

基于频率通道注意力机制和 MSCNet 的锂电池剩余使用寿命预测

卢世宇¹ 王海瑞¹ 朱贵富^{2,3} 李亚龙¹

¹ 昆明理工大学信息工程与自动化学院 昆明 650504

² 昆明理工大学信息化建设管理中心 昆明 650504

³ 昆明理工大学-曙光信息产业股份有限公司 AI 联合研究中心 昆明 650504

(lsy111315@qq.com)

摘要 为解决锂离子电池容量估计中特征提取不准确、数据噪声大及容量衰减趋势跟踪精度低等问题,提出了一种基于频率通道注意力机制(Frequency Channel Attention Mechanism, FCA)和 MSCNet(Multi-Scale Inter-Series Correlations Net)的新型模型。模型首先对原始传感器数据进行去噪处理,以降低噪声对模型性能的干扰;其次,引入频率通道注意力机制,通过频域分析将输入序列映射到频域,识别主导时间尺度以捕捉显著的周期性模式,并对时间序列进行多尺度分解;最后,利用 MSCNet 对多尺度输出进行动态聚合,捕获不同时间尺度内的跨序列相关性,提升模型对时间依赖性的理解,同时减少模型参数量。在 CALCE 和 NASA 公开数据集上的实验表明,该模型在电池使用寿命预测中的相对误差(RE)较现有算法降低了 10%~20%,能够更精准地跟踪电池衰退趋势。

关键词: 锂离子电池;剩余使用寿命预测;注意力机制;多尺度;跨序列相关性

中图分类号 TM912

Remaining Useful Life Prediction of Lithium-ion Batteries Based on Frequency-channel Attention Mechanism and MSCNet

LU Shiyu¹, WANG Hairui¹, ZHU Guifu^{2,3} and LI Yalong¹

¹ School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650504, China

² Information Construction Management Center, Kunming University of Science and Technology, Kunming 650504, China

³ AI Joint Research Center, Kunming University of Science and Technology-Shuguang Information Industry Co., Ltd., Kunming 650504, China

Abstract To address issues such as inaccurate feature extraction, significant data noise, and low precision in tracking capacity degradation trends in lithium-ion battery capacity estimation, a novel model combining the Frequency Channel Attention Mechanism(FCA) and Multi-Scale Inter-Series Correlations Net(MSCNet) is proposed. The model is designed in three stages. Firstly, raw sensor data are preprocessed to remove noise. Secondly, prominent periodic patterns are extracted through frequency domain analysis using the frequency-enhanced attention mechanism. Finally, the multi-scale outputs are aggregated by MSCNet, reducing model parameters while improving effectiveness of feature extraction. Experiments based on publicly available CALCE and NASA datasets demonstrate that the proposed model reduces relative error(RE) in battery life prediction by 10%~20% compared to existing algorithms, enabling more accurate tracking of battery degradation trends.

Keywords Lithiumion battery, Remaining useful life prediction, Attention mechanism, Multi-scale, Inter-series correlation

1 引言

锂离子电池作为一种重要的便携式能源,广泛应用于交通、国防军事和航空航天等关键领域^[1]。随着充放电循环次数的增加,锂离子电池的使用寿命逐渐缩短^[2]。电池老化不仅会导致性能显著下降,还会增加维护成本,甚至可能引发灾难性后果^[3]。因此,为确保电池及其运行系统的安全,降低潜在风险,对电池的状态进行精确监测至关重要,在达到使用寿命阈值之前采取有效的维护措施尤为必要^[4]。准确预测锂电

池的剩余使用寿命(Remaining Useful Life, RUL)不仅能够全面反映其健康状况,还能为维护计划的制定提供支持,从而提高系统的可靠性与安全性。

锂离子电池 RUL 的预测方法主要分为 3 类:基于模型的方法、基于数据驱动的方法以及融合方法^[5]。

基于模型的方法依赖数学函数来描述电池的物理^[6]和电化学^[7]特性。而基于数据驱动的方法则侧重于利用历史数据进行建模,不涉及物理特性,旨在刻画容量的退化过程。由于其灵活性,数据驱动的方法近年来得到了广泛关注^[8]。机器

基金项目:国家自然科学基金(61863016)

This work was supported by the National Natural Science Foundation of China(61863016).

通信作者:朱贵富(zhuguifu@kust.edu.cn)

学习算法在处理高维时间序列数据时表现出强大的能力,能够有效提取有价值的特征信息,实现对电池性能的精准预测、优化与控制^[9]。例如,Ding 等^[10]通过基于长短时记忆网络(LSTM)改进的门控循环单元(GRU)来学习锂电池的容量衰减特性,并通过迭代预测未来容量的变化。Xiao 等^[11]提出了一种基于等电压间隔下不同放电时间的健康指标,并利用遗传算法优化反向传播神经网络,实现了对电池容量的快速、准确估计。Jia 等^[12]提出了一种结合双向门控循环单元(Bi-GRU)与 Transformer 注意力机制的混合模型,有效解决了长时间序列预测中的问题。这些研究尽管在电池寿命和健康状态预测方面取得了显著进展,但在并行处理能力及长期依赖关系的捕捉上仍存在一定的局限性。

此外,在实际应用中,传感器收集的原始数据常伴有大量噪声^[13]。许多方法直接处理未经过滤的原始数据,严重影响了预测性能。尽管 Song 等^[14]提出的时间 Transformer 网络结合自注意力机制与去噪自动编码器显著降低了噪声干扰,但噪声点的随机分布问题尚未得到有效解决。

频率信息的提取是时间序列分析的重要方向。Zhou 等^[15-16]基于时间序列的稀疏表示开发了 FEDformer 模型,通过傅里叶变换引入频率信息,但吉布斯现象和傅里叶逆变换的高计算开销限制了其实际应用^[17]。此外,在频域与时域转换过程中亦消耗了大量资源。因此,开发一种兼具高效性与鲁棒性的 RUL 预测模型仍然是亟待解决的问题。

为克服现有模型的局限性,本文提出了一种基于频率通道注意力机制和 MSCNet 的新型模型。其中,MSCNet 由两个核心组件组成:SGB(ScaleGraph Blocks)层和 MoE(Mixture of Experts)层。该模型通过直接余弦变换(Direct Cosine Transform, DCT)捕捉频域特征,利用多尺度图块(SGB层)和专家混合模块(MoE层)提升对复杂时间序列的建模能力,并通过动态模拟噪声增强模型鲁棒性。本文的主要贡献如下:

1)为解决序列间复杂的多尺度相关性问题,引入频率通道注意力机制。该机制充分利用频率域分析的优势,更加有效地捕捉长周期依赖关系。此外,通过引入离散余弦变换(DCT),显著缓解了边界振荡问题。同时,该机制采用频率域加权策略,将频率特征直接与原始序列融合,从而在减少模型参数数量的基础上,进一步提升了特征提取能力与计算效率。

2)为同时捕获序列内和序列间的相关性,SGB层引入动态邻接矩阵建模不同时间尺度之间的关系。该层通过多头注意力机制与图卷积网络(GCN)的协同作用,深入挖掘多序列依赖特性,从而有效克服了现有基于固定尺度建模方法(Autoformer 与 Informer)在跨尺度关系捕捉方面的局限性。

3)MoE层通过动态评估各尺度特征的重要性并进行加权聚合,有效克服了传统方法基于固定尺度建模的局限性,从而显著提升了模型对复杂模式的适应能力。此外,该层采用稀疏门控策略(Top-K 选择机制),在减少不相关特征干扰的同时,确保专家层训练的稳定性,并降低模型过拟合的风险。

4)区别于小波变换、低通滤波等静态去噪算法,本文采用 Dropout 机制动态模拟噪声分布,在模型训练过程中有效增强其抗干扰能力。通过实验验证,即使在噪声比例高达 35% 的情况下,该模型依然能够保持较低的误差水平,显著优于现有模型的性能表现。

2 预测模型及方法

2.1 模型架构

为实现 RUL 的精准预测,本文提出了一种融合频率通道注意力机制与 MSCNet 的新型模型。该模型结合频率通道注意力以提取容量衰减数据中的关键特征,并通过 MSCNet 捕捉复杂趋势,实现对 RUL 的高精度预测。模型框架由 5 个核心模块组成:输入与去噪、注意力层、MSCNet(包括 SGB 层和 MoE 层)及输出层。整体架构如图 1 所示。RUL 预测方法流程图如图 2 所示。

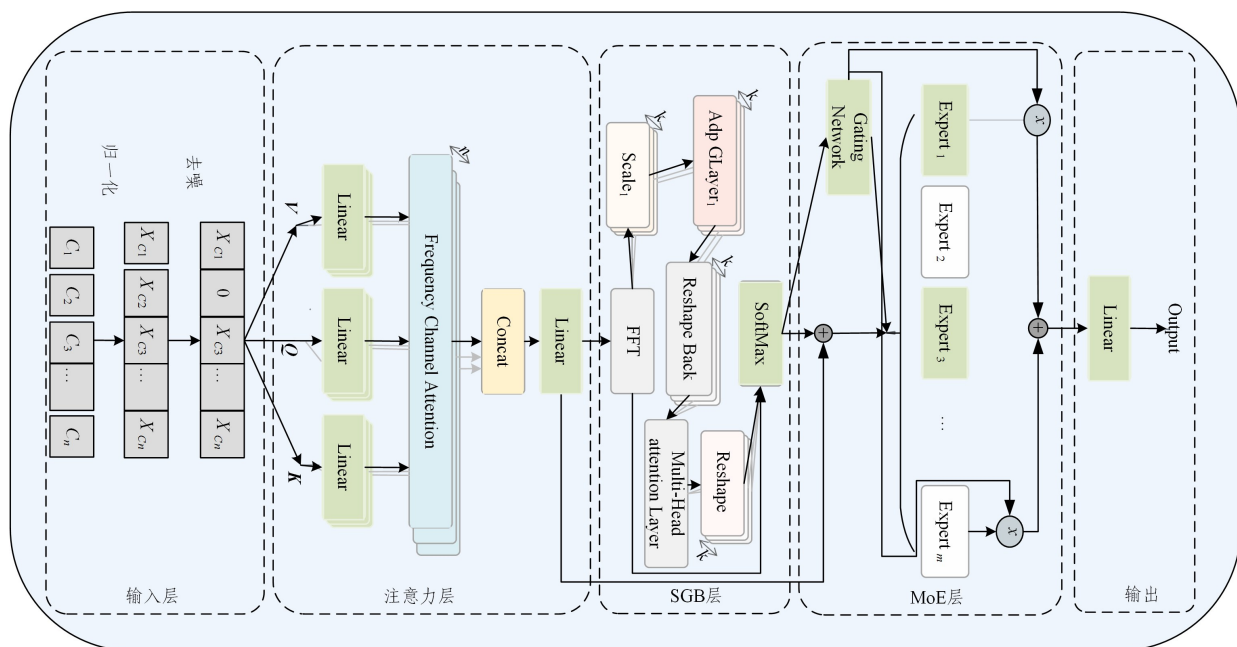


图 1 主模型框架图

Fig. 1 Master model frame diagram

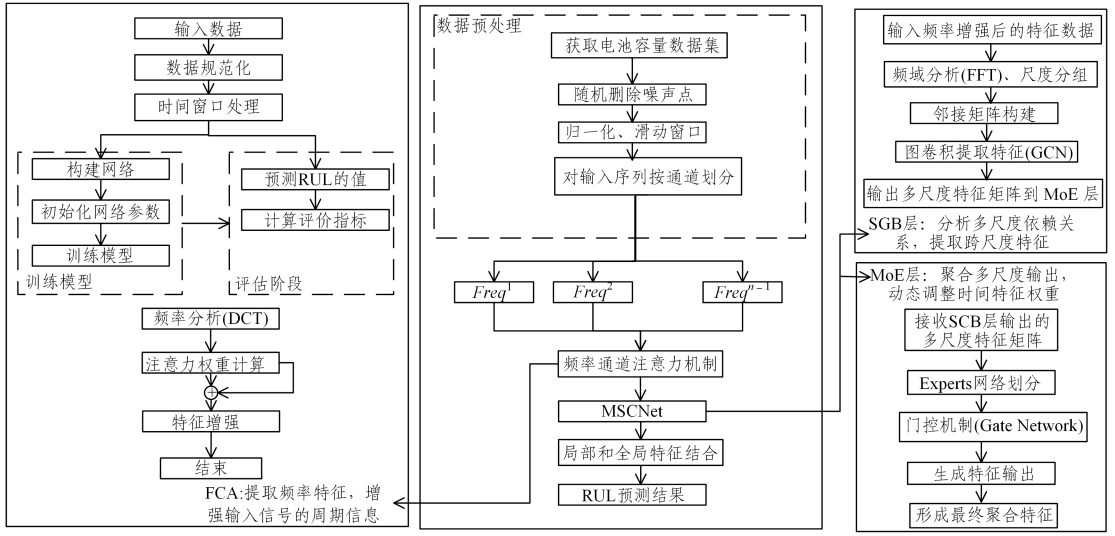


图2 总算法流程

Fig. 2 Total algorithm flow

2.1.1 输入层

为确保样本数据的一致性并减少数据分布差异对模型性能的影响,输入层首先对数据进行归一化处理。具体而言,容量的输入序列 $c = [c_1, c_2, \dots, c_n]$ 通过 $x_c = c/C_0$ 映射到 $(0, 1]$, 从而统一数据的数值范围,增强训练稳定性并提高计算效率。同时,针对充放电过程中的噪声干扰问题,采用随机删除序列

中噪声点的方式进行降噪: $x_c : x = \text{dropout}(x_c)$ 。

2.1.2 注意力层

频率信息在时间序列分析中具有重要意义,但现有模型缺乏捕获数据中丰富频率信息的能力。为此,本文引入频率通道注意力机制,在细粒度层面提取通道独立的频域特征,同时消除通道间的干扰。其架构如图3所示。

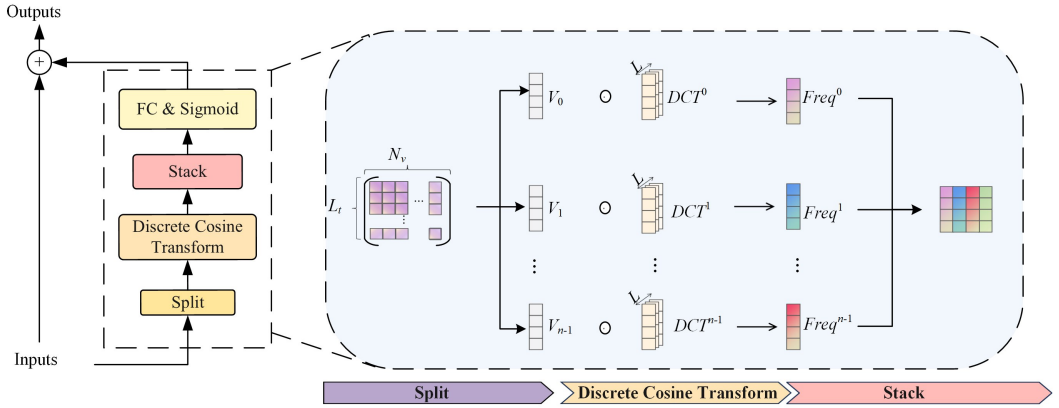


图3 频率通道注意力机制架构

Fig. 3 Architecture of frequency channel attention mechanism

具体流程如下:

首先,将输入特征 $\mathbf{X} \in \mathbb{R}^{n \times L}$ 按通道维度细分为 n 个独立的通道变量 $\{v_0, v_1, \dots, v_{n-1}\}$, 其中 $v^i \in \mathbb{R}^{1 \times L}$ 且 $i \in \{0, 1, 2, \dots, n-1\}$ (n 为通道数量), 以减少通道间信息的干扰并避免特征混叠,从而便于提取每个通道的频域信息。

其次,每个通道变量与离散余弦变换分量 B_j^i 按低频到高频顺序逐元素相乘:

$$\mathbf{Freq}^i = \text{DCT}_j^i(v^i) = \sum_{j=0}^{j=L-1} v_j^i B_j^i \quad (1)$$

再次,沿通道维度堆叠生成频域张量 $\mathbf{Freq} \in \mathbb{R}^{n \times L}$:

$$\mathbf{Freq} = \text{stack}(\mathbf{Freq}^0, \mathbf{Freq}^1, \dots, \mathbf{Freq}^{n-1}) \quad (2)$$

然后,通过全连接网络建模通道间的频率依赖关系,生成频域自适应权重向量 $\mathbf{F}_{\text{att}} = \sigma(\mathbf{W}_2 \delta(\mathbf{W}_1 * \mathbf{Freq}))$ 。

随后,将输入特征与频域权重向量进行逐元素相乘,得到频域增强的特征表示:

$$\mathbf{X}_{i+1;t+o} = \mathbf{X}_{i-L+1;t} \cdot \mathbf{F}_{\text{att}}(\mathbf{X}_{i-L+1;t}) \quad (3)$$

最后,经由全连接层 $\text{FC}(\mathbf{X})$ 进一步投影后,生成自适应权重向量,与原始输入结合后经线性投影层优化后输出到下一层。

2.1.3 SGB层

每个SGB层包含以下4个步骤:1)捕捉输入时间序列的多尺度特性;2)通过自适应图卷积模块提取尺度相关的跨序列依赖;3)利用多头注意力机制提取序列内部的时间依赖性;4)通过SoftMax函数动态优化多尺度输出的加权融合。整体架构如图1中SGB层所示。

首先,在初始层中,将输入时间序列的 N 个变量嵌入到大小为 d_{model} 的向量 $\mathbf{X} \in \mathbb{R}^{d_{\text{model}} \times L}$ 中,并通过公式 $\mathbf{X}^i = \text{ScaleGraphBlock}(\mathbf{X}^{i-1}) + \mathbf{X}^{i-1}$ 输入后续层。

其次,通过快速傅里叶变换(FFT)提取输入序列的主要频率特性:

$$\mathbf{F} = \text{Avg}(\text{Amp}(\text{FFT}(\mathbf{X}^i))) \quad (4)$$

其中, $Amp(\cdot)$ 表示幅度值的计算, 矢量 $\mathbf{F} \in \mathbb{R}^L$ 表示每个频率分量的振幅。

再次, 提取前 k 个主要频率分量, 通过公式 $f_1, \dots, f_k = \arg\text{Top}k(\mathbf{F})$ 和 $s_i = \frac{L}{f_i}$ 确定时间尺度 $\{s_1, \dots, s_k\}$ 。然后, 根据时间尺度将序列重构为三维张量 \mathbf{x}^i , 如下式所示:

$$\mathbf{x}^i = \text{Reshape}_{e_{s_i}, f_i}(\text{Padding}(\mathbf{X}_m)) \quad (5)$$

其中, $\text{Padding}(\cdot)$ 表示通过零扩展操作适配不同的时间尺度。

随后, 构建邻接矩阵 \mathbf{E}_1^i 和 \mathbf{E}_2^i , 建模时间尺度间的依赖关系, 并通过 MixHop 图卷积进一步提取跨序列依赖性:

$$\mathbf{A}^i = \text{Softmax}(\text{ReLU}(\mathbf{E}_1^i (\mathbf{E}_2^i)^T)) \quad (6)$$

$$\mathbf{H}_{\text{out}}^i = \sigma(j \in P(\mathbf{A}^i)^j \mathbf{H}^i) \quad (7)$$

$\mathbf{H}_{\text{out}}^i$ 通过多层感知机 (MLP) 投影回 3D 张量 $\mathbf{x}^i \in \mathbb{R}^{d_{\text{model}} \times s_i \times f_i}$, 以匹配后续的输入形态。

在每个时间尺度中, 采用多头自注意力机制 (Self-MHA), 对时间尺度张量应用公式: $\mathbf{x}_{\text{out}}^i = \text{MHA}(\mathbf{x}^i)$ 。

最后, 将所有时间尺度的张量 $\mathbf{x}_{\text{out}}^i$ 重塑回一个二维矩阵 $\mathbf{x}_{\text{out}} \in \mathbb{R}^{d_{\text{model}} \times L}$, 并根据其频域振幅特性进行加权聚合:

$$\mathbf{x}_{\text{out}} = \sum_{i=1}^k a^i \mathbf{x}_{\text{out}}^i \quad (8)$$

该过程利用 FFT 提取振幅信息并通过 SoftMax 函数动态调整权重后输出到下一层。

2.1.4 MoE 层

MoE 层通过同时训练一组 Expert 层 (记为 $\mathbf{E}(x)$), 使其专注于不同的输入场景。随后, 这些 Expert 层的输出通过线性组合为最终的预测, 其中门控函数 $\mathbf{G}(x)$ 用于参数化每个 Expert 层的贡献比例:

$$\text{MoE}(x) = \sum_{i=1}^m \mathbf{G}(x)_i \mathbf{E}_i(x) \quad (9)$$

为了确保稀疏性和平衡性, 本文按照文献[18]的方法, 采用带噪 Top-K 门控策略:

$$\mathbf{N}(x)_{i:t+T} = \mathbf{W}_s \mathbf{x}_{\text{out}} \mathbf{W}_t + \mathbf{b} \quad (10)$$

$$\mathbf{G}(x)_i = \text{ScaleGraphBlock}(\text{Top-k}(\mathbf{N}(x), i)) \quad (11)$$

其中, $\mathbf{b} \in \mathbb{R}^T$; 矩阵 $\mathbf{W}_s \in \mathbb{R}^{d_{\text{model}} \times L}$ 和 $\mathbf{W}_t \in \mathbb{R}^{T \times L}$ 分别用于变量维度和时间维度上的线性投影, 生成融合后的预测结果为 $\mathbf{N}(x)_{i:t+T}$, 其中 t 表示变量数量, T 表示预测步长。

MoE 层根据各时间尺度的特征重要性动态分配权重, 有效整合多尺度特征, 为后续网络提供更丰富的信息表征。

2.1.5 输出层

为了预测电池容量的未来变化趋势, 在 MoE 层提取特征的基础上, 采用全连接层将高维特征映射至容量预测值。预测输出 Output 的过程定义如下: $\text{Output} = f(\mathbf{W}_p \mathbf{x}_e + \mathbf{b}_p)$, 其中 $\mathbf{W}_p, \mathbf{b}_p, f(\cdot)$ 分别表示输出层的权重、偏差和激活函数。通过输出层, 模型最终生成对电池容量变化的预测结果。

3 实验以及实验设置

3.1 数据集


本文基于两种不同电极材料的锂离子电池数据集, 在室温环境下对模型性能进行了验证。

第一组数据来自马里兰大学高级生命周期工程中心, 包含 4 组电池 (CS2_35, CS2_36, CS2_37 和 CS2_38) 的容量衰减数据[19]。该系列电池的测试流程如下: 电池首先充电至 4.2 V,


随后切换至恒压 (CV) 模式, 直至电流降至 20 mA; 放电过程在恒流 (CC) 模式下进行, 直至电池电压降至 2.7 V。电池的寿命终止条件为容量衰减至额定容量的 70%, 即 $0.77 \text{ A} \cdot \text{h}$ [20]。

第二组数据来自 NASA PCoE 研究中心, 包含 B0005, B0006, B0007 和 B0018 这 4 组电池的容量衰减数据[21]。其测试流程为: 充电时, 电池以 1.5 A 恒流模式 (CC) 充至 4.2 V, 然后切换至恒压模式 (CV), 直到电流降至 20 mA; 放电采用 2 A 恒流模式 (CC) 进行, 直至电压分别降至 B0005 为 2.7 V、B0006 为 2.5 V、B0007 为 2.2 V、B0018 为 2.5 V。电池的寿命终止条件为容量衰减至额定容量的 70%, 即 $1.40 \text{ A} \cdot \text{h}$ [22]。图 4 展示了两组数据集中的电池容量衰减曲线。

图 4(a) 给出了 CALCE 数据集上更加复杂的非线性衰减模式, 表现出早期显著下降的趋势, 并伴随较大波动与突变点, 反映出高噪声和复杂工况特征, 有助于检验模型的鲁棒性和抗干扰能力。相比之下, 图 4(b) 给出了 NASA 数据集上电池容量的平滑线性衰减过程, 前期下降缓慢, 后期加速, 突出较为规律的老化趋势, 适合评估模型在低噪声环境下的预测精度。两组数据集相互补充, 为全面评估模型在不同工况下的性能及实际应用潜力提供了有力支持。



(a) CALCE 数据集



(b) NASA 数据集

图 4 电池容量衰减曲线

Fig. 4 Battery capacity attenuation curve

3.2 性能评估指标

为了全面评估模型性能, 本文采用了 3 项常见的评估指标: 相对误差 (RE)、平均相对误差 (MAE) 和均方相对误差 (RMSE)。这些指标的定义如下:

$$RE = \frac{|RUL^{\text{pred}} - RUL^{\text{true}}|}{RUL^{\text{true}}}$$

$$MAE = \frac{1}{n} \sum_{t=1}^n \|Y_t - \bar{Y}_t\| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \bar{Y}_t)^2}$$

此外, 采用了留一法交叉验证对所有数据集进行评估。具体方法如下: 在每次迭代中, 选择一个电池作为测试样本, 其余电池则用于训练模型。经过 5 次迭代后, 计算并得出所有电池的平均评估结果, 从而获得模型的整体性能表现。

3.3 实验环境与参数设置

本文实验使用的两组数据集在训练集和测试集的划分上遵循 2:8 的比例,以确保模型训练和评估的科学性和公平性。所提模型有 4 个关键参数:学习率、注意力头数量、隐藏层数量和 MoE 层中 Expert 层数量。在实验中,学习率在 $\{10^{-4}, 10^{-3}, 10^{-2}\}$ 中选择;注意力头数量在 $\{2, 4, 8, 16\}$ 中选择;隐藏层数量在 $\{32, 64, 128, 256\}$ 中选择;MoE 层数量在 $\{4, 8, 16, 64\}$ 中选择。所有实验均在配备 512 GB 内存及 GeForce RTX 3090 GPU(24 GB)的设备上进行训练。

3.4 对比实验

为验证所提模型的有效性,将其与以下基线模型进行了比较:

MLP:广泛应用于各种任务的神经网络模型,主要通过多层全连接网络学习电池的时间趋势。其关键参数为学习率和隐藏层数。在 NASA 和 CALCE 数据集上设置学习率为 0.01,隐藏层数分别为 2 和 4。

LSTM:通过存储单元保留时间序列中先前时间步的信息,能够捕捉数据的上下文及长期依赖性。其关键参数为学习率和隐藏层数。在 NASA 和 CALCE 数据集上均设定学习率为 0.001,隐藏层数为 2。

GRU:LSTM 的一个扩展,可以有效地捕获和保留序列数据中的相关信息。GRU 有两个关键的超参数,即学习率和隐藏层的数量。在 NASA 和 CALCE 数据集上,将学习率设置为 0.001,隐藏层的数量设置为 2。

Dual-LSTM:通过两个 LSTM 单元分别学习输入信号的短期和长期依赖特性,以预测电池 RUL。其关键超参数同样为学习率和隐藏层数,学习率设定为 0.001,隐藏层数为 2。

Transformer^[23]:一种基于自注意力机制的神经网络模型,能够有效处理长时间序列数据,并通过并行计算加速训练过程。其关键超参数为学习率、注意力头数和隐藏层数。在 NASA 和 CALCE 数据集上将学习率设为 0.01,注意力头数分别为 4 和 16,隐藏层数分别为 16 和 64。

Informer^[24]:一种针对长序列预测优化的 Transformer 变体,采用稀疏注意力机制和信息瓶颈层来降低计算复杂度,更适合处理大规模时间序列数据。其关键超参数为学习率、注意力头数量和隐藏层数。在 NASA 和 CALCE 数据集上设置学习率为 0.01,注意力头数分别为 8 和 16,隐藏层数分别为 32 和 64。

Autoformer^[25]:一种专为长序列时间序列预测设计的自回归结构模型。通过引入自适应的时间序列分解机制,它能够捕捉序列中的长期趋势和短期波动特征。其关键参数包括学习率和编码器的层数。在 NASA 和 CALCE 数据集上,学习率设定为 0.0005,编码器层数设置分别为 3 和 9。

TimesNet^[26]:一种专门用于时间序列分析的神经网络模型,能够自动提取多尺度时间特征,并适应复杂的序列模式。通过多层时域块结构,TimesNet 有效整合了时间序列中的全局与局部信息。其关键参数为学习率和时域块的数量。在 NASA 和 CALCE 数据集上,学习率设置为 0.0005,时域块数量设置为 4。

UPF-OCS^[27]:基于优化组合策略的无痕卡尔曼滤波(UPF-OCS)通过结合无痕卡尔曼滤波器和优化组合策略,提高了预测精度和鲁棒性。该方法能够有效处理非线性和非高

斯系统,在时间序列预测中表现出色。其关键参数为学习率和状态更新步长。在 NASA 和 CALCE 数据集上,设置学习率为 0.01,状态更新步长分别为 0.05 和 0.005。

ALF-PF-LSTM^[28]:基于自适应莱维飞行优化的粒子滤波及长短时记忆神经网络的方法(ALF-PF-LSTM)结合了粒子滤波的鲁棒性和 LSTM 的长期依赖性学习能力,同时通过莱维飞行优化提高了粒子滤波的全局搜索效率。其关键参数包括粒子数和学习率。在 NASA 和 CALCE 数据集上,设置粒子数分别为 50 和 150,学习率为 0.001。

4 实验结果分析

4.1 对比实验结果

首先进行了对比实验以评估各方法的性能,结果如表 1 所列,最佳结果以粗体标出。

表 1 各方法的 RE, MAE 和 RMSE

方法	NASA 数据集			CALCE 数据集		
	RE	MAE	RMSE	RE	MAE	RMSE
MLP	0.3851	0.1379	0.1541	0.4018	0.1557	0.2038
LSTM	0.2648	0.0829	0.0905	0.0902	0.0582	0.0736
GRU	0.3044	0.0806	0.0921	0.1319	0.0671	0.0946
Dual-LSTM	0.2557	0.0815	0.0879	0.0885	0.0636	0.0874
Transformer	0.2252	0.0713	0.0802	0.0764	0.0613	0.0705
Autoformer	0.2010	0.0695	0.0811	0.0731	0.0595	0.0733
TimesNet	0.1953	0.0745	0.0800	0.0712	0.0554	0.0702
UPF-OCS	0.1986	0.0712	0.0951	0.0759	0.0694	0.0829
ALF-PF-LSTM	0.2095	0.0889	0.0894	0.0841	0.0815	0.0852
Informer	0.2001	0.0760	0.0872	0.0761	0.0577	0.0794
FCA+MSCnet	0.1908	0.0679	0.0785	0.0634	0.0513	0.0710

通过表 1 的实验结果,本文对不同方法的预测性能进行了系统性分析,以验证模型在复杂环境中的表现及其鲁棒性。1) 实验结果表明,预测方法在两组数据集上的表现均具有较高的精度与稳定性。与传统模型(如 LSTM, GRU 和 Transformer)相比,本文方法在关键评估指标——相对误差、均方根误差和平均绝对误差上均取得了显著优化,有效提升了预测性能。2) 在 NASA 数据集上,由于容量衰减过程较为平滑,本文模型能够精准捕捉长期趋势,表现出更低的预测误差和更高的稳定性。在 CALCE 数据集上,面对非线性衰减与高噪声干扰,本文模型依托频域分析与跨尺度建模机制,有效抑制了噪声干扰,并通过动态调整注意力权重,在关键趋势转折点的预测中展现出卓越的适应性和鲁棒性。3) 进一步分析预测误差分布发现,本文模型在处理高频突变和后期快速衰减阶段的数据时,其误差显著小于其他对比方法,充分证明了模型在复杂环境和非平稳数据中的优越性能。4) 此外,分析了模型在不同时间步上的预测表现,结果显示本文方法在早期阶段能够实现接近真实值的高精度预测;在后期阶段,通过动态调整注意力权重,模型有效规避了误差积累问题,保持了趋势跟踪的稳定性。综上所述,本文模型不仅在低噪声环境下具有卓越的预测精度,而且在复杂环境和高噪声条件下依然表现出良好的鲁棒性与适应性。

为更直观地展示本文方法的优越性,本文选取了 NASA 和 CALCE 数据集集中的 B0005 和 CS2_35 进行验证,并将前 30% 的数据划分为训练集。图 5 展示了不同方法的模拟预测曲线。从图中可以清晰地观察到所提预测模型能够有效捕捉

电池容量退化的趋势。与 MLP, LSTM, GRU, Dual-LSTM, Transformer, Autoformer, TimesNet, UPF-OCS, ALF-PF-Transformer, Autoformer, TimesNet, UPF-OCS, ALF-PF-LSTM, Informer, FCA+MSCNet, Stop line(1.4 Ah), Training boundary

LSTM 和 Informer 方法相比,本模型的预测精度更高,且预测曲线对真实退化趋势的拟合效果更佳。

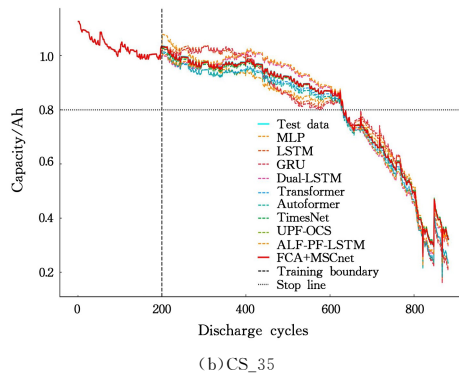
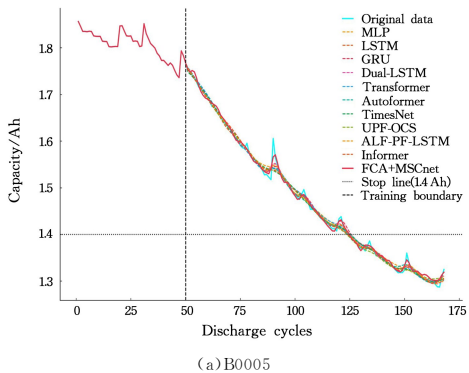






图 5 不同方法的模拟预测曲线

Fig. 5 Simulated prediction plots of different methods





4.2 频率通道注意力机制的消融实验

为了进一步探讨频率通道注意力对模型性能的贡献,将本文提出的模型与其简化版本进行了对比,后者采用传统 transformer 的多头自注意力机制。在两个数据集上,消融实

验的模拟预测曲线如图 6 所示。由图 6 可知,本文模型在所有数据集上的拟合效果均优于其简化版本。这表明,频率通道注意力机制在处理具有强长期依赖特性的时间序列数据时,能够更有效地捕捉复杂的时序模式和依赖关系。



(a) NASA 数据集



(b) CALCE 数据集

图 6 频率通道注意力机制消融实验的模拟预测曲线

Fig. 6 Simulated prediction curves of frequency channel attention mechanism ablation experiments

图 7 展示了频率注意力特征的热图,刻画了模型在不同时间步与频率通道上的注意力权重分布特征。

化注意力权重的大小。结果表明,模型会对低频特征赋予较高权重,突出其在长期趋势提取方面的优势;同时,模型能够动态关注高频特征,以有效捕捉短期变化及突发异常。这种兼顾趋势提取与噪声抑制的注意力机制充分展现了模型在特征学习中的灵活性与适应性,从而显著提升了预测精度与鲁棒性。




图 7 频率注意力机制特征热图

Fig. 7 Frequency channel attention mechanism feature heatmap

图中纵轴表示时间步,横轴对应频率通道,色条则用于量

4.3 MSCNet 的消融实验

为评估 MSCNet 对模型性能的影响,将使用 MSCNet 的模型与不使用 MSCNet 的简化版本进行对比。实验结果如图 8 所示。从图 8 可见,包含 MSCNet 的模型在所有情况下均优于其简化版本,这表明 MSCNet 显著增强了预测性能。特别是在 CALCE 数据集上,模型的拟合效果尤为突出,说明较大的数据集有助于 MSCNet 更有效地捕捉时间序列特征,从而进一步提升预测精度。

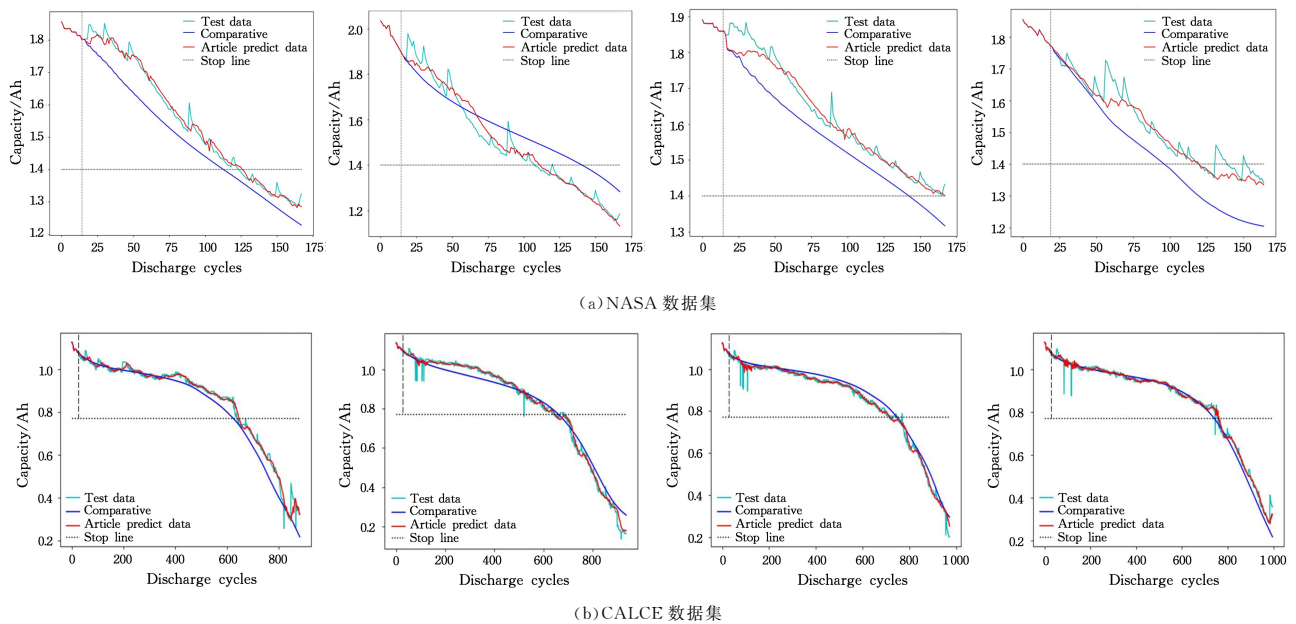


图 8 MSCNet 的消融实验的模拟预测曲线

Fig. 8 Simulated prediction curves of MSCNet's ablation experiment


4.4 去噪的消融实验

为进一步分析去噪处理对模型性能的影响,进行了去噪处理模型(Y-Dropout)与未去噪版本(N-Dropout)的消融实验。在实验中,将 Dropout 值固定为 0.1,以比较未去噪的简化版本,实验结果如表 2 所列。


表 2 去噪的消融实验

Table 2 Ablation experiment on denoising

数据集	指标	未去噪版本	去噪	提升/%
NASA	RE	0.2031	0.1909	6.01
	MAE	0.0682	0.0669	1.94
	RMSE	0.0787	0.0775	1.47
CALCE	RE	0.0684	0.0634	7.28
	MAE	0.0542	0.0511	5.73
	RMSE	0.0749	0.0711	5.04



(a) NASA 数据集



(b) CALCE 数据集

图 9 去噪的消融实验效果

Fig. 9 Renderings of denoising ablation experiment

结束语 本文提出了一种新型模型用于电池 RUL 预测,该模型通过随机删除序列中噪声点实现对原始数据的降噪处理。为了更好地模拟电池容量的变化趋势,采用了频率通道注意力机制,将输入序列转换至频域,从电池容量退化数据中提取出关键特征。随后,通过 MSCNet 提取每个时间尺度内的序列相关性,并聚合来自不同尺度的输出,实现精准的预测。实验结果表明,所提模型在相对误差指标上相较于基线方法提升了 10%~20%,验证了其优越性。

从表 2 结果可见,Y-Dropout 在所有情况下均优于 N-Dropout,表明去噪处理有效提升了模型性能。尤其在噪声较大的 CALCE 数据集上,去噪处理表现出更显著的提升,表明其对噪声较大且变化频繁的时间序列具有更强的改善作用。


为了进一步验证去噪效果,在原始数据中加入了不同比例的高斯噪声进行敏感性分析。噪声比例从 5%~35%,以 5% 为间隔,添加到原始数据的选定比例中。相应的 RMSE 结果如图 9 所示。

从图 9 可见,随着噪声比例的增加,模型性能逐渐下降,表明噪声数据对模型性能具有负面影响,限制甚至破坏了模型的学习能力。在两个数据集上,大多数情况下,Y-Dropout 的表现均优于 N-Dropout,表明去噪处理有效提升了模型性能。去噪处理作为一种合理的解决方案,通过增强模型的鲁棒性和泛化能力,显著减少了噪声的负面影响。

尽管本研究取得了一定成果,但仍有若干方向值得进一步探讨。首先,本文的模型主要基于两个数据集进行训练和验证,这在一定程度上限制了其在更广泛应用场景中的通用性。未来的研究应考虑引入更大规模和多样化的数据集,以提高电池 RUL 估计的准确性和模型的泛化能力。此外,电池的使用行为受到温度、电流等多种因素的显著影响,未来的工作可进一步探讨不同工况下的 RUL 预测问题,深入分析这些因素如何影响电池衰退模式,从而开发更具鲁棒性和适应性的预测模型。

参考文献

- [1] HUANG K, DING H, GUO Y F, et al. Prediction of remaining useful life of lithium-ion battery based on adaptive data preprocessing and long short-term memory network[J]. Transactions of China Electrotechnical Society, 2022, 37(15): 3753-3766.
- [2] LI F, MIN Y, ZHANG Y, et al. State-of-health estimation method for fast-charging lithium-ion batteries based on stacking ensemble sparse Gaussian process regression[J]. Reliability Engineering & System Safety, 2024, 242(2): 1-13.
- [3] WU Z Q, CHEN H J. Joint estimation of SOC and SOH of lithium battery based on adaptive H2/H ∞ filtering[J]. Journal of Metrology, 2023, 44(11): 1719-1727.
- [4] LI Z H, SHI Q L, WANG K L, et al. Research status and prospect of state of health estimation method for lithium-ion battery [J/OL]. <http://kns.cnki.net/kcms/detail/32.1180.TP.20240715.1700.006.html>.
- [5] NIU Z Y, JIANG X, XIE B, et al. Study on simulation and safety protection of electric vehicle overcharge and explosion accident [J]. Transactions of China Electrotechnical Society, 2022, 37(1): 36-47, 57.
- [6] SHU X, SHEN J W, LI G, et al. A Flexible State-of-Health Prediction Scheme for Lithium-Ion Battery Pack with Long Short-Term Memory Network and Transfer Learning[J]. IEEE Transactions on Transportation Electrification, 2021, 7(4): 2238-2248.
- [7] SU S S, LI W, MOU J H, et al. A Hybrid Battery Equivalent Circuit Model, Deep Learning, and Transfer Learning for Battery State Monitoring [J]. IEEE Transactions on Transportation Electrification, 2023, 9(1): 1113-1127.
- [8] WU Z Q, HU X Y, MA B Y, et al. Lithium Battery SOC Estimation Based on RFF and GWO-PF [J]. Journal of Quantitative & Technical Economics, 2022, 43(9): 1200-1207.
- [9] SHAHID F, ZAMEER A, MUNEEB M. A Novel Genetic LSTM Model for Wind Power Forecast [J]. Energy, 2021, 10(1): 1016-1020.
- [10] DING G, WANG W, ZHU T. Remaining useful life prediction for lithium-ion batteries based on CS-VMD and GRU [J]. IEEE Access, 2022, 10: 89402-89413.
- [11] XIAO S, LIU P, CHEN K, et al. Battery state of health prediction based on voltage intervals, BP neural network and genetic algorithm [J]. International Journal of Green Energy, 2024, 21(8): 1743-1756.
- [12] JIA C, TIAN Y, SHI Y, et al. State of health prediction of lithium-ion batteries based on bidirectional gated current unit and transformer [J]. Energy, 2023, 285: 129401-129409.
- [13] ZHANG M D, LIU Y, CHEN J, et al. Lithium-ion Battery Health State Estimation Based on ISSA-GPR [J/OL]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20231219.1345.010.html>.
- [14] SONG W, WU D, SHEN W, et al. A remaining useful life prediction method for lithium-ion battery based on temporal transformer network [J]. Procedia Computer Science, 2023, 217: 1830-1838.
- [15] ZHOU T, MA Z, WEN Q, et al. Fedformer: Frequency enhanced decomposed transformer for long-term series forecasting [C] // International Conference on Machine Learning. PMLR, 2022: 27268-27286.
- [16] ZHOU T, MA Z, WEN Q, et al. Film: Frequency improved long-term memory model for long-term time series forecasting [J]. Advances in Neural Information Processing Systems, 2022, 35: 12677-12690.
- [17] SHIZGAL B D, JUNG J H. Towards the resolution of the Gibbs phenomena [J]. Journal of Computational and Applied Mathematics, 2003, 161(1): 41-65.
- [18] SHAZEER N, MIRHOSEINI A, MAZIARZ K, et al. Outrageously large neural networks: The sparsely-gated mixture-of-experts layer [J]. arXiv:1701.06538, 2017.
- [19] SHEN J, MA W, SHU X, et al. Accurate state of health estimation for lithium-ion batteries under random charging scenarios [J]. Energy, 2023, 279: 128092.
- [20] XIA X Y, YUE J H, ZENG X Y, et al. A Remaining Capacity Estimation Method for Lithium-ion Batteries Based on State-Dependent RBF-ARX Model [J/OL]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20240613.1329.012.html>.
- [21] LI C, ZHANG H L, ZHANG J P. Health Status Estimation of Spent Lithium-ion Batteries Based on Kernel Functions and Hyperparameter Optimization [J]. Energy Storage Science and Technology, 2024, 13(6): 2010-2021.
- [22] WANG P, PENG X Y, CHENG Z, et al. A multi-time-scale state joint estimation method for lithium-ion batteries based on data-driven model fusion [J]. Automotive Engineering, 2022, 44(3): 362-371, 378.
- [23] CHEN D, HONG W, ZHOU X. Transformer network for remaining useful life prediction of lithium-ion batteries [J]. IEEE Access, 2022, 10: 19621-19628.
- [24] ZHOU H, LI J, ZHANG S, et al. Expanding the prediction capacity in long sequence time-series forecasting [J]. Artificial Intelligence, 2023, 318: 103886-10392.
- [25] WU H, XU J, WANG J, et al. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting [J]. Advances in Neural Information Processing Systems, 2021, 34: 22419-22430.
- [26] WU H, HU T, LIU Y, et al. Timesnet: Temporal 2d-variation modeling for general time series analysis [J]. arXiv: 2210.02186, 2023.
- [27] YANG J S, FANG W, CHEN J Y, et al. A lithium-ion battery remaining useful life prediction method based on unscented particle filter and optimal combination strategy [J]. Journal of Energy Storage, 2022, 55: 105648.
- [28] ZHANG Y, CHEN L, LI Y, et al. A hybrid approach for remaining useful life prediction of lithium-ion battery with adaptive levy flight optimized particle filter and long short-term memory network [J]. Journal of Energy Storage, 2021, 44: 103245.



LU Shiyu, born in 2000, postgraduate. His main research interests include machine learning and life expectancy prediction.



ZHU Guifu, born in 1984, master supervisor, senior engineer. His main research interests include intelligent diagnosis technology and education big data.