

机械滥用场景下锂离子电池温度 多模态神经网络预测方法

李杰, 李倩, 覃正鹏, 黄鑫蓉

(长安大学能源与电气工程学院, 710064, 西安)

摘要: 针对锂离子电池机械滥用场景下单一模态建模、简单融合策略和物理约束不足导致的温度预测精度低的问题,提出了一种基于多模态神经网络的最高温度预测方法。首先,选用 1 200 mA·h 的 18650 型锂离子电池,在 10%~90% 荷电状态范围内开展机械挤压实验,采集热成像图、荷电状态、电压、载荷和变形等多源数据,构建超过 200 组的多模态数据集。然后,利用多尺度卷积模块、注意力机制和双向长短期记忆网络提取热成像时空特征,结合一维卷积神经网络与双向长短期记忆网络提取电化学与力学时序特征,并通过变换器融合机制实现跨模态特征自适应融合。最后,引入温度变化率约束的物理损失函数,以提升预测的合理性和鲁棒性。研究表明:多模态神经网络模型短期预测(1~3 步)的决定系数达到 0.972~0.990,中长期预测(6~15 步)的决定系数稳定在 0.900 以上,能够实现机械滥用条件下锂离子电池的多步预测,并在不同荷电状态和预测步长下表现出显著的精度优势和良好的适应性,为锂离子电池热失控的多级预警和安全管理提供了技术支持。

关键词: 锂离子电池;机械滥用;注意力机制;温度预测

中图分类号: TM734 **文献标志码:** A

DOI: 10.7652/xjtuxb202602004 **文章编号:** 0253-987X(2026)02-0038-11

Multimodal Neural Network-Based Temperature Prediction Method for Lithium-Ion Batteries Under Mechanical Abuse Scenarios

LI Jie, LI Qian, QIN Zhengpeng, HUANG Xinrong

(School of Energy and Electrical Engineering, Chang'an University, Xi'an 710064, China)

Abstract: To address the issue of low temperature prediction accuracy in lithium-ion batteries under mechanical abuse scenarios caused by single-modal modeling, simplistic fusion strategies, and insufficient physical constraints, a maximum temperature prediction method based on multimodal neural networks is proposed. First, 18650-type lithium-ion batteries with a capacity of 1 200 mA·h were selected, and mechanical compression experiments were conducted within a state of charge (SOC) range of 10% to 90%. Multi-source data including thermal images, SOC, voltage, load, and deformation were collected to construct a multimodal dataset comprising over 200 sample groups. Subsequently, multiscale convolutional modules, attention mechanisms, and bidirectional long short-term memory (Bi-LSTM) networks were used to extract spatiotemporal features from thermal images, while one-dimensional convolutional neural networks combined

收稿日期: 2025-07-03。

作者简介: 李杰(1984—),男,副教授,博士生导师。

基金项目: 国家自然科学基金资助

项目(52407236)。

网络出版时间: 2025-09-30

网络出版地址: <https://link.cnki.net/urlid/61.1069.T.20250930.0017.002>

with Bi-LSTM were employed to extract electrochemical and mechanical spatial-temporal features. Cross-modal adaptive feature fusion was achieved through a transformer fusion mechanism. Finally, a physics-informed loss function incorporating temperature change rate constraints was introduced to improve prediction rationality and robustness. The results show that the multimodal neural network model achieves coefficients of determination of 0.972 to 0.990 for short-term predictions (1—3 steps) and remains stable above 0.900 for medium-to long-term predictions (6—15 steps). The model enables effective multi-step temperature prediction under mechanical abuse conditions and demonstrates significant accuracy advantages and good adaptability across different SOC levels and prediction horizons, providing technical support for multi-level early warning and safety management of lithium-ion battery thermal runaway.

Keywords: lithium-ion battery; mechanical abuse; attention mechanism; temperature prediction

随着电动汽车与储能系统的快速发展,锂离子电池因高能量密度和长寿命而被广泛应用,但其在机械滥用条件下的安全性仍是关键制约因素^[1-2]。机械冲击或挤压可能导致内部结构损伤、隔膜破裂和电解液泄漏,引发短路与热失控进而产生高温,严重威胁设备与人员安全^[3]。因此,准确预测机械滥用下的最高温度对安全设计和风险评估至关重要。

传统热失控预测依赖于物理建模和数值仿真,但在复杂场景下,模型构建困难,计算开销大^[4-5]。近年来,机器学习与深度学习在电池状态估计和安全预测中展现潜力^[6]。Zhang等^[1]系统梳理了热失控机制与方法。张世超等^[7]和Feng等^[8]分别总结了热行为特征与防护策略。朱振威等^[6]综述了机器学习在安全预测中的应用。Thelen等^[9]和Khaleghi等^[10]提出了概率与在线学习方法,以应对制造差异和时变性。此外,物理信息神经网络(PINN)通过引入物理约束提升了模型的可解释性^[11]。Liu等^[12]利用多模态数据对健康状态进行建模。Suh等^[13]提出时空注意力网络,显著提升了寿命预测性能。在热失控预测方面, Kim等^[14]将PINN和深度算子网络相结合,进行虚拟数据建模^[15], Das Goswami等^[16]构建多物理-深度融合模型,实现了电池的包级预测。针对机械滥用, Chai等^[17]揭示了磷酸铁锂热失控行为, Azuaje-Berbecí等^[5]建立了机械变形热模型, Kong等^[18]探讨了热失控传播机制。

在电池状态建模中,多模态学习展现出其独特优势^[19]。Ding等^[20]提出元热失控预测神经网络模型,融合高维热成像、低维温度和电压数据实现了多步热失控预测。Lanubile等^[21]提出知识引导框架,用于健康状态估计。Iftikhar等^[22]结合自编码器与长短期记忆网络,提升了寿命预测精度。Li^[23]提出

了一种基于数据驱动的锂离子电池机械滥用条件下热失控预警方法。Pan等^[24]和Cortada等^[25]分析了荷电状态、空气暴露和机械载荷对电池结构的影响。Valizadeh等^[26]指出数据可用性和泛化能力是关键挑战。Kim等^[27]和Khaleghi等^[10]分别在概率学习和自放电预测方面提出了新方法。Kim等^[14]提出的时空多模态注意力网络进一步提升了预测性能。

尽管研究取得了一些进展,但机械滥用条件下对多模态最高温度的预测仍存在不足:①多数研究聚焦单一模态特征,缺乏对机械、热、电等多源信息的协同建模;②现有融合方法多采用简单拼接或加权平均,未能充分挖掘模态间的复杂交互关系;③物理约束的融入程度有限,模型可解释性有待提升;④针对机械滥用场景的实证数据较为匮乏。

针对上述问题,本文提出基于多模态神经网络的机械滥用最高温度预测方法,融合热、力、电等多源特征,提升了预测精度与工程适用性。创新点包括:设计多模态特征提取与交互结构,结合多尺度卷积和长短期记忆网络捕捉短期动态;引入Transformer融合机制和模态注意力调节器,实现异构信息协同建模;构建物理约束损失函数,纳入温度变化率等物理先验;基于200组实验数据开展多场景验证,结果表明所提方法在预测精度、稳定性和泛化能力方面均优于现有模型,能为电池热管理与安全预警提供技术支撑。

1 锂电池机械滥用实验研究

本文选用德安达公司生产的NCR18650型圆柱形锂离子电池作为研究对象,其额定容量为1 200 mA·h。该电池的规格为标准18650型,直径为18 mm,高度为65 mm。正极材料为镍钴锂酸锂

(LiNiCoO_2), 负极材料为石墨, 隔膜为聚乙烯 (PE) 与聚丙烯 (PP) 多层复合材料。电池的放电截止电压为 2.75 V, 充电截止电压为 4.20 V。

实验装置如图 1 所示, 包含电池测试系统、电子万能试验机、彩色无纸记录仪、热成像仪和计算机。




图 1 电池机械滥用测试装置

Fig. 1 Test device of battery mechanical abuse

电池经测试系统进行充、放电预处理, 荷电状态 (SOC) 分别为 10%、30%、50%、70% 和 90%。充电采用恒流恒压 (CC-CV) 模式, 以 0.5C 恒流充电至 4.20 V, 再以 4.20 V 恒压充电至电流降为 0.05C; 放电采用 0.5C 恒流进行至电压为 2.75 V 截止。每次充、放电后, 将电池静置 30 min 以达到化学平衡。将上述过程循环进行 5 次, 以激活电池。预处理完成后, 将电池充电至目标 SOC, 并静置 30 min 以达到热平衡。

采用配备 100 kN 量程压力传感器的电子万能试验机, 在室温 25 °C 环境下开展机械滥用实验。测试采用半径分别为 2.5、5.0、7.5 mm 的 3 种圆柱形压头, 加载速度为 10 mm/min, 压痕位置距电池负极为 30 mm, 压入深度为 13 mm。采用彩色无纸记录仪测量电压, 采用距离电池 1 m 的热成像仪测量表面温度。

在不同压头半径下对 SOC 为 50% 的锂电池开展局部压痕实验, 载荷、电压和电池表面温度的变化如图 2 所示。由图可见, 压入初期载荷近似线性上升, 对应弹性变形; 随着深度增加, 载荷快速升至峰值后因内部结构塌陷而下降, 随后再次上升, 整个过程表现为典型的结构破坏-载荷回弹双阶段响应机制。




图 2 不同压头半径下载荷、电压和电池表面温度的变化
Fig. 2 Variation of load, voltage and battery surface temperature under different indenter radii

由图 2 可见, 压头半径为 2.5、5.0、7.5 mm 时, 对应的最大载荷分别为 3.87、4.54、5.31 kN, 这主要源于接触面积扩大, 变形所需的机械能提高。载荷达到峰值后, 电池进入结构破坏阶段, 电压先短暂波动然后迅速跌至 0, 表明正、负极接触引发短路, 瞬时大电流在内部产生大量热, 触发电解液分解和隔膜熔融等副反应, 形成热-电-化学耦合的正反馈链, 最终导致热失控。同时, 电压突降现象随着压头半径的增大而延后, 即小半径压头在浅压入时便可诱发短路, 而大半径压头需更深压入才能达到同样效果。这是由于小尺寸压头应力集中, 更易造成隔膜穿透失效。值得注意的是, 压头半径为 5.0 mm 时对应的电压曲线在 130~150 s 出现回升, 系局部隔膜破损引发瞬时短路后, 在载荷释放和卷芯回弹作用下, 部分短路路径暂时被阻断, 内阻上升、电流减小所致。随后, 随着温度升高与材料劣化, 新短路路径形成, 导致电压再次下降。

图 3~图 5 展示了不同 SOC 和压头半径 (2.5、5.0、7.5 mm) 下, 载荷、电压和电池表面温度的变化。图 3 给出了载荷-变形曲线, $F_{\max}$ 为最大载荷。由图可见, 最大载荷随着 SOC 升高显著增大, 压头半径为 5.0 mm 时, SOC 为 90% 下的载荷较 10% 时提高了约 25.19%。不同压头半径下的曲线趋势相同, 且半径越大载荷越高, 其原因在于 SOC 升高时, 锂嵌入负极孔隙使颗粒层更致密, 从而增强了抗压能力。低 SOC 电池在失效后仍保持一定结构完整性, 而对于高 SOC 电池, 载荷则会快速下降, 表明其伴随着更剧烈的反应和破坏。

图 4 给出了电压-时间曲线。从中可以看出, 不同压头半径下, 电压均呈现类似的下降趋势。SOC 越高, 短路触发时间越短; 压头半径由 2.5 mm 增至

7.5 mm 时,触发时间略延后,表明高 SOC 电池在外力作用下更易发生内短路。

图 5 为电池表面温度-时间曲线。由图可见,温度变化与压头尺寸关系不大。SOC 为 10%~50%

时温度上升缓慢,而 70% 和 90% 时则迅速升至约 400 °C。不同 SOC 下的最高温度相近,表明高 SOC 虽能加速热失控触发并加剧反应强度,但由于热失控属自催化放热过程,导致释放热量最终趋于饱和。




图 3 不同 SOC 和压头半径时的载荷对比

Fig. 3 Comparison of load under different SOC levels and indenter radii




图 4 不同 SOC 和压头半径时的电压对比

Fig. 4 Comparison of voltage under different SOC levels and indenter radii




图 5 不同 SOC 和压头半径时的电池表面温度对比

Fig. 5 Comparison of battery surface temperature under different SOC levels and indenter radii

上述实验结果表明,18650 锂离子电池机械滥用下的极限载荷、短路触发时间和温升速率与电池 SOC 密切相关,且在不同压头尺寸下呈现相似的规

律性。随着 SOC 增加,电池最大载荷增大,但高 SOC 电池更容易发生内部短路,温度上升速度更快。当压头半径从 2.5 mm 增至 7.5 mm 时,最大载荷显

著增大,短路触发时间略有延长,但温度峰值变化不大,表明了 SOC 的主导作用和压头尺寸的调节效应。

2 多模态温度预测算法

多模态融合模型旨在整合热成像和数值模态(电压、SOC、载荷、变形等)的异构信息,通过跨模态交互生成统一的特征表示,用于预测未来多步的最高温度。该模型由图像编码器、数值编码器和模态融合 3 个模块组成。

2.1 图像编码器

图像编码器用于处理热成像序列,提取其空间

与时间特征,为多模态融合和温度预测提供高质量输入。其模块结构如图 6 所示。图中, Z_{img} 、 Z_{num} 分别为输出热成像特征和数值模态特征; x 为输入特征序列, $x_0, x_1, x_2, \dots, x_n$ 分别对应各个时间步的输入特征; y 为输出特征序列, $y_0, y_1, y_2, \dots, y_n$ 分别对应各个时间步的输出特征; n 为序列的时间步索引上限,实际序列长度为 $n+1$ 。该模块采用多尺度卷积结构,通过不同尺寸卷积核提取多层次空间特征,增强模型对复杂温度分布的感知能力。卷积后结合批归一化与线性整流激活函数(ReLU),提升特征表达的稳定性。




图6 图像编码器模块结构

Fig. 6 Structure of the image encoder module

为突出高温相关区域,引入卷积块注意力机制(CBAM),将通道注意力与空间注意力相融合。其中,前者强化温度敏感通道,后者聚焦显著区域,有效抑制无关信息,增强对高温区域的关注。在提取空间特征后,模块进一步引入双向长短期记忆网络(Bi-LSTM)建模时间序列,捕捉温度上升趋势和动态变化。该序列特别适用于极端工况下的时序预测。

整体上,图像编码器将多尺度卷积、CBAM 和

Bi-LSTM 相结合,构建兼具空间感知与时序建模能力的特征提取框架,为后续多模态融合与高温预测奠定坚实基础。

2.2 数值编码器

数值编码器用于处理电压、SOC、载荷和变形等时间序列数据,提取关键的局部动态模式和长期趋势特征。模块结合一维卷积神经网络(1D-CNN)与 Bi-LSTM 网络,对每种数值模态独立建模。1D-

CNN 用于提取短期局部特征,识别电压突变、载谐波波动等快速变化模式;Bi-LSTM 用于建模长期依赖,捕捉 SOC 缓变、电压衰减、变形累积等趋势。

2.3 模态融合模块

模态融合模块旨在将热成像、电压、SOC、载荷和变形等多种模态的特征有效整合,生成统一的高质量表示,用于预测锂电池在机械滥用条件下未来多个时间步的最高温度。其结构如图7所示。

模态融合模块充分挖掘各模态间的互补性和相关性,提升了模型对温度演化物理机制的理解能力,增强了预测的准确性与鲁棒性。在此场景下,虽然各模态特征来源不同,但在热失控过程中往往呈现出高度耦合的演化关系。为了对这些跨模态关联进行建模,模态融合模块主要包括以下3个关键步骤。

步骤1 跨模态特征交互。采用 Transformer 中的注意力机制,对不同模态间的相互依赖关系进行建模。跨模态注意力机制的计算式写为

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (1)$$

式中: $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别为查询向量、键向量和值向量,来自不同模态的线性映射; $\text{softmax}()$ 为归一化指数函

数; d_k 为键向量的维度。

步骤2 动态模态权重分配。通过一个浅层神经网络自动为每个模态分配重要性权重,反映其在当前工况下对温度预测的贡献。融合前的5个模态特征分别为 $\mathbf{Z}_1, \mathbf{Z}_2, \mathbf{Z}_3, \mathbf{Z}_4, \mathbf{Z}_5$, 则动态权重表达式写为

$$w_i = \frac{\exp(\varphi(\mathbf{Z}_i))}{\sum_{j=1}^5 \exp(\varphi(\mathbf{Z}_j))} \quad (2)$$

式中: w_i 为第 i 个模态的权重,可通过 softmax 函数归一化,保证总和为1; $\varphi()$ 为可训练的打分函数。

步骤3 特征融合与预测。基于计算得到的动态权重,对所有模态特征进行加权融合,生成统一的模态特征表示

$$\mathbf{Z}_{\text{fusion}} = \sum_{i=1}^5 w_i \mathbf{Z}_i \quad (3)$$

通过多层感知机(MLP)将融合后的特征映射到预测空间,输出未来 T_{pred} 步的最高温度

$$\hat{\mathbf{T}} = \text{MLP}(\mathbf{Z}_{\text{fusion}}) \in \mathbf{R}^{T_{\text{pred}}} \quad (4)$$

模态融合模块通过跨模态注意力机制建模模态间关系,利用动态权重调节不同模态的重要性,并生成统一的特征表示,最终用于多步最高温度预测。




图7 模态融合模块结构

Fig. 7 Structure of the modality fusion module

2.4 损失函数

通过综合误差度量与物理规律约束,设计损失函数和约束机制,引导模型实现高精度且合理的温度预测。本文构建的综合损失函数,能够结合均方误差、平均绝对误差和物理约束项,在预测精度、鲁棒性与物理合理性之间实现平衡。

综合损失函数具体定义如下

$$L_{\text{total}} = w_{\text{MSE}} L_{\text{MSE}} + w_{\text{MAE}} L_{\text{MAE}} + w_{\text{phy}} L_{\text{phy}} \quad (5)$$

$$L_{\text{MSE}} = \frac{1}{BT_{\text{pred}}} \sum_{i=1}^B \sum_{t=1}^{T_{\text{pred}}} (y_{i,t} - y_{\text{true},i,t})^2 \quad (6)$$

$$L_{\text{MAE}} = \frac{1}{BT_{\text{pred}}} \sum_{i=1}^B \sum_{t=1}^{T_{\text{pred}}} |y_{i,t} - y_{\text{true},i,t}| \quad (7)$$

$$L_{\text{phy}} = \frac{1}{B(T_{\text{pred}} - 1)} \sum_{i=1}^B \sum_{t=1}^{T_{\text{pred}}-1} \text{ReLU}(|y_{i,t+1} - y_{i,t}| - \Delta T_{\text{max}}) \quad (8)$$

式中: L_{MSE} 、 L_{MAE} 、 L_{phy} 分别为均方误差损失函数、平均绝对误差损失函数和物理约束损失函数; w_{MSE} 、 w_{MAE} 和 w_{phy} 分别为各函数的权重; $y_{i,t}$ 、 $y_{\text{true},i,t}$ 分别为模型的预测值和真实值; B 为批次; T_{pred} 为预测步数; t 为时间步索引; ΔT_{max} 为最大允许温度变化量。

在权重分配上,均方误差占主导地位,引导模型准确逼近真实值;平均绝对误差对异常值更具鲁棒性,适应复杂工况;物理约束项通过 $\text{ReLU}(|y_{i,t+1} - y_{i,t}| - \Delta T_{\text{max}})$ 限制相邻时间步之间的温度变化,当预测温度变化超过阈值 ΔT_{max} 时,约束项输出为正并在损失中施加惩罚,这样不仅确保了预测结果的物理可解释性,还提升了模型在极端工况下的稳定性,有效避免不符合热传导规律的预测结果。

3 多模态预测结果与分析

3.1 数据处理

本文数据源包含电池的热成像图、电压、SOC、载荷和变形数据信息,具体如表 1 所示。

在模型训练前,先对原始热图像进行预处理操作,将其转换为灰度图并统一调整为 300×100 像素,再采用线性映射将灰度像素强度转换为温度。采用索贝尔算子计算温度分布在 x 、 y 方向的梯度,与温度共同构成三通道特征图。同时,对电压、SOC、载荷和变形等数值序列进行标准化处理,序列

长度统一设置为 40。

表 1 数据源模态维度特征

Table 1 Data source modality dimensional feature

模态类型	维度
热成像图(时间序列帧)	$40 \times 300 \times 100 \times 3$
工作电压	40×1
SOC	40×1
载荷	40×1
变形	40×1

3.2 模型实验参数设置

采用 200 个实验组构成的数据集,按照 9 : 1 的比例随机划分为训练验证集和测试集,其中训练验证集进一步按 8 : 2 的比例划分为训练集和验证集。采用 PyTorch 1.13 深度学习框架,在配备 NVIDIA RTX 3090 GPU(24 GB 显存)和 Ubuntu 20.04 操作系统的计算机上对多模态融合模型进行训练。

图像编码器采用多尺度卷积结构,卷积核尺寸为 $3 \times 5 \times 7$,通道数依次为 16、32、64,结合 CBAM 并配置 Bi-LSTM 网络,隐藏单元数为 128,丢弃率为 0.3。数值编码器采用 1D-CNN 结构,卷积核尺寸为 3,通道数为 16、32,同样配置 Bi-LSTM 网络,隐藏单元数为 64,丢弃率为 0.3。模态融合模块基于 Transformer 架构,嵌入维度为 256,注意力头数为 8,网络层数为 4,融合层输出维度为 5,丢弃率为 0.3。

模型训练采用批次大小为 8 的自适应矩估计优化器,初始学习率为 1×10^{-4} ,采用余弦退火学习率调整策略。损失函数权重 w_{MSE} 、 w_{MAE} 、 w_{phy} 分别为 0.5、0.3 和 0.2,训练轮数为 100,输入时间步长度为 40,预测步数为 15,梯度裁剪阈值为 1。采用混合精度计算优化显存使用,设置早停策略,耐心值为 10,最小改进阈值为 0.001。采用均方误差 E_{MSE} 、平均绝对误差 E_{MAE} 、均方根误差 E_{RMSE} 和决定系数 R^2 这 4 项指标,对模型性能进行评估。

3.3 预测结果和分析

为全面验证本文所提模型的预测性能,分别进行了超前 1 步、3 步、6 步、9 步、12 步和 15 步的最高温度预测实验。压头半径为 5 mm 时,电池 SOC 为 30%、70% 下的机械滥用实验数据分别如图 8 和图 9 所示。图中,真实值与预测值的对比清晰地呈现出模型在不同预测步长下的性能表现。




图8 SOC为30%时不同预测步数的温度预测结果对比

Fig. 8 Comparison of temperature prediction results for different prediction steps when SOC is 30%




图9 SOC为70%时不同预测步数的温度预测结果对比

Fig. 9 Comparison of temperature prediction results for different prediction steps when SOC is 70%

由图 8 可见,在温度升高初期,所有预测步数的预测值与真实值均存在一定程度偏差,且随着预测步数的增加逐渐增大。在温度快速上升阶段,模型呈现出明显的分层预测特性:短期预测(1~3 步)几乎完美,预测值与真实值高度重合;中期预测(6~9 步)能够较好地跟踪真实温度的变化轨迹;长期预测(12~15 步)的预测值相较于真实值出现轻微滞后,但整体趋势较为准确。

从图 9 可见,1 步预测的精度较高,能够精确捕捉电池在 8~15 s 内的急剧温升过程,此时电池温度从 25℃ 迅速上升至 350℃ 左右。随着预测步长增加到 3 步和 6 步,预测精度开始略微下降,在温度快速上升阶段,预测曲线出现轻微滞后。当预测步长依次增加至 9、12、15 步时,预测难度显著增加,但仍能识别出温度上升的基本趋势。

上述对比分析表明,高 SOC 电池的温度突变给预测模型带来巨大挑战,急剧的温度跳跃和非线性变化使得长期预测变得困难;低 SOC 电池的平缓变化为预测模型提供了理想的条件,即使是长期预测也能保持较高精度。这种差异源于高 SOC 下电池储能密度大,电极材料活性高,机械滥用时容易引发大量副反应,产生大量热;而低 SOC 下可用能量相对较少,电化学活性较低,热生成速率缓慢且可控。

表 2 展示了不同超前预测步数下的 4 项误差评估指标对比,用于全面评估锂离子电池机械滥用条件下温度预测模型的性能。

表 2 不同预测步数下的误差评估指标
Table 2 Error evaluation metrics under different prediction steps

超前预测 步数	$E_{MAE}/^{\circ}\text{C}$	$E_{MSE}/^{\circ}\text{C}$	$E_{RMSE}/^{\circ}\text{C}$	R^2
1	1.79	34.76	5.89	0.990
3	2.35	112.68	10.61	0.972
6	3.30	230.09	15.16	0.949
9	4.00	324.83	18.02	0.936
12	4.60	404.49	20.11	0.927
15	5.38	485.42	22.03	0.918

由表 2 可知,在短期预测(1~3 步)中,模型表现出较高的预测精度, E_{MAE} 和 E_{RMSE} 均维持在较低水平, R^2 介于 0.972~0.990 之间,表明模型能够准确预测电池的最高温度。随着预测步长延伸至中长期(6~9 步)和长期(12~15 步), E_{RMSE} 的增长幅度明显大于 E_{MAE} ,表明预测误差分布中存在个别较大

偏差,此时 R^2 仍保持在 0.900 以上,表明模型在长期预测中仍具备可靠的温度预测能力。

为全面验证模型在不同 SOC 下的预测性能,对电池 SOC 为 10%~90% 范围内的锂离子电池进行了系统的温度预测验证实验。统计分析结果表明,在上述 SOC 范围内,15 步时预测的 E_{MAE} 保持在 5.38℃ 以内, E_{RMSE} 小于 22.03℃, R^2 高于 0.900,显示出优异的预测精度。通过分析发现,模型预测精度随着 SOC 变化呈现一定规律:在中、低 SOC (10%~60%) 区间,由于电池温度变化相对平缓,模型在短期及长期预测中均能保持高精度,并能准确捕捉温度变化趋势;在高 SOC (70%~90%) 区间,受储能密度增大和热失控风险上升的影响,温度突变发生频率提高,使得长期预测面临更大挑战,但在短中期预测(1~9 步)中仍能保持较高的可靠性。

综上,所提模型在 10%~90% SOC 范围内均表现出良好的预测精度与适应性,短期预测精度最高;尽管高 SOC 条件下长期预测的难度增加,但模型仍能有效捕捉整体趋势及关键温度变化,体现出较强的普适性和工程应用价值。上述性能变化主要归因于机械滥用条件下热失控行为的随机性、多物理场耦合过程的强非线性以及长期预测中的误差累积效应,尤其是在高 SOC 状态下,储能密度大、电极材料活性高等因素使得温度突变成为长期预测的主要挑战。总体而言,在 1~15 步预测范围内,所提模型的性能表现优异,具有较高的实际应用潜力。

4 结 论

针对锂离子电池在机械滥用条件下热失控预测精度低的问题,提出了一种基于多模态神经网络的温度预测模型,融合热成像、电压、变形与载荷等多源数据,通过跨模态特征交互提升了模型的预测性能。通过理论分析与实验验证,得到以下主要结论。

(1)所构建的多模态神经网络温度预测模型在全时间步长范围内均表现出优异性能,其中短期预测(1~3 步)的 R^2 达到了 0.972~0.990,中长期(6~9 步)和长期预测(12~15 步)的 R^2 均保持在 0.900 以上,验证了模型从短期监控到长期预警的全面适用性。

(2)模型在电池 SOC 为 10%~90% 范围内表现出良好的适应性与鲁棒性。其中,预测 15 步时的 E_{MAE} 保持在 5.38℃ 以内, E_{RMSE} 小于 22.03℃, R^2 高于 0.900,表明中、低 SOC 区间预测精度较高;而高 SOC 区间虽面临温度突变挑战,但短、中期预测仍

能保持一定的可靠性。

综上所述,本文所构建的多模态融合架构可有效应对热失控过程中的强非线性与长期预测误差累积问题,能够准确捕捉温度变化趋势和关键突变,体现出较强的普适性与工程应用价值。

参考文献:

- [1] ZHANG Xi, CHEN Shun, ZHU Jingzhe, et al. A critical review of thermal runaway prediction and early-warning methods for lithium-ion batteries [J]. *Energy Material Advances*, 2023, 4: 0008.
- [2] ZHOU Yuxin, DING Yifei, CHEN Yuying, et al. Thermal degradation of lithium-ion battery cathodes: a machine learning prediction of stability and safety [J]. *Energy Materials*, 2025, 5: 500077.
- [3] WANG Zilong, SADEGHI H, HUANG Xinyan, et al. Thermal runaway and flame propagation in battery packs: numerical simulation and deep learning prediction [J]. *Engineering Applications of Computational Fluid Mechanics*, 2025, 19(1): 2445160.
- [4] WANG Gongquan, PING Ping, KONG Depeng, et al. Advances and challenges in thermal runaway modeling of lithium-ion batteries [J]. *The Innovation*, 2024, 5(4): 100624.
- [5] AZUAJE-BERBECÍ B J, ERTAN H B. A model for the prediction of thermal runaway in lithium-ion batteries [J]. *Journal of Energy Storage*, 2024, 90(Part A): 111831.
- [6] 朱振威, 苗嘉伟, 祝夏雨, 等. 基于机器学习方法的锂电池剩余寿命预测研究进展 [J]. *储能科学与技术*, 2024, 13(9): 3134-3149.
ZHU Zhenwei, MIAO Jiawei, ZHU Xiayu, et al. Research progress in lithium-ion battery remaining useful life prediction based on machine learning [J]. *Energy Storage Science and Technology*, 2024, 13(9): 3134-3149.
- [7] 张世超, 沈泽宇, 陆盈盈. 金属锂电池的热失控与安全性研究进展 [J]. *物理化学学报*, 2021, 37(1): 55-72.
ZHANG Shichao, SHEN Zeyu, LU Yingying. Research progress of thermal runaway and safety for lithium metal batteries [J]. *Acta Physico-Chimica Sinica*, 2021, 37(1): 55-72.
- [8] FENG Xuning, REN Dongsheng, HE Xiangming, et al. Mitigating thermal runaway of lithium-ion batteries [J]. *Joule*, 2020, 4(4): 743-770.
- [9] THELEN A, HUAN Xun, PAULSON N, et al. Probabilistic machine learning for battery health diagnostics and prognostics: review and perspectives [J]. *npj Materials Sustainability*, 2024, 2(1): 14.
- [10] KHALEGHI S, HOSEN M S, KARIMI D, et al. Developing an online data-driven approach for prognostics and health management of lithium-ion batteries [J]. *Applied Energy*, 2022, 308: 118348.
- [11] WANG Fujin, ZHAI Zhi, ZHAO Zhibin, et al. Physics-informed neural network for lithium-ion battery degradation stable modeling and prognosis [J]. *Nature Communications*, 2024, 15(1): 4332.
- [12] LIU Hongao, LI Chang, HU Xiaosong, et al. Multi-modal framework for battery state of health evaluation using open-source electric vehicle data [J]. *Nature Communications*, 2025, 16(1): 1137.
- [13] SUH S, MITTAL D A, BELLO H, et al. Remaining useful life prediction of lithium-ion batteries using spatio-temporal multimodal attention networks [J]. *Helvion*, 2024, 10(16): e36236.
- [14] KIM S W, KWAK E, KIM J H, et al. Modeling and prediction of lithium-ion battery thermal runaway via multiphysics-informed neural network [J]. *Journal of Energy Storage*, 2023, 60: 106654.
- [15] JEONG J, KWAK E, KIM J H, et al. Prediction of thermal runaway for a lithium-ion battery through multiphysics-informed DeepONet with virtual data [J]. *eTransportation*, 2024, 21: 100337.
- [16] DAS GOSWAMI B R, ABDISOBOUHI Y, DU Hui, et al. Advancing battery safety: integrating multiphysics and machine learning for thermal runaway prediction in lithium-ion battery module [J]. *Journal of Power Sources*, 2024, 614: 235015.
- [17] CHAI Zhixiong, LI Junqiu, LIU Ziming, et al. Experimental analysis and safety assessment of thermal runaway behavior in lithium iron phosphate batteries under mechanical abuse [J]. *Scientific Reports*, 2024, 14(1): 8673.
- [18] KONG Jinzhen, LIU Jie, ZHU Jingzhe, et al. Review on lithium-ion battery PHM from the perspective of key PHM steps [J]. *Chinese Journal of Mechanical Engineering*, 2024, 37(1): 71.
- [19] XIONG Rui, WANG Ju, SHEN Weixiang, et al. Co-estimation of state of charge and capacity for lithium-ion batteries with multi-stage model fusion method [J]. *Engineering*, 2021, 7(10): 1469-1482.
- [20] DING Shuya, DONG Chaoyu, ZHAO Tianyang, et al. A meta-learning based multimodal neural network for multistep ahead battery thermal runaway forecasting [J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(7): 4503-4511.
- [21] LANUBILE A, BOSONI P, POZZATO G, et al. Do-

- main knowledge-guided machine learning framework for state of health estimation in lithium-ion batteries [J]. Communications Engineering, 2024, 3(1): 168.
- [22] IFTIKHAR M, SHOAB M, ALTAF A, et al. A deep learning approach to optimize remaining useful life prediction for li-ion batteries [J]. Scientific Reports, 2024, 14(1): 25838.
- [23] LI Jie, ZHANG Yunlong, YUAN Boxing, et al. A data-driven thermal runaway warning method for lithium-ion batteries under mechanical abuse [J]. IEEE Transactions on Transportation Electrification, 2025, 11(2): 5169-5179.
- [24] PAN Zhexin, SEDLATSCHKE T, XIA Yong. Effect of state-of-charge and air exposure on tensile mechanical properties of lithium-ion battery electrodes [J]. Journal of the Electrochemical Society, 2020, 167(9): 090517.
- [25] CORTADA-TORBELLINO M, ELVIRA D G, EL AROUDI A, et al. Review of lithium-ion battery internal changes due to mechanical loading [J]. Batteries, 2024, 10(7): 258.
- [26] VALIZADEH A, AMIRHOSSEINI M H. Machine learning in lithium-ion battery: applications, challenges, and future trends [J]. SN Computer Science, 2024, 5(6): 717.
- [27] KIM H, JUNG T, JUNG J, et al. Accurate prediction of electrochemical degradation trajectory for lithium-ion battery using self-discharge [J]. International Journal of Energy Research, 2024, 2024(1): 1758578.
- (编辑 李慧敏)