分配所属聚类簇的真实标签中位数，以确保标签的一致性和合理性。接着，将生成的合成数据与真实数据在特征、聚类标签及 RUL 标签上进行合并，形成增强后的数据集。通过统计各聚类簇的数据分布，验证合成数据有效地补充了原始数据中的不足，实现了数据集的平衡性。

（四）模型构建与训练

1. 模型准备

为了适应时间序列模型的输入要求，本文采用滑动窗口方法将增强后的数据转换为序列形式。具体而言，设定序列长度为 15，并在每个时间步将特征向量与对应的条件向量进行拼接，生成适合深度学习模型输入的序列数据。数据集按时间顺序划分为 80% 的训练集和 20% 的测试集，以确保模型训练过程中不会发生数据泄漏。

2. 模型训练

本文构建了 BiLSTM 模型，旨在通过同时捕捉序列的前向和后向信息来提升对时序数据的理解。在此基础上，引入自适应注意力层和层次化注意力层，构建多层次注意力机制，从而增强模型对关键时间步和重要特征的关注能力。具体参数选择见下表 8。




图 11: 预测结果示意图 (HNEI)

Fig.11: Illustration of Prediction Results (HNEI)

CALCE 的两个模型的性能比较如表 10 所示，图 12 展示了预测结果的示意图，直观地展示了实际值与预测值之间的差异。



表 10: 模型的性能比较表 (CALCE)  
Table 10: Model Performance Comparison (CALCE)

Model	MAE	MSE	RMSE	R <sup>2</sup>
BiLSTM	0.0189	0.0006	0.024	0.97
BiLSTM with Hybrid Attention	0.008	0.0003	0.0179	0.98

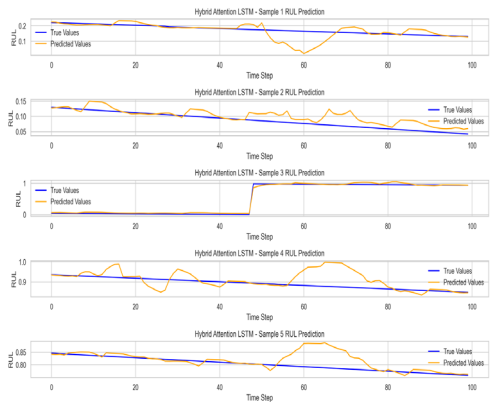


图 12: 预测结果示意图 (CALCE)

Fig.12: Illustration of Prediction Results (CALCE)

此外,带有多重注意力机制的 BiLSTM 在训练过程中的平稳性明显优于标准 BiLSTM 模型,这一现象可以从训练损失曲线和验证损失曲线的变化趋势中观察到(以 CALCE 数据集为例)。如图 13 和图 14 所示,带有多重注意力机制的 BiLSTM 模型在训练过程中表现出更为平滑的损失下降曲线,且损失下降速度较快,训练收敛过程较为稳定。




图 13: BiLSTM 模型的损失曲线

Fig.13: BiLSTM Model Loss Curve




图 14: 带注意力机制的 BiLSTM 模型的损失曲线

Fig. 14: BiLSTM Model Loss Curve with Attention Mechanism

具体来说,标准 BiLSTM 模型在训练过程中存在一定的波动,其损失曲线时常出现震荡,这表明模型在学习过程中可能会

陷入局部最优解,导致收敛速度较慢,并且容易陷入过拟合或欠拟合的状态。相比之下,带有多重注意力机制的 BiLSTM 通过自适应和层次化注意力机制,能够更有效地聚焦于对锂离子电池 RUL 预测最为关键的时间步,从而减少了训练过程中的不必要干扰,提高了模型的学习效率。特别是在训练初期,注意力机制的引入使得模型能够在有限的训练轮次内更好地捕捉到数据中的重要特征,进一步加速了训练过程。

(五) 实验结果对比

本文利用 HNEI 数据集进行锂离子电池健康状态估计和 RUL 预测,并与现有研究进行了对比分析。本文方法与李超等人提出的基于数据扩展的锂离子电池早期寿命在线预测方法进行了对比<sup>[30]</sup>。详细实验结果如表 11 所示。由表 11 可知本文该方法在 HNEI 数据集精度上做出一定的提升(尤其在 MAE 和 RMSE 方面),验证其对于 RUL 预测的有效性。

表 11: 实验结果对比 (HNEI)  
Fig.11: Comparison of Experimental Result (HNEI)

方法	MAE	RMSE	R <sup>2</sup>
GPR+CNN-LSTM	0.5173	0.9982	0.9987
Tr-AttentionLSTM	0.6662	1.0107	0.9982
Transformer	0.7937	1.2072	0.9977
DNN	0.9970	1.4537	0.9978
GPR+CNN-LSTM	0.7351	1.0823	0.9984
本研究	0.0080	0.0320	0.99

本文利用 CALCE 数据集进行锂离子电池健康状态估计和 RUL 预测,并与现有研究进行了对比分析。本文方法与黄煜峰等人<sup>[31]</sup>提出的基于卡尔曼滤波优化 Transformer 模型的预测方法,以及王海瑞等人<sup>[32]</sup>基于生成对抗网络的 RUL 预测方法进行了对比。详细实验结果如表 12 所示。

表 12: 实验结果对比  
Fig.12: Comparison of Experimental Result (CALCE)

来源	预测模型	RMSE	R <sup>2</sup>
黄煜峰等人	RNN	0.0911	0.8214
	MLP	0.0959	0.8047
	LSTM	0.0966	0.8785
	GRU	0.0988	0.8592
	In-Transformer	0.0345	0.9789
王海瑞	CNN-BiLSTM	0.135	\
	CNN-BiGRU	0.038	\
	MsDCNN-Informer	0.0037	\
本研究	BiLSTM	0.0179	0.98

四、结束语

本文针对锂离子电池 RUL 预测中的数据瓶颈与模型局限性,提出一种融合数据增强、元学习优化与注意力机制的多模态解决方案。通过 WGAN-GP 结合 FCM 聚类生成退化模式感知的合成数据,缓解了实际场景中数据稀缺性问题;元学习自编码器通过动态优化策略实现特征表达的鲁棒性提升;BiLSTM 与层次化

注意力机制的结合，有效捕捉了退化过程中的局部突变与长期依赖特征。实验表明，相较于现有方法，本文框架在跨数据集场景下的预测效果和稳定性良好。未来研究可从三方面拓展：其一，引入多源异构数据（如温度、阻抗谱）构建跨模态融合模型；其

二，设计在线增量学习机制以适应电池动态退化过程；其三，探索极端工况（如低温、高倍率充放电）下的退化模式可解释性建模。本研究为锂离子电池健康管理的工程化应用提供了理论依据，并为复杂工业系统的智能运维范式革新提供了参考路径。

# 参考文献

[1] 陈立泉. 锂离子电池改变世界——2019年诺贝尔化学奖成果简析 [J]. 科技导报, 2019, 37(24): 36–40.

[2] 陈建安, 陈曦, POTAPENKO Hanna, 等. 锂电池的电解质安全性的研究进展及军事化前景 [J]. 兵器材料科学与工程, 2025, 48(01): 145–154.

[3] 杜志明, 陈佳伟. 锂离子电池热失控危险性研究进展 [J]. 安全与环境学报, 2021, 21(04): 1523–1532.

[4] 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.

[5] 秦琪, 赵帅, 陈绍伟, 等. 基于粒子群优化粒子滤波的电容剩余寿命预测 [J]. 计算机工程与应用, 2018, 54(20): 237–241+258.

[6] 王志福, 杨忠义, 罗崴, 等. 基于数据驱动的锂离子动力电池剩余使用寿命预测方法综述 [J]. 科学技术与工程, 2023, 23(15): 6279–6289.

[7] 简献忠, 张博, 王如志. 一种改进 RAO 算法与多核 SVM 的锂离子电池寿命预测模型 [J]. 小型微型计算机系统, 2022, 43(11): 2314–2320.

[8] Li L, Wang P, Chao K H, et al. Remaining Useful Life Prediction for Lithium-ion Batteries Based on Gaussian Processes Mixture [J]. PloS One, 2016, 11(9): e0163004.

[9] Chaoui H, Ibe-Ekeocha C C. State of Charge and State of Health Estimation for Lithium Batteries Using Recurrent Neural Networks[J]. IEEE Transactions on Vehicular Technology, 2017, 66(10): 8773–8783.

[10] Zheng S, Ristovski K, Farahat A, et al. Long Short-Term Memory Network for Remaining Useful Life Estimation[C]//2017 IEEE International Conference on Prognostics and Health Management (ICPHM). IEEE, 2017: 88–95.

[11] Chen C, Pecht M. Prognostics of Lithium-ion Batteries Using Model-based and Data-driven Methods[C]//Proceedings of the IEEE 2012 Prognostics and System Health Management Conference. IEEE, 2012: 1–6.

[12] 贺宁, 张思媛, 李若夏, 等. 粒子滤波和 GRU 神经网络融合的锂电池 RUL 预测 [J]. 哈尔滨工业大学学报, 2024, 56(05): 142–151.

[13] 李梦蝶, 赵光, 罗灵鲲, 等. 基于改进 CNN-LSTM 的飞控系统剩余寿命预测 [J]. 计算机工程与应用, 2022, 58(16): 274–283.

[14] Li X, Zhang L, Wang Z, et al. Remaining Useful Life Prediction for Lithium-ion Batteries Based on a Hybrid Model Combining the Long Short-Term Memory and Elman Neural Networks[J]. Journal of Energy Storage, 2019, 21: 510–518.

[15] Liu Y, Wen J, Wang G. A Comprehensive Overview of Remaining Useful Life Prediction: From Traditional Literature Review to Scientometric Analysis. Machine Learning with Application. 2025: 100704.

[16] 裴洪, 胡昌华, 司小胜, 等. 基于机器学习的设备剩余寿命预测方法综述 [J]. 机械工程学报, 2019, 55(08): 1–13.

[17] S. Siami-Namini, N. Tavakoli and A. S. Namin, The Performance of LSTM and BiLSTM in Forecasting Time Series, 2019 IEEE International Conference on Big Data, Los Angeles, CA, USA, 2019, pp. 3285–3292.

[18] 董作林, 宋金岩, 孟子迪. 基于模态分解和深度学习的锂离子电池寿命预测 [J/OL]. 储能科学与技术, 1–12[2025-01-20].

[19] 吴美君, 杨新, 潘超凡, 等. 自编码器结合持续学习: 现状、挑战与展望 [J/OL]. 计算机学报, 1–37[2025-01-20].

[20] 李凡长, 刘洋, 吴鹏翔, 等. 元学习研究综述 [J]. 计算机学报, 2021, 44(02): 422–446.

[21] 鲁南, 欧阳权, 黄良升, 等. 基于注意力机制和多任务 LSTM 的锂电池容量预测方法 [J]. 电气工程学报, 2022, 17(04): 41–50.

[22] 王永, 李行健, 邓江洲. 融合注意力机制的残差神经协同过滤推荐模型 [J]. 运筹与管理, 2024, 33(10): 201–208.

[23] Smagulova K, James A P. Overview of Long Short-Term Memory Neural Networks[J]. Deep Learning Classifiers with Memristive Networks: Theory and Applications, 2020: 139–153.

[24] 刘大同, 周建宝, 郭力萌, 等. 锂离子电池健康评估和寿命预测综述 [J]. 仪器仪表学报, 2015, 36(01): 1–16.

[25] 林娅, 陈则王. 锂离子电池剩余寿命预测研究综述 [J]. 电子测量技术, 2018, 41(04): 29–35.

[26] Li X, Yu D, Byg S V, et al. The development of machine learning-based remaining useful life prediction for lithium-ion batteries[J]. Journal of Energy Chemistry, 2023, 82(07): 103–121.

[27] Ge M F, 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.

[28] 王健雁, 廖成龙, 凌泽. 锂离子电池的循环寿命影响因素研究进展 [J]. 化工新型材料, 2019, 47(S1): 33–35.

[29] Gulrajani I, Ahmed F, Arjovsky M, et al. Improved Training of Wasserstein Gans[J]. Advances in Neural Information Processing Systems, 2017, 30.

[30] 李超, 汪伟, 安斯光, 等. 基于数据扩展的锂离子电池早期寿命在线预测 [J]. 现代电子技术, 2024, 47(10): 171–176.

[31] 黄煜峰, 梁焕超, 许磊. 基于卡尔曼滤波算法优化 Transformer 模型的锂离子电池健康状态预测方法 [J]. 储能科学与技术, 2024, 13(08): 2791–2802.

[32] 王海瑞, 侯晓建, 朱贵富, 等. 基于 MsDCNN-Informer 模型的设备剩余寿命预测 [J/OL]. 控制工程, 1–12[2025-03-14].