



融合特征多尺度池化的锂电池健康状态评估算法

周星凯¹, 竺春祥^{1*}, 贾迎浩¹, 王斌锐¹, 李冲²

(¹中国计量大学 机电工程学院, 杭州 310018; ²上海第二工业大学 智能制造与控制工程学院, 上海 201209)

摘要: 随着新能源技术的迅速发展, 准确评估电池健康状态对于电池管理系统的优化和电池寿命预测具有至关重要的意义。现有的SOH估计方法主要依赖传统神经网络对时间序列进行编码, 但这些方法通常忽略了通道间特征的相互关系, 导致信息利用不足。为解决这一问题, 本文提出了一种基于混合空间池化与多通道特征加权融合的SOH预测方法。首先, 通过混合池化模块对电池电压、电流、温度等时序数据进行多尺度特征提取, 结合最大池化、平均池化和L2池化策略, 有效提高了模型对退化特征的感知能力。接着, 利用多通道加权融合模块, 通过优化特征通道之间的交互与融合, 进一步提升了模型的预测性能。实验结果表明, 所提方法在马里兰大学、同济大学和西交大的多个公开电池数据集上表现优异, 在MAE、RMSE和MAPE等评估指标上均优于传统方法, 取得了最佳结果, 其中MAE为0.0012, RMSE为0.0017, MAPE为0.1661。尤其在复杂退化模式下, 展现出更强的鲁棒性和更好的泛化能力。

关键词: 锂电池; 特征融合; 混合池化; 电池健康状态

doi: 10.19799/j.cnki.2095-4239.2026.0153

中图分类号: TM911

文献标志码: A

文章编号: 2095-4239 (XXXX) XX-1-15

Multi-Scale Pooling Enhanced Feature Fusion for Lithium-Ion Battery SOH Estimation

ZHOU Xingkai¹, ZHU Chunxiang^{1*}, JIA Yinghao¹, WANG Binrui¹, LI Chong²

(¹College of Mechanical and Electrical Engineering, China Jiliang University, Hangzhou 310018, China;

²School of Intelligent Manufacturing and Control Engineering, Shanghai Polytechnic University, Shanghai 201209, China)

Abstract: Accurate estimation of lithium-ion battery State of Health (SOH) is essential for the optimization of battery management systems (BMS) and reliable lifetime prediction. However, existing neural-network-based SOH estimation methods often ignore the interdependencies among feature channels, leading to suboptimal feature utilization and degraded prediction accuracy. This study proposes a novel SOH estimation framework that integrates Hybrid Spatial Pooling (HPP) with a multi-channel feature fusion module (STAR). The HPP module performs multi-scale feature extraction on voltage, current, and temperature time-series by combining max, average, and L2 pooling operations to enhance degradation-sensitive feature

收稿日期: 2026-02-10; 修改稿日期: 2026-04-27。

基金项目: 国家自然科学基金资助项目 (52205292), 浙江省自然科学基金白马湖实验室联合基金资助项目 (LBMHY25B030001), 中国计量大学2025年校级教改项目 (HEX2025003), 中国计量大学2024年度基本科研业务费项目 (2024YW59)。

第一作者: 周星凯 (2000—), 男, 硕士生, 锂电池健康状态估计, E-mail: 1197907916@qq.com; 通信作者: 竺春祥, 博士, 讲师, 研究方向, 锂电池管理系统算法, E-mail: led2016@cjlu.edu.cn。

引用本文: 周星凯, 竺春祥, 贾迎浩, 等. 融合特征多尺度池化的锂电池健康状态评估算法[J]. 储能科学与技术, XXXX, XX(XX): 1-15.

Citation: ZHOU Xingkai, ZHU Chunxiang, JIA Yinghao, et al. Multi-Scale Pooling Enhanced Feature Fusion for Lithium-Ion Battery SOH Estimation[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-15.

representation. The STAR module further strengthens feature interactions across channels through adaptive weighting and cross-channel enhancement. Experimental evaluations on three publicly available datasets from the University of Maryland, Tongji University, and Xi'an Jiaotong University demonstrate the effectiveness of the proposed approach. The model achieves a mean absolute error of approximately 0.0012, a root-mean-square error of roughly 0.0017, and a mean absolute percentage error of about 0.1661, consistently outperforming conventional neural-network baselines. In addition, the method exhibits strong robustness under complex degradation patterns and preserves stable generalization capability across different battery chemistries. The proposed HPP - STAR framework significantly enhances SOH estimation through three main contributions: (1) introducing hybrid multi-scale pooling to enrich degradation-aware representations, (2) optimizing inter-channel dependencies via multi-channel feature fusion, and (3) achieving consistently high accuracy across diverse datasets. These results verify the effectiveness and generalization capability of the proposed approach, providing a promising direction for future SOH estimation in practical BMS applications.

Keywords: lithium-ion battery; feature fusion; hybrid pooling; battery state of health

随着新能源汽车、储能系统以及消费电子的快速发展,锂离子电池凭借高能量密度、长循环寿命和低自放电率,已成为最核心的能量存储单元^[1]。然而,在长期充放电循环和复杂运行工况下,电池性能会逐渐衰退,表现为容量下降、内阻增加和安全性降低^[2]。因此,如何准确评估锂离子电池的健康状态(State of Health, SOH),已成为电池管理系统(Battery Management System, BMS)的关键任务。有效的SOH估计不仅能够提升系统运行的安全性和可靠性,还能为电池的智能运维与调度提供重要支撑^[3]。SOH通常被定义为电池在当前状态下可用性能与初始性能的比值,是衡量电池老化程度的关键指标^[4]。最常见的判定方式是基于容量衰减,当SOH下降至70% - 80%时,电池通常被认为达到寿命终点(End of Life, EOL)^[5]。SOH的准确估计不仅有助于避免电池过度使用引发的安全隐患,而且是实现电池寿命预测与健康管理的基礎^[6]。因此,SOH估计的精度与鲁棒性直接关系到电池系统的可靠性与安全性,对智能运维与能量调度具有重要意义。

目前,电池SOH估计方法主要分为三类:实验方法、模型方法和数据驱动方法^[7]。实验方法如开路电压(Open Circuit Voltage, OCV)法、库仑积分(Coulomb Counting)法以及电化学阻抗谱(Electrochemical Impedance Spectroscopy,

EIS)测试等,能够通过直接测量电池的容量、内阻或阻抗特征来反映电池健康状态。OCV法基于端电压与SOC的单值对应关系,理论上可实现较高精度,但需要长时间静置以达到电化学平衡,实时性较差^[8]。库仑积分法通过对充放电电流积分来估算容量,但长期应用会受到测量噪声与漂移累积的影响。EIS方法则能够在频域层面揭示电池退化机理,但测试条件苛刻、设备昂贵且难以车载化应用^[9]。因此,实验方法虽然直观,但往往存在高成本与低实时性的问题。模型方法主要包括基于物理机理的电化学模型和基于等效电路的简化模型。电化学模型能够从反应动力学角度准确描述电池内部离子传输与相变过程,但其参数众多、计算复杂,需要大量实验标定,难以满足在线估算的需求^[10];等效电路模型(Equivalent Circuit Model, ECM)则以电阻、电容等元件近似电池动态行为,并结合扩展卡尔曼滤波(EKF)、无迹卡尔曼滤波(UKF)等方法进行参数辨识和SOH估计,具有建模简便、计算高效的优点^[11]。但ECM本质上是一种近似模型,参数会随温度、SOC和循环工况发生显著波动,从而限制了在不同场景下的普适性。

数据驱动方法凭借强大的非线性建模与特征自动提取能力,已成为近年来电池SOH估计的重要研究方向^[12]。早期研究主要采用传统机器学习方法,如支持向量机(SVM)^[13]、高斯过程回归

(GPR)^[14]和随机森林(RF)^[15],通过人工构造的电压、电流、温度特征建立映射模型,虽然在小规模数据集上取得了一定精度,但高度依赖专家经验,难以适应多样化工况^[16]。为克服人工特征工程的不足,研究者开始引入深度学习方法。Zhang等人^[17]基于LSTM网络直接建模电池容量退化序列,能够捕捉时间依赖特征,并在NASA与CALCE数据集上取得较高精度,但在快速衰减阶段预测误差明显增大。Zhu等人^[18]提出了一种端到端深度学习模型能够直接从原始充电数据中高精度地估计锂电池健康状态。其预测平均绝对误差在NASA数据集上低至1.14%,在牛津数据集上更是达到了0.038%。在序列建模任务中,为应对梯度消失问题并提升模型对远距离上下文信息的捕捉能力,注意力机制应运而生,并迅速成为关键技术。通道注意力机制(SE和SEA)被用于对特征通道加权,以突出关键的退化特征^[19-20]。时序注意力机制则通过学习不同时刻的重要性来捕捉其不同阶段的特性^[21]。以Transformer为代表的全局注意力机制旨在建模序列中任意元素之间的直接交互,通过计算所有时间步的关联权重实现全局依赖关系建模^[22]。Bao等人^[23]提出的TTSNet结构利用VIT分支提取电压、电流和温度特征,再结合时间Transformer编码器与注意力引导的特征融合模块,在SOC和SOH预测任务中表现显著优于传统RNN与CNN。Wang等人^[24]提出了一种融合多尺度特征提取、改进型LSTM与双流注意力机制的多任务学习框架,实现了锂电池SOH高精度预测。Gui等人^[25]提出了一种基于多模态数据信息对齐的锂离子电池SOH估计方法,通过结合本地-全局并行的CNN-Transformer网络以及多信息对齐的迁移学习策略,有效提升了在目标域数据稀缺场景下的估计精度与泛化能力,然而,这类方法的计算开销较大,在长序列建模中存在效率瓶颈,同时缺乏结构化约束,在跨工况与跨电池条件下的稳定性仍有不足。现有的锂电池SOH估计方法多基于深度神经网络对多变量时间序列进行建模,并在一定程度上引入通道注意力或特征融合机制以刻画多物理量信息。然而,已有方法在通道间特征交互的建模方式上通常依赖独立加权或局部关联假设,难以充分刻画电压、电流和温度等信号在电池退化过程中的全局协同性,从而在复杂退化场景下仍存在特征利用

不充分的问题。

综上所述,数据驱动方法在时序建模、特征自动提取、多模态融合与注意力机制引入等方面取得了显著进展。在电池SOH估计中,多尺度特征的学习是一个关键挑战。尤其在处理电池退化过程中的多样化特征时,传统的池化方法往往无法有效地捕捉不同时间尺度上的重要信息,更为重要的是,当前许多深度学习方法对特征通道之间的联系重视不足,忽略了各个通道特征在不同电池状态下的交互和相互作用,导致特征融合过程中的信息丢失,限制了模型性能的提升。本文提出了一种多通道混合池化特征融合的方法,用于锂电池SOH的估计。本文的主要贡献如下。

(1)针对锂电池退化特征在统计属性上呈现异质性的问题,本文提出一种混合金字塔池化(HPP)结构,在多尺度池化框架下融合最大池化、平均池化与L2池化,从不同统计视角对局部异常、长期趋势与整体能量变化进行协同建模。

(2)针对锂电池SOH估计中多模态特征之间存在强相关性但难以有效建模的问题,本文引入基于特征交互核心(series-core fusion)的STAR特征融合模块,对多通道时序特征进行集中式全局融合。该模块通过构建统一的核心表示来刻画电压、电流和温度等信号的共性退化特征,并通过残差映射将全局信息反馈至各通道,从而避免传统通道注意力机制对单一特征质量的过度依赖,在复杂退化场景下提升模型的稳定性与鲁棒性。

(3)为全面评估所提方法的有效性,本文在马里兰大学、同济大学及西安交通大学三个公开电池数据集上进行了系统实验。结果表明,通过HPP与STAR的SOH预测方法在所有数据集上均表现出优异的性能,能够准确捕捉不同电池在不同退化阶段的变化趋势。与传统方法相比,本方法在预测精度、计算效率与跨数据泛化能力方面均具有明显优势,显示出良好的实用价值与推广潜力。

1 方法

本次用于估计电池SOH的模型结构如图1所示,该网络结构采用多通道输入处理方式,分别利用电压、电流和温度信号进行特征提取。其主要结构包括三个分支网络:电压分支、电流分支和温度分支,每个分支通过1D卷积层提取局部特征。之

后, 利用混合金字塔池化 (HPP) 对各分支的特征进行多尺度池化, 以增强模型对不同时间尺度信息的感知。池化后的特征进一步融合进入 STAR 模块, 该模块通过自适应加权融合特征, 强化重要特

征, 并通过残差连接确保信息流的有效传递。最终, 融合后的特征通过全连接层进行映射, 输出 SOH 预测结果。

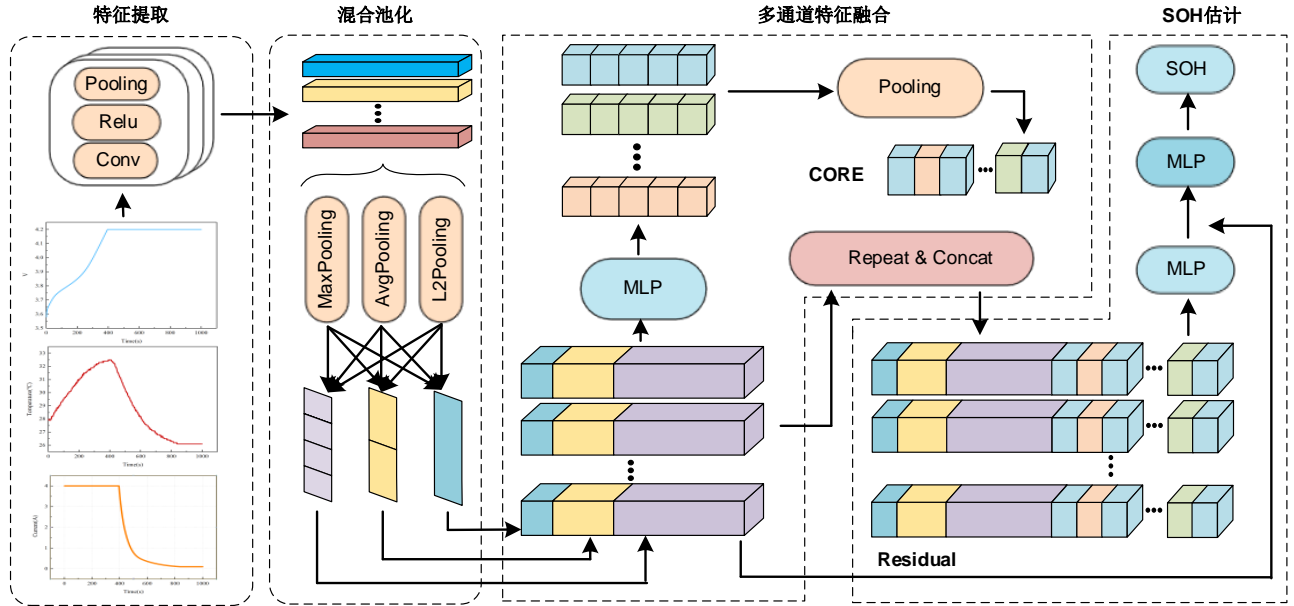


图 1 锂电池 SOH 预测模型结构框图

Fig. 1 Block diagram of the lithium battery SOH prediction mode

1.1 CNN 特征提取层

本文通过 CNN 神经网络来提取电压电流温度上的特征, 具体的示意图如图 2 所示, CNN 通过卷积核在输入数据上滑动, 能够高效地捕捉局部相关性和空间模式, 对于电池的时序数据, 这意味着可以准确地识别出电压骤降、电流尖峰、温度异常等短期、局部的退化征兆。同时相同的卷积核在整个输入序列上共享参数, 这大大减少了模型需要学习的参数量, 降低了过拟合的风险。具体来说, 输入数据 $X \in \mathbb{R}^{B \times C \times L}$ 经过卷积操作后, 利用卷积核 W_k 对输入数据进行特征提取, 得到新的特征表示:

$$X' = \text{Conv1D}(X, W_k) + b_k \quad (1)$$

其中, $b_k \in \mathbb{R}^{d_{series}}$ 是偏置项, $X' \in \mathbb{R}^{B \times C \times L'}$ 是经过卷积层处理后的特征表示, L' 是卷积后特征的长度, 接着使用 RELU 激活函数对卷积结果进行非线性变换, 进一步增强模型的表达能力, 然后使用最大池化操作对卷积后的特征图进行池化, 减少计算量并保留最显著的特征:

$$X_{pool} = \text{MaxPooling}(X'_{ReLU}, p_{size}, p_{stride}) \quad (2)$$

其中 p_{size} 是池化窗口的大小, p_{stride} 是池化步

幅。池化操作后, 特征图的大小减小, 信息浓缩。通过堆叠多个卷积层和池化层, CNN 能够逐层提取电池数据中的多层次特征。每一层卷积和池化操作使得模型能够从局部特征中逐步学习到更抽象的高维特征。在每个特征 (电压、电流、温度) 经过三层的卷积层和池化层提取特征后, 本文将它们沿通道进行拼接, 得到最终的特征表示。

$$X_{final} = \text{concat}(X_{V_{pool}}, X_{I_{pool}}, X_{T_{pool}}) \quad (3)$$

1.2 混合金字塔池化层

为了增强模型对电池退化过程中的多尺度特征的学习能力, 本文在空间金字塔池化 (SPP) [26] 进行改进, 混合空间金字塔结构如图 3 所示。SPP 通过在不同尺度下对特征进行池化, 有效增强了模型对多尺度信息的感知能力。然而, SPP 通常采用单一池化算子, 其隐含假设是不同尺度下的特征可以通过同一种统计方式进行有效表征。在锂电池 SOH 估计任务中, 这一假设并不完全成立。电池退化过程中同时存在局部突变特征、长期演化趋势以及整体幅值变化等具有不同统计属性的退化信息, 单一池化方式难以对其进行全面刻画。该模块

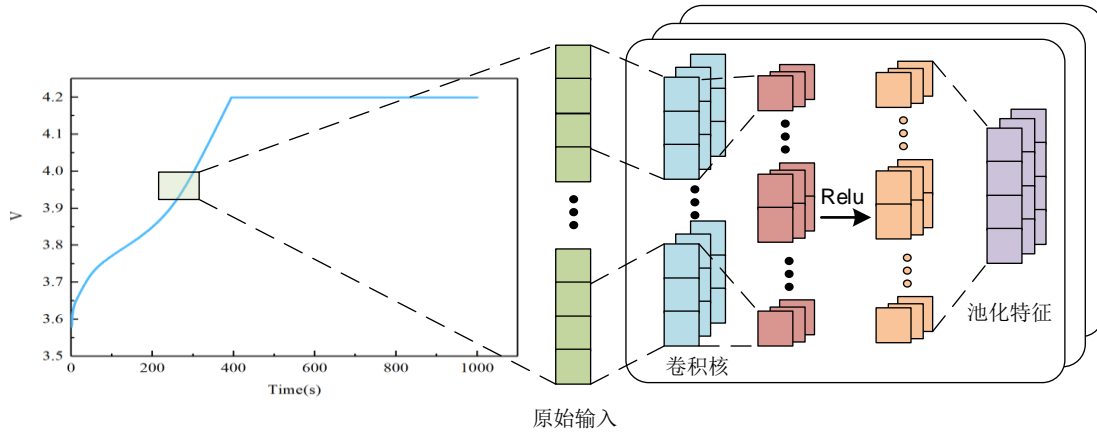


图2 CNN特征提取层示意图
Fig. 2 Schematic diagram of the CNN feature extraction layer

结合了多种池化方式（最大池化、平均池化和L2池化），其中，不同池化算子从不同统计视角对特征进行建模，最大池化强调局部极值变化，平均池化刻画整体趋势，而L2池化对特征能量变化更加敏感。通过在多个尺度上对特征进行池化操作，帮助模型从不同尺度和不同特征视角学习退化特征，从而提高了模型的鲁棒性和精度。HPP模块能够有效地捕捉不同时间尺度和特征类型上的信息，使得模型能够更好地应对电池退化模式的多样性。

力机制提供多尺度、多特征的丰富表示。具体的计算过程如下。

首先对输入特征 X 进行池化，池化的尺度由人为设定，对于每个池化尺度 L_p ，计算池化窗口的大小 k ，步幅为 s 和填充 p ：

$$k, s = L/L_p \quad (4)$$

$$p = k/2 \quad (5)$$

接下来，分别进行最大池化、平均池化和L2池化操作。对于每个池化尺度 L_p ，池化操作可以通过以下公式得到池化后的特征表示 X_{scale} ：

$$X_{scale}^{max} = \text{MaxPooling}(X, k, s, p) = \max(x_i) \quad (6)$$

$$X_{scale}^{avg} = \text{AvgPooling}(X, k, s, p) \quad (7)$$

$$X_{scale}^{l2} = \text{L2Pooling}(X, k, s, p) \quad (8)$$

其中各个池化的所代表的计算方式为：

$$\text{MaxPooling}(x) = \max(x_i) \quad (9)$$

$$\text{AvgPooling}(x) = \frac{1}{k} \sum_{i=1}^k x_i \quad (10)$$

$$\text{L2Pooling}(x) = \sqrt{\sum_{i=1}^k x_i^2} \quad (11)$$

对于每个池化尺度，可以得到一个池化后的特征表示 X_{scale} 。本文将所有的池化尺度的特征表示沿通道维度进行拼接，得到最终的多尺度特征表示：

$$X_{final} = \text{concat}(X_{scale}^{max}, X_{scale}^{avg}, X_{scale}^{l2}, \dots) \quad (12)$$

1.3 混合金字塔池化层

STAR模块最初由Han等人^[27]提出，用于多变量时间序列预测任务，如图4所示，其核心思想是通过特征交互核心机制实现集中式特征交互，从而避免传统分布式注意力机制在多变量场景下的高复杂度与不稳定性。本文借鉴STAR的这一思想，并

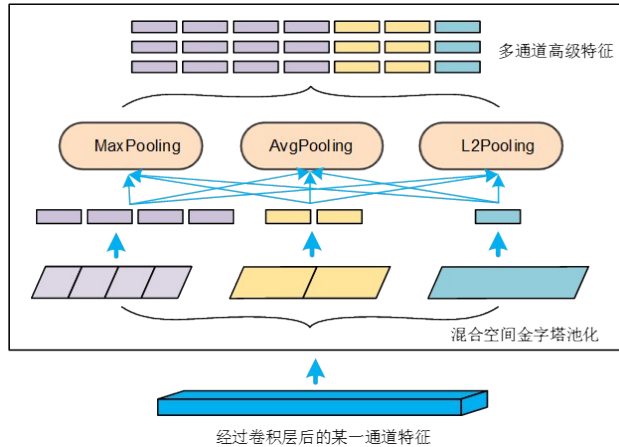


图3 混合金字塔池化结构图
Fig. 3 Structure diagram of hybrid pyramid pooling

HPP模块的输入是一个形状为 $X \in \mathbb{R}^{B \times C \times L}$ 的张量，其中 B 是批次大小， C 是通道数， L 是每个通道的特征维度。该模块通过在多个池化尺度对特征进行混合池化，包括最大池化、平均池化和L2池化。得到不同尺度的池化方式的特征表示，并将结果沿通道维度进行拼接，从而为后续通道注意

将其引入锂电池 SOH 估计任务，用于建模电压、电流和温度等多物理量特征在退化过程中的全局耦合关系。从建模假设角度看，STAR 与传统通道注意力机制存在本质差异。SE、ECA 等方法隐含假设各通道对预测目标的贡献是可区分的，因此通过独立加权来强调“重要通道”、抑制“次要通道”。

然而，在锂电池 SOH 估计任务中，电压、电流和温度等多物理量信号通常受共同老化机理驱动，其退化过程呈现出显著的协同性与一致性。STAR 通过构建统一的特征交互核心表示，显式建模这种共源退化特征，而非对单一通道进行竞争式加权，从而更符合 SOH 演化过程的实际特性。




图 4 注意力机制对比图

Fig. 4 Comparison diagram of attention mechanisms

该注意力机制的具体计算方法如图 5 所示。首先，为了将电池的时序数据映射到高维空间，采用线性投影（Embedding）操作，将原始输入数据 $X \in \mathbb{R}^{C \times d}$ 映射为隐藏空间的表示 $S_0 \in \mathbb{R}^{C \times d'}$ ，其中 C 是通道数， d 是每个通道的特征和维度， d' 是隐藏层的维度：

$$S_0 = \text{Embedding}(X) \quad (13)$$

其中线性投影由两个全连接层构成：

$$\text{Embedding}(X) = W_2(\text{Gelu}(W_1 X + b_1)) + b_2 \quad (14)$$

其中 W_1 和 b_1 分别对应着全连接层的权重矩阵和偏置向量。

Gelu 是一个光滑的激活函数，其公式为：

$$\text{Gelu}(x) = 0.5 \cdot x \left(1 + \tanh \left(\sqrt{\frac{2}{\pi}} \cdot (x + 0.044715x^3) \right) \right) \quad (15)$$

接下来，使用 Softmax 计算每个通道的权重：

$$S_1 = \text{softmax}(S_0) = \frac{e^{S_0}}{\sum_{i=1}^C e^{S_0}} \quad (16)$$

随后基于 Softmax 权重的加权选择机制，从每个样本中选择一个通道

$$\text{indices}_i = \text{multinomial}(S_1, 1) \quad (17)$$

根据采样得到的通道索引，从核心特征 S_1 中选择对应的通道特征，通过

$$S'_1 = \text{gather}(S_1, \text{indices}_i) \quad (18)$$

具体而言，在每次特征融合过程中，通过权重

分配机制从多通道特征中选取一个具有代表性的核心特征，用以表征当前时序样本的全局退化模式。由于该核心特征在通道维度上与原始输入特征数量不一致，为保证后续网络结构在维度上的一致性，本文将该核心特征在通道维度上进行扩展，使其通道数与原始输入保持一致。随后，将扩展后的核心特征与原始输入特征在通道维度上进行拼接，从而在保留原始多通道信息的同时，引入全局退化表征，形成更加丰富且具有互补性的特征表示：

$$S''_1 = \text{concat}(X, (\text{repeat}(S'_1, C))) \quad (19)$$

随后通过两层线性层将 S''_1 映射到 X 相同的维度并进行残差连接得到最终的特征：

$$S_{\text{final}} = X + W_4(\text{Gelu}(W_3 S''_1 + b_3)) + b_4 \quad (20)$$

最后经过两层全连接将所有的特征信息进行总结来得到最后的预测 SOH 的结果

$$\text{SOH} = W_6(\text{Relu}(W_5 S''_1 + b_5)) + b_6 \quad (21)$$

2 电池数据集介绍及处理

2.1 数据集介绍

本研究使用了三个公开数据集进行实验验证，具体包括马里兰大学数据集（CALCE）^[28]、西安交通大学（XJTU）数据集^[29]和同济大学（TJ）数据集^[30]。如表 1 所示，这些数据集涵盖了不同化学成分的电池，包括钴酸锂电池（LCO）、镍钴锰三元

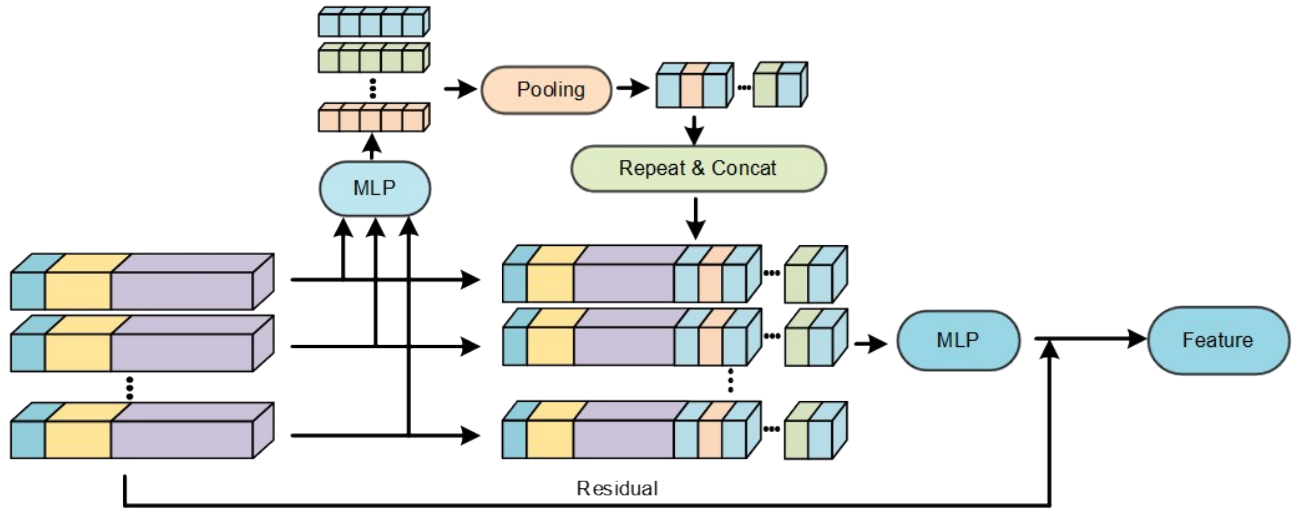


图 5 特征注意力融合结构图

Fig. 5 Structure diagram of feature attention fusion

电池（NCM）、镍钴铝三元电池（NCA）等类型，电池的容量、截止条件和样本数量各不相同，为评估模型的泛化能力提供了充分的依据。每个数据集都包含了多个充放电周期的数据，且SOH在实验过程中逐步衰减。

2.2 数据集分配

为了公平地评估模型的性能，本研究对每个数据集进行了合理的划分，确保训练集、验证集和测试集的划分具有代表性和多样性。具体的划分如表

表 1 实验电池详细说明

Table 1 Detailed description of experimental batteries

电池成分	马里兰大学	西交大	同济大学
化学成分	LCO	NCM	NCA
额定容量	1.1Ah	2Ah	3.5Ah
EOL	0.77Ah	1.6Ah	2.5Ah
饱和电压	4.2V	4.2V	4.2V
电池总数	15	55	130

2所示。

表 2 数据划分策略

Table 2 Data partitioning strategy

数据集	训练集	验证集	测试集
CALCE	CS2_33 CS2_34 CS2_35	CS2_36	CS2_37 CS2_38
XJTU	Batch1_1 Batch1_2 Batch1_3	Batch1_4	Batch1_5 Batch1_6 Batch1_7
TJ	TJ45_11 TJ45_12 TJ45_13 TJ45_14 TJ45_15	TJ45_11 TJ45_12 TJ45_13	TJ45_19 TJ45_20 TJ45_21 TJ45_22 TJ45_23

2.3 数据预处理

首先，针对不同数据集和不同充电循环中采样点数不一致的问题，本文对单次充电过程的电压、电流和温度时序数据进行统一的长度对齐处理。具体而言，以每个充电循环的完整充电过程为基本单元，通过重采样方式将原始时序映射到统一的时间维度上，从而消除不同循环采样长度差异对模型训练的影响。

在实现过程中，本文采用一维线性插值方法对原始时序信号进行重采样。插值公式为：

$$y = y_i + \frac{(x - x_i)}{(x_{i+1} - x_i)}(y_{i+1} - y_i) \quad (22)$$

该过程仅用于时间轴对齐，使不同样本在时间维度上具有一致的表示形式，而不改变原始信号的整体变化趋势和统计特性。通过上述处理，不同数据集和不同循环的数据均可作为统一格式的模型输入，便于后续多尺度特征提取与特征融合。

2.4 评估指标

为了全面评估模型的性能，本文采用了以下几个常见的评估指标。

平均绝对误差（MAE）用于衡量预测值与实际

值之间的差异。其计算公式为：

$$MAE = \frac{1}{n} \sum_{i=1}^n |SOH_i - SOH'_i| \quad (23)$$

均方根误差（RMSE）衡量的是预测误差的标准偏差，能够反映预测值与实际值的偏差程度。其计算公式为：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (SOH_i - SOH'_i)^2} \quad (24)$$

平均绝对百分比误差（MAPE）用于衡量预测误差相对于实际值的百分比。其计算公式为：

$$MAPE = \frac{1}{n} \left| \frac{SOH_i - SOH'_i}{SOH_i} \right| \quad (25)$$

其中 SOH'_i 表示预测 SOH 的算术平均值。

3 实验结果与讨论

本节介绍本文在三种公开数据集下进行的实验，以验证所提方法的有效性。

3.1 实验设置

本节基于以下硬件平台开展：13th Gen Intel (R) Core(TM) i7-13650HX（主频 2.6GHz）、NVIDIA GeForce RTX 4060 Laptop 显卡、16GB 内存及 Windows11 操作系统。实验模型采用 Python3.9 与 Pytorch2.6 框架实现，模型具体结果如第三章所述。优化器采用 Adam 算法，学习率设为 1×10^{-3} 。模型训练总轮次设定为 200，批次大小为 64。

3.2 消融实验

为验证本文提出的 HPP 模块与 STAR 特征聚合模块共同带来的性能提升，本文设计了一项消融实验，将完整模型与一个仅包含普通 CNN 与 SPP 模块的基线模型进行对比。所有实验均在相同的训练设置、超参数与数据集划分下进行，以确保对比的公平性。数据集采用 XJTU 数据集，实验结果如图 6、图 7 所示。

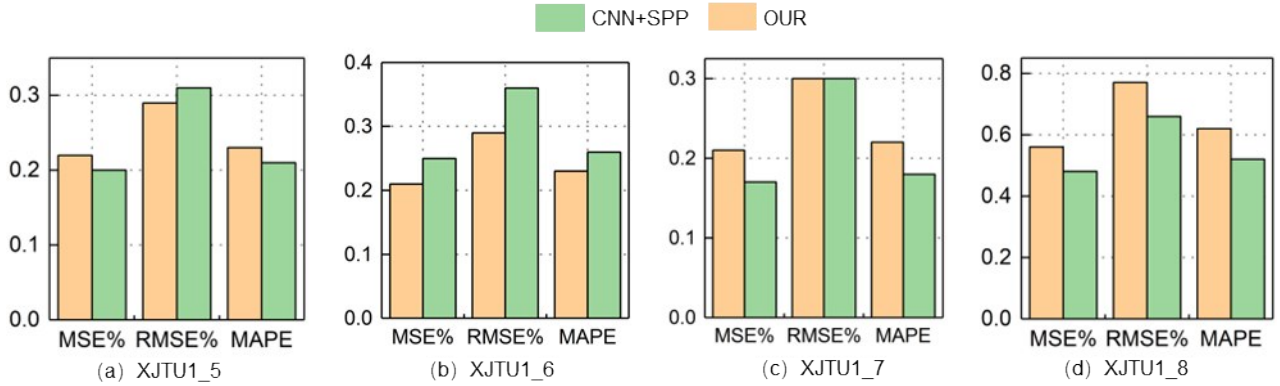


图6 消融实验结果对比图

Fig. 6 Comparison of ablation experiment results

需要说明的是，本文提出的混合金字塔池化（HPP）模块在结构设计上并非作为独立组件使用，其多尺度、多统计特征输出旨在为后续的 STAR 特征融合模块提供更加丰富且具有互补性的通道表示。STAR 模块通过特征交互核心机制对多通道特征进行集中式建模，其有效性依赖于前端特征在统计属性和尺度信息上的多样性。

基于上述结构耦合关系，本文在消融实验中选择以 CNN-SPP 作为对比基线模型，用于评估由 HPP 与 STAR 共同引入的性能增益。其中，SPP 模块采用单一池化算子进行多尺度特征汇聚，能够在保持整体网络结构一致的前提下，与所提出的 HPP

- STAR 结构形成合理对照。该设计有助于客观评估混合池化与集中式特征融合在 SOH 估计任务中的综合效果。

从图 6 中可以观察到，采用 HPP 和 STAR 特征聚合模块的模型在多个评估指标上显著优于基线模型。从图 7 中也可看见，黄色曲线的预测结果较为稳定，且其点分布更加接近理想红色拟合线，表明该模型的预测精度较高，能够更准确地反映实际 SOH 的变化。而绿色散点所代表的基线模型在多个 SOH 值区间，尤其是 SOH 较低和较高的区间出现了较大的预测误差，表现出一定的波动，表明该模型在处理电池退化的复杂性方面存在不足。

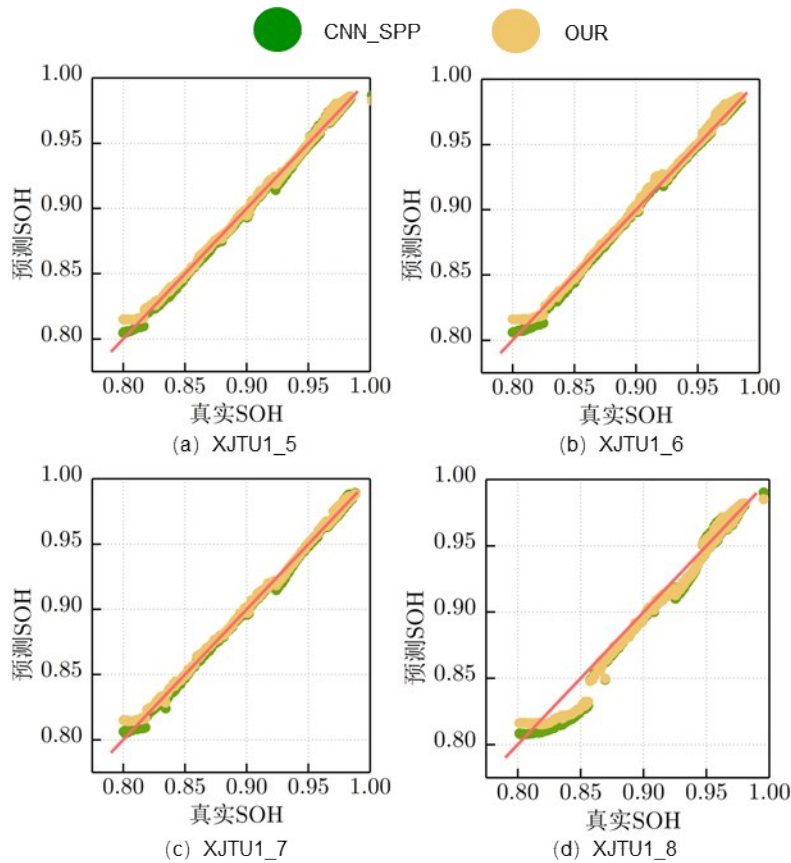


图 7 消融实验一致性散点图

Fig. 7 Scatter plot of consistency in ablation experiments

这一结果验证了HPP和STAR模块在提升模型性能方面的有效性。HPP模块通过多尺度特征融合，增强了对电池退化过程中不同尺度信息的捕捉能力，而STAR模块则通过优化特征通道之间的交互，进一步提升了模型的表现。尤其在电池退化的后期，采用HPP和STAR模块的模型能够更好地适应退化过程中的复杂变化，展现出更强的鲁棒性和泛化能力。

3.3 对比实验

在本研究中，本文使用了四种不同的模型来预测锂电池的SOH，包括CNN、CNN-LSTM、Transformer和本文提出的模型（OUR）。为了验证各模型的性能，本文在多个公开电池数据集上进行了测试，涉及不同的退化模式和工况。总体的实验结果如表3所示。

从实验评估指标的结果可以看出，本文的方法在大多数数据集上均表现出优于其他模型的性能。在所有测试中，本文的方法在MAE、RMSE和MAPE指标上均优于CNN、CNN-LSTM和

Transformer模型。例如，在数据集CS2_36中，本文的方法在MAE（0.0068）、RMSE（0.009）和MAPE（1.2479）上均优于其他模型，其中CNN的MAE为0.009，RMSE为0.0167，MAPE为2.846%。通过这种多维度的性能提升，本文的方法展现了更强的准确性和鲁棒性。在其他数据集，如同济数据集TJ_45_20和西交大数据集XJTU_1_5，本文的模型也表现出较低的预测误差，尤其在MAE和RMSE上，分别为0.002和0.0026（tj-45-20数据集）以及0.0025和0.0036（xjtu-1-5数据集），相比之下，Transformer和CNN-LSTM模型的误差较大，尤其在MAPE指标上，我的方法仍然明显优于它们。从各个模型的实际预测图7中可以看到

对于同济大学数据集，所选取的电池的寿命表现出了较为稳定的下降趋势。从图中的各个电池的预测表现中可以看出，本文的模型能够更为准确地捕捉电池退化的过程，特别是在中后期的预测上，保持了与实际SOH的一致性，而其他模型在

表3 与现有方法的性能对比
Table 3 Performance comparison with existing methods

SOH		CS2_36			CS2_37			CS2_38			tj-45-19		
method	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	
CNN	0.0095	0.0167	2.846	0.0084	0.0154	2.289	0.0128	0.0227	1.6235	0.0029	0.0035	0.3557	
CNN-LSTM	0.0119	0.0184	2.8781	0.0085	0.0124	1.3773	0.0088	0.0116	1.2908	0.0029	0.0033	0.3738	
transformer	0.0079	0.0101	1.4905	0.0081	0.0109	1.1902	0.0083	0.0103	1.1664	0.002	0.0025	0.2406	
OUR	0.0068	0.009	1.2479	0.0066	0.0117	0.9816	0.0066	0.0085	0.8822	0.0013	0.0017	0.1661	
SOH		tj-45-20			tj-45-21			tj-45-22			tj-45-23		
method	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	
CNN	0.0028	0.0032	0.3488	0.0024	0.003	0.292	0.0031	0.0034	0.3925	0.0032	0.0043	0.4133	
CNN-LSTM	0.0035	0.0039	0.4403	0.0026	0.003	0.3316	0.0035	0.0045	0.4574	0.0024	0.0029	0.2958	
transformer	0.0027	0.0032	0.3329	0.0015	0.0021	0.1853	0.0019	0.0024	0.2471	0.0026	0.003	0.3167	
OUR	0.002	0.0026	0.233	0.0014	0.0018	0.1687	0.0015	0.0023	0.1909	0.0018	0.0025	0.2151	
SOH		xjtu-1-5			xjtu-1-6			xjtu-1-7			xjtu-1-8		
method	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	
CNN	0.004	0.0062	0.4341	0.0035	0.0057	0.3854	0.004	0.0063	0.4386	0.0051	0.0073	0.5578	
CNN-LSTM	0.0042	0.0056	0.4613	0.004	0.0051	0.4312	0.0063	0.0082	0.7003	0.0083	0.0111	0.9196	
transformer	0.0065	0.0075	0.6991	0.006	0.007	0.6399	0.0064	0.0077	0.6786	0.0057	0.0073	0.6214	
OUR	0.002	0.0031	0.2142	0.0025	0.0036	0.2659	0.0017	0.003	0.1834	0.0048	0.0066	0.5327	

一些数据点的误差相对会大一些，但总体的预测效果都较为良好。

对于马里兰大学的电池数据集来说，该数据集包含较长的周期电池且具有较高的动态变化。在锂电池退化的前期阶段表现出平稳的下降趋势，但在后期（500个循环以后），电池的SOH有较大幅度的下降，这对此时的SOH预测产生了一定的困难。在这种较为复杂的退化模式下，所提出的模型在电池SOH预测中表现出了出色的精度和鲁棒性。尤其是在SOH出现波动的阶段。而其他模型则在此阶段的表现不尽人意，未能充分捕捉到电池的退化状态。

对于西交大数据集的电池来说，SOH呈现出非单调的退化趋势：初期阶段，SOH出现短暂的上升，然后进入平稳下降阶段，随后的中期退化加速，最终进入后期稳定下降的阶段。具体而言，在前期（大约0到100个循环内），SOH先是略有回升，随后缓慢下降，维持在95%以上；进入中期（大约200至400个循环之间），SOH下降速率明显加快，电池的性能快速衰退；接近电池寿命终止（EOL）时，SOH的下降逐渐趋于平稳，最终保持在一个较低的水平。与其他预测模型进行对比时，

本文提出的模型在整体表现上优于其他模型，尤其在后期退化阶段，能够准确跟踪SOH的变化趋势。其他模型在后期退化过程中出现了较大误差，特别是在200至300个循环之间的预测波动较大，可能是由于这些模型未能有效捕捉电池退化的动态特征或受到充放电策略等因素的影响。但在锂电池的SOH初期的上升时段，这些模型并不能够十分精准地预测SOH。

本文方法的性能优势并不主要体现在所有样本上均获得大幅数值提升，而在于其在不同退化规律下保持了较稳定的预测能力。对于同济大学数据集中退化趋势相对平稳的样本，各模型均可取得较高精度；而在马里兰大学数据集中后期快速衰减样本以及西交大数据集中具有非单调退化特征的样本上，所提方法表现出更好的误差控制能力。这表明本文方法的价值更多体现在复杂退化场景下的鲁棒性提升，而非仅体现为简单样本上的局部精度改进。

为进一步评估所提出方法在现有研究中的相对性能水平，本文将实验结果与近年来部分文献中公开报告的SOH预测结果进行了对照分析，相关结果汇总如表4所示。需要指出的是，不同文献在数

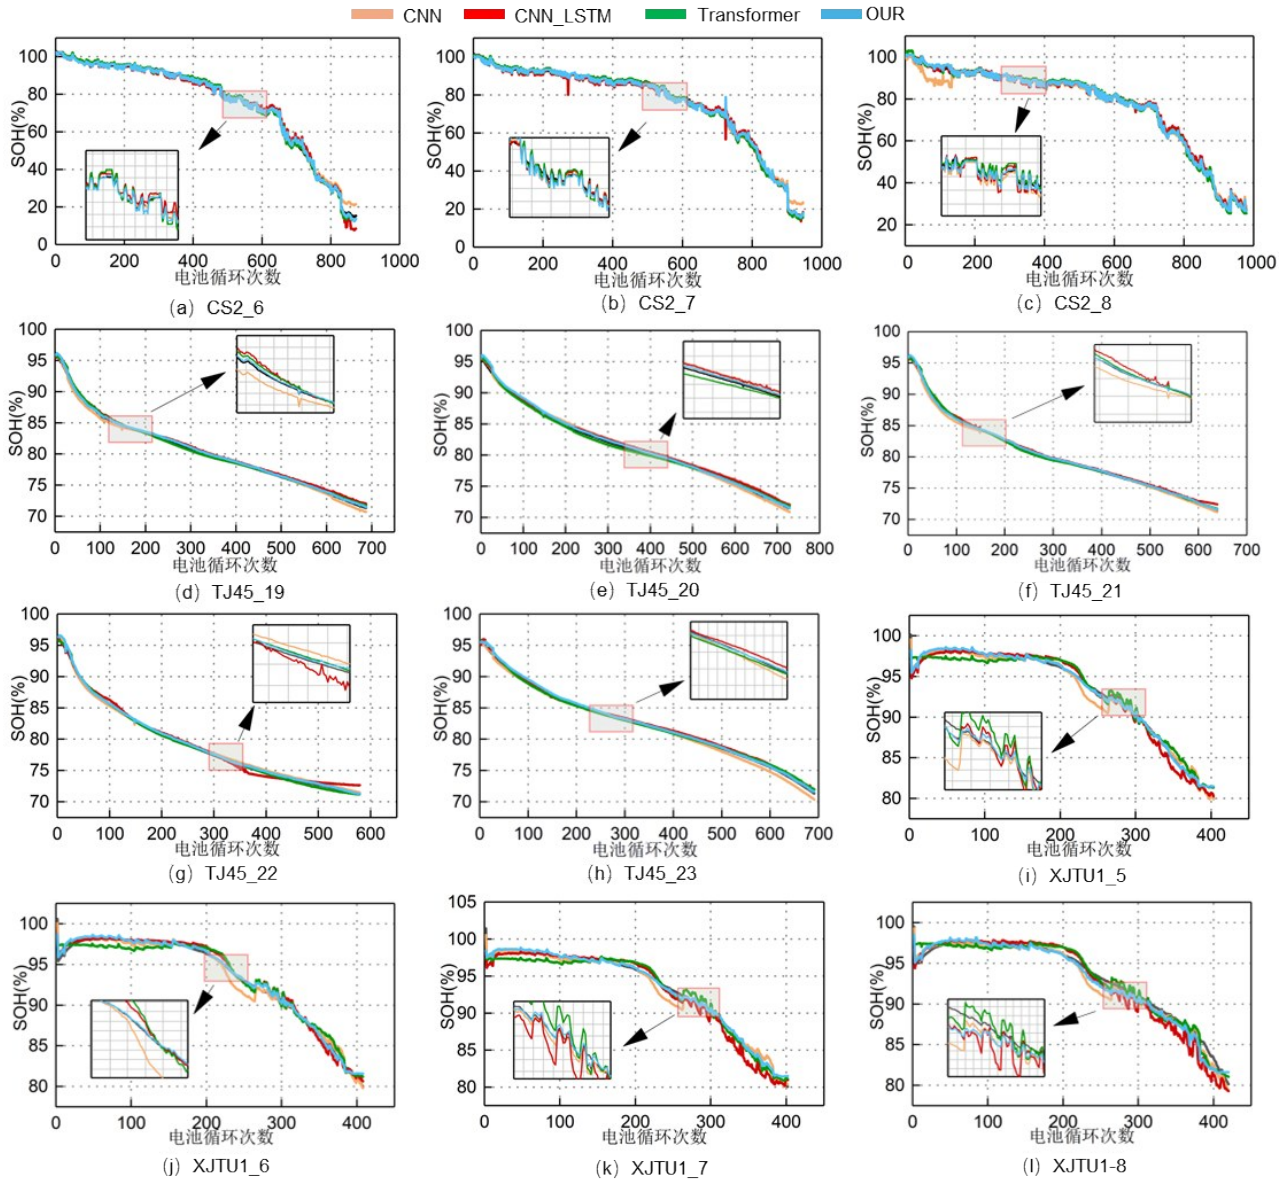


图 8 模型预测对比图

Fig. 8 Comparison of model predictions

据预处理策略、模型训练方式及实验设置等方面存在差异，因此该对照分析主要用于反映不同方法在SOH预测精度层面的总体水平，而非严格的同条件性能比较。从表4可以看出，本文方法在多个公开数据集上的预测误差水平与现有代表性方法相比具有一定竞争力，进一步验证了所提出方法在SOH估计任务中的有效性。

同时为了验证电流、电压和温度对SOH预测的有效性，本文在西交大数据集上进行了多组实验，分别使用电压、电流、电压与温度（VIT）等不同输入特征对SOH进行了预测，实验结果如图9

表 4 近年文献SOH对比结果

Table 4 Comparison of SOH results from recent literature

方法	数据集	MAE/%	RMSE/%	MAPE/%
Li ^[31]	CALCE	0.87	1.47	0.98
Chen ^[32]	CALCE	0.84	1.07	1.07
Wang ^[24]	XJTU	0.47	0.62	/
Ours(Average)	CALCE	0.66	0.97	1.03
	XJTU	0.22	0.4	0.29

所示。可以看出，采用电压、电流和温度作为输入特征的模型在MAE和RMSE方面均表现出较好的

性能。通过实验结果可以看出，电流、电压和温度作为输入特征显著提升了SOH预测的精度。在所有电池中，VIT模型的MAE和 R^2 都表现出明显的优势，尤其是在5号和第7号电池中，具有最低的MAE和最高的 R^2 ，这表明电流和温度信息对提高模型预测精度具有重要作用。相比之下，单独使用电压或电流特征的模型预测效果较差，尤其在第8号中，VIT模型依然保持了较低的误差，而仅使用

电流和电压的模型误差较大。值得注意的是，在第6号电池样本中，使用电压、电流、温度三模态特征所训练模型的MAE反而高于仅使用电压与电流的模型，表明温度特征在该组电池中可能未能提供有效的判别信息，甚至对模型预测造成一定干扰。这一现象可能归因于温度信号的变化范围较小或噪声较大，导致三模态融合反而影响模型对关键特征（电压与电流）的提取能力。

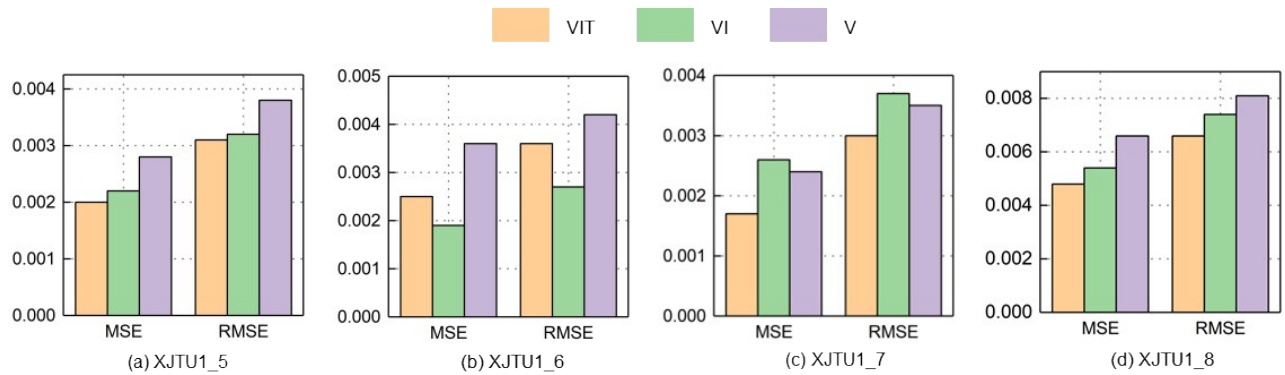


图9 电压电流温度对比图

Fig. 9 Comparison of voltage, current, and temperature

此外，图9展示了不同模型在各数据集上的相对误差分布，进一步验证了采用电压、电流和温度作为输入特征的模型相较于单一电压或电流特征模型，具有显著的性能优势。通过对比不同模型的结果，可以清楚地看到，VIT模型在所有数据集上均

展现出较低的相对误差，尤其是在5号和7号电池的预测中，显示了更为稳定和精确的预测性能，进一步印证了电流和温度信息对模型预测精度的重要贡献。

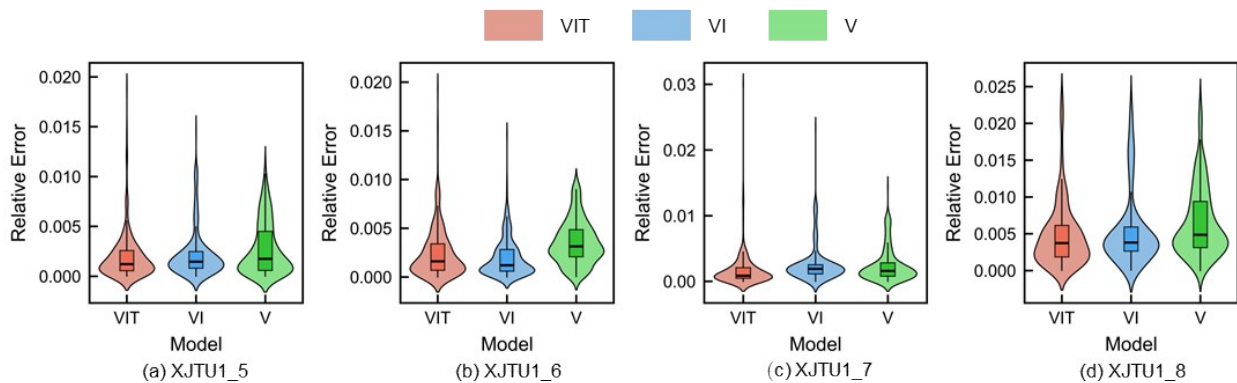


图10 电压电流温度误差对比小提琴图

Fig. 10 Violin plot of voltage, current, and temperature errors

3.4 充电区间适应性实验

为验证所提方法在缺乏完整充电区间数据情况下的适应能力，本文进一步开展了部分充电区间实验。在实际电动车运行过程中，由于用户充电行为

的不确定性，电池往往难以获得完整充电区间数据。因此，有必要评估模型在部分充电区间条件下的SOH估计性能。在本实验中，分别选取20%-80%和30%-70%的SOC区间作为模型输入，并

在 XJTU 数据集上进行测试。实验结果如表 5 所示。总体来看，在部分充电区间条件下模型仍保持较低预测误差，说明所提方法在缺乏完整充电区间数据的情况下仍具有较好的 SOH 估计能力，体现出一定的区间适应性。

表 5 不同充电区间下 SOH 预测误差 (MAE)

Table 5 SOH prediction error (MAE) under different charging intervals

电池	完全充电	20-80%	30-70%
XJTU1_5	0.002	0.002	0.0019
XJTU1_6	0.0025	0.0018	0.0029
XJTU1_7	0.0017	0.0024	0.0017
XJTU1_8	0.0048	0.005	0.0042
Average	0.00275	0.0028	0.00268

3.5 负载计算

为评估模型的复杂度与计算效率，本文采用 torchinfo 工具对所提出模型的参数规模进行统计。在输入序列长度为 4000 的条件下，模型总参数数量为 2.22×10^5 ，整体结构较为紧凑。模型主要由一维卷积、池化操作以及轻量级全连接层构成，未引入大规模自注意力矩阵计算，其前向计算复杂度约 92.4M mult-adds。值得注意的是，HPP 与 STAR 模块主要通过少量线性映射与特征重组操作实现，其引入的额外参数量在模型总参数中占比较低，并未显著增加整体计算负担。该结构设计在保证多尺度特征提取与多通道协同建模能力的同时，有效控制了模型复杂度。

为进一步评估所提出方法在工程应用场景下的计算效率与模型复杂度，本文在保持相同硬件平台与运行环境的条件下，对不同模型的训练时间与推理效率进行了对比分析。在相同训练轮次（200 轮）条件下，统计各模型的总训练时间与平均单轮训练耗时，结果如表 6 所示。CNN 模型具有最快的训练速度，但其预测精度相对有限；CNN-LSTM 在计算复杂度与性能之间表现出一定折中。相比之下，本文提出的方法在引入混合金字塔池化与 STAR 特征融合模块后，训练时间有所增加，但整体计算代价仍显著低于 Transformer 模型。同时，结合前述精度对比实验结果，可以看出所提出方法在预测精度提升的同时，保持了较为可控的计算开销，在精度与效率之间取得了良好的平衡，体现出较好的工程应用潜力。

表 6 训练时间对比

Table 6 Comparison of training time

模型	总训练时间/s	平均单轮训练时间/s
CNN	14.91	0.0745
CNN_LSTM	34.63	0.173
Transformer	252.45	1.262
Ours	57.81	0.289

4 结论

针对现有 SOH 估计方法中多通道特征交互不足、退化信息利用不充分的问题，本文提出了一种融合混合金字塔池化与 STAR 特征模块的 SOH 预测方法。该方法通过多尺度混合池化增强退化特征表征能力，并利用统一核心表示实现多通道特征的集中式融合。

在 CALCE、XJTU 和 TJ 三个公开数据集上的实验结果表明，所提方法在 MAE、RMSE 和 MAPE 等指标上总体优于 CNN、CNN-LSTM 和 Transformer 等对比模型，同时在训练时间和模型复杂度方面保持了较为可控的开销，体现出较好的精度—效率平衡。

为进一步验证模型在实际应用场景中的适应能力，本文补充开展了部分充电区间实验，在 20%-80% 和 30%-70% 的 SOC 区间条件下对模型性能进行了评估。实验结果表明，在部分充电区间条件下模型仍能保持较低预测误差，说明所提方法在缺乏完整充电区间数据时仍具有一定的 SOH 估计能力。未来工作将进一步研究更加灵活的输入区间建模方法，并结合真实车载运行数据开展验证，同时探索模型在嵌入式平台上的轻量化部署与优化，以提升方法在实际电池管理系统中的应用潜力。

参考文献

- [1] SHU X, SHEN J, GUO F, et al. Towards real-world battery health intelligence: A review of machine learning advances and challenges in SOH estimation[J]. eTransportation, 2025, 26: 100509. <https://doi.org/10.1016/j.etrans.2025.100509>
- [2] S V, CHE H S, SELVARAJ J, et al. State of health (SOH) estimation methods for second life lithium-ion battery—Review and challenges[J]. Applied Energy, 2024, 369: 123542. <https://doi.org/10.1016/j.apenergy.2024.123542>.
- [3] ALSUWIAN T, ANSARI S, ZAINURI M A A M, et al. A review of expert hybrid and co-estimation techniques for SOH and RUL estimation in battery management system with electric vehicle application[J]. Expert Systems with Applications, 2024, 246:

123123. <https://doi.org/10.1016/j.eswa.2023.123123>.
- [4] ZHANG L, CHEN C, LUO D. A comprehensive framework of synchronous SOC-SOH joint estimation for lithium-ion battery with multi-depth expert networks[J]. *Energy*, 2025, 339: 138953. <https://doi.org/10.1016/j.energy.2025.138953>.
- [5] YANG S, ZHANG C, JIANG J, et al. Review on state-of-health of lithium-ion batteries: Characterizations, estimations and applications[J]. *Journal of Cleaner Production*, 2021, 314: 128015. <https://doi.org/10.1016/j.jclepro.2021.128015>.
- [6] WANG R, CHEN L, XU J, et al. Multimodal deep learning with time-frequency health features for battery SOH and RUL prediction[J]. *Journal of Energy Chemistry*, 2026, 113: 303-314. <https://doi.org/10.1016/j.jechem.2025.09.018>.
- [7] DEMIRCI O, TASKIN S, SCHATZ E, et al. Review of battery state estimation methods for electric vehicles—Part II: SOH estimation[J]. *Journal of Energy Storage*, 2024, 96: 112703. <https://doi.org/10.1016/j.est.2024.112703>.
- [8] CHEN G, ZHOU H, XU Y, et al. A novel SOC-OCV separation and extraction technology suitable for online joint estimation of SOC and SOH in lithium-ion batteries[J]. *Energy*, 2025, 326: 136246. <https://doi.org/10.1016/j.energy.2025.136246>.
- [9] Raza K, Samadi A F, Berecibar M, 等. From EV to stationary energy storage: EIS-based SoH estimation for second life Li-ion batteries[J]. *Journal of Energy Storage*, 2026, 141: 119316. DOI: <https://doi.org/10.1016/j.est.2025.119316>.
- [10] QIN D, LI L, WU H, et al. A composite progressive approach alternating between electrochemical model and data-driven model for the state of health assessment of lithium-ion batteries [J]. *Journal of Energy Storage*, 2024, 97: 112921. <https://doi.org/10.1016/j.est.2024.112921>.
- [11] SUN J, LIU Y, KAINZ J. A comparative study of parameter identification methods for equivalent circuit models for lithium-ion batteries and their application to state of health estimation[J]. *Journal of Energy Storage*, 2025, 114: 115707. <https://doi.org/10.1016/j.est.2025.115707>.
- [12] BAO Z, NIE J, LIN H, et al. Dual-task learning for joint state-of-charge and state-of-energy estimation of lithium-ion battery in electric vehicle[J]. *IEEE Transactions on Transportation Electrification*, 2025, 11(1): 558-569. <https://doi.org/10.1109/TTE.2024.3393477>.
- [13] ZHANG J, WANG P, GONG Q, et al. SOH estimation of lithium-ion batteries based on least squares support vector machine error compensation model[J]. *Journal of Power Electronics*, 2021, 21(11): 1712-1723. <https://doi.org/10.1007/s43236-021-00307-8>.
- [14] YANG D, ZHANG X, PAN R, et al. A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve[J]. *Journal of Power Sources*, 2018, 384: 387-395. <https://doi.org/10.1016/j.jpowsour.2018.03.015>.
- [15] YANG N, SONG Z, HOFMANN H, et al. Robust state of health estimation of lithium-ion batteries using convolutional neural network and random forest[J]. *Journal of Energy Storage*, 2022, 48: 103857. <https://doi.org/10.1016/j.est.2021.103857>.
- [16] LIU J F, CHEN H W, IU H H C. Lithium-ion battery life prediction considering capacity regeneration using VMD and DAIPSO-GPR [J]. *Journal of Electronics & Information Technology*, 2023, 45(3): 1111-1120. <https://doi.org/10.11999/JEIT211585>. 刘金锋, 陈浩伟, IU H H C. 基于VMD和DAIPSO-GPR解决容量再生现象的锂离子电池寿命预测研究[J]. *电子与信息学报*, 2023, 45(3): 1111-1120.
- [17] ZHANG L, JI T, YU S, et al. Accurate prediction approach of SOH for lithium-ion batteries based on LSTM method[J]. *Batteries*, 2023, 9(3): 177. <https://doi.org/10.3390/batteries9030177>.
- [18] ZHU C, GAO M, HE Z, et al. State of health prediction for Li-ion batteries with end-to-end deep learning[J]. *Journal of Energy Storage*, 2023, 65: 107218. <https://doi.org/10.1016/j.est.2023.107218>.
- [19] GUO M H, LIU Z N, MU T J, et al. Beyond self-attention: External attention using two linear layers for visual tasks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(5): 5436-5447. <https://doi.org/10.1109/TPAMI.2022.3211006>.
- [20] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 11531-11539.
- [21] TAN C, GAO Z, WU L, et al. Temporal attention unit: Towards efficient spatiotemporal predictive learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023: 18770-18782.
- [22] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Advances in Neural Information Processing Systems. 2017, 30.
- [23] BAO Z, NIE J, LIN H, et al. TTSNet: State-of-charge estimation of Li-ion battery in electrical vehicles with temporal transformer-based sequence network[J]. *IEEE Transactions on Vehicular Technology*, 2024, 73(6): 7838-7851. <https://doi.org/10.1109/TVT.2024.3350663>.
- [24] WANG C, BAO Z, LIN H, et al. A multi-task targeted learning framework for lithium-ion battery state-of-health and remaining useful life[J]. *IEEE Transactions on Transportation Electrification*, 2025: 1-1. <https://doi.org/10.1109/TTE.2025.3610457>.
- [25] GUI X, DU J, WANG Q, et al. Multi-modal data information alignment based SOH estimation for lithium-ion batteries using a local - global parallel CNN-Transformer network[J]. *Journal of Energy Storage*, 2025, 129: 117178. <https://doi.org/10.1016/j.est.2025.117178>.
- [26] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[C]//Computer Vision - ECCV 2014. Cham: Springer, 2014: 346-361.
- [27] HAN L, CHEN X Y, YE H J, et al. Softs: Efficient multivariate time series forecasting with series-core fusion[J]. *Advances in Neural Information Processing Systems*, 2024, 37: 64145-64175.
- [28] HE W, WILLIARD N, OSTERMAN M, et al. Prognostics of lithium-ion batteries based on Dempster - Shafer theory and the Bayesian Monte Carlo method[J]. *Journal of Power Sources*, 2011, 196(23): 10314-10321. <https://doi.org/10.1016/j>

- jpowsour.2011.08.040.
- [29] WANG F, ZHAI Z, ZHAO Z, et al. Physics-informed neural network for lithium-ion battery degradation stable modeling and prognosis[J]. *Nature Communications*, 2024, 15(1): 4332. <https://doi.org/10.1038/s41467-024-48779-z>.
- [30] ZHU J, WANG Y, HUANG Y, et al. Data-driven capacity estimation of commercial lithium-ion batteries from voltage relaxation[J]. *Nature Communications*, 2022, 13(1): 2261. <https://doi.org/10.1038/s41467-022-29837-w>.
- [31] LI Y, QIN X, CHAI M, et al. SOH evaluation and RUL estimation of lithium-ion batteries based on MC-CNN-TimesNet model[J]. *Reliability Engineering & System Safety*, 2025, 261: 111125. <https://doi.org/10.1016/j.res.2025.111125>.
- [32] CHEN B, ZHANG Y, WU J, et al. Lithium-ion battery state of health estimation based on feature reconstruction and transformer-GRU parallel architecture[J]. *Energies*, 2025, 18(5). <https://doi.org/10.3390/en18051236>.