

基于 LSTM-BP 平均池化的动力电池温度预测

张 浩^{1,2} 林华艳^{1,2*}

ZHANG Hao LIN Huayan

摘 要

为实现新能源汽车动力电池温度预测, 文章提出一种 LSTM-BP-Average pooling 模型。该模型采用双层 LSTM 网络捕获温度演化的长期时序依赖关系, 通过平均池化机制对全时间步隐藏状态进行全局融合, 再经浅层 BP 神经网络非线性映射, 实现动力电池温度预测。结果表明, 该模型预测精度显著优于传统 BP 和单一 LSTM 以及 LSTM-BP 模型, 并在不同数据集泛化测试中 R^2 均保持在 0.98 以上, 证明了该模型优秀的温度预测能力和泛化能力。

关键词

LSTM-BP; 平均池化; 动力电池; 温度预测

doi: 10.3969/j.issn.1672-9528.2026.07.039

0 引言

随着新能源汽车产业的快速发展, 动力电池作为核心动力源, 温度管理是保证动力电池平安和高效使用的关键^[1]。电池在真实行驶工况下, 受电流、电压及车速等因素影响, 热产生与散热过程呈现强非线性、时变性和长时序依赖特性, 若能准确预测电池组实时工作温度, 则可有效避免新能源汽车热失控问题。因此, 有效的动力电池温度预测模型有利于提高电池热管理系统监控及控制的精度^[2]。动力电池热过程是典型分布参数系统, 传统物理机理建模依赖偏微分方程的解析与数值求解, 在缺乏完整过程信息、难以确定精确方程时适用性受限, 数据驱动方法则可避开精确物理方程依赖实现温度预测, 已成为该领域主流研究方向^[3]。

误差反向传播 (back propagation, BP) 神经网络可被应用于锂电池热管理中的温度预测任务^[4]。传统 BP 神经网络存在训练结果偏差大、模型稳定性不足、对训练样本依赖性强^[5-6]的问题, 现有基于 BP 模型训练的神经网络在动力电池温度预测中误差较高, BP 不适配电池数据的时间序列特性, 导致其预测精度与鲁棒性不足^[7]。时序建模机制能有效弥补这一缺陷, 通过捕捉历史序列中的依赖关系提升模型在复杂工况, 以提升长期依赖捕捉能力。

长短期记忆网络 (long short-term memory, LSTM) 通过门控机制有效捕捉时序数据中的长期依赖^[8], 可应用于动力电池温度预测任务^[9-10]。LSTM-BP 属于 LSTM 相关模型, 对数据噪声敏感, 泛化能力受数据质量影响显著^[11]。因此, 本研究提出动力电池温度预测模型 LSTM-BP-Average pooling

实现温度预测。通过与 BP、LSTM 及多种 LSTM-BP 变体对比, 验证所提方法在真实行驶工况下的有效性和泛化性, 旨在为电车动力电池热管理提供可靠的预测技术支撑。

1 数据分析与模型搭建

1.1 三元锂离子电池行驶状态实验数据

本研究所用数据来源于智能汽车安全技术国家重点实验室开源的真实环境下实车运行三元锂离子电池数据集^[12]。该数据集记录纯电动乘用车在城市道路、郊区及高速等多种工况下的完整行驶过程, 采样周期 10 s, 研究对象为 vin1 数据集, 清洗后得到 1 456 525 条有效放电记录。

为确保模型输入的物理意义与时序连续性, 设计仅保留 $\text{speed} > 0 \text{ km} \cdot \text{h}^{-1}$ 且 $\text{totalcurrent} > 2 \text{ A}$ 的数据点, 时间戳差值 $> 60 \text{ s}$ 视为停车或丢帧, 切分为独立片段, 保留长度 $\geq 10 \text{ min}$ 的片段。最终将数据按时间顺序划分为 6 份, 第 1 份数据集 ablation 用作消融实验, 其余 5 份数据集用于检验模型泛化能力。按 6:2:2 的比例将数据划分为训练集、验证集和测试集。实验环境如表 1 所示。

表 1 实验环境配置

配置项	参数
CPU	Intel Core i9-14900KF
GPU	GeForce RTX 3090
内存	32 GB
内存规格	DDR4
编程语言	Python 3.10
深度学习框架	PyTorch 2.9.0
CUDA	12.6

原始温度字段存在空值与格式异常, 因此设计鲁棒温度特征提取算法, 优先解析探针序列, 异常时回退使用均值估算。

1. 重庆移通学院 重庆 401420

2. 公共大数据安全技术重点实验室 重庆 401420

为识别与电池温度相关特征变量，采用互信息（mutual information, MI）和随机森林特征重要性（random forest, RF）相结合的特征筛选方法，图 1 为 0-1 标准化后相关性热力图。




图 1 相关性热力图

为验证特征相关性得到模型的输入维度，本研究在互信息基础上使用随机森林方法评估不同特征对温度预测的贡献度，结果如表 2 所示。综合 MI 和 RF 指标，speed、 $V_{\min}$ 和 I_i 在两种评估方法中均表现出较高相关性，因此，选取特征 I_i 、 $V_{\min}$ 、speed 作为模型输入。

表 2 MI、RF 相关性分析

特 征	MI	RF
speed	0.158	0.751
$V_{\min}$	0.052	0.094
I_i	0.011	0.054
$V_{\max}$	0.053	0.040
soc	0.095	0.034
V_i	0.052	0.027

1.2 模型搭建

采用 Z-score 标准化方法，对原始数据进行标准化处理，将输入特征转换为零均值和单位方差，用于消除量纲差异，加速模型训练收敛，计算公式为：

$$y_i = \frac{x_i - \bar{x}}{s} \tag{1}$$

式中： $\bar{x}$ 和 s 分别表示整个数据集的全局均值和标准差。

为保持时间序列的连续性，将数据划分为固定长度的重叠窗口，每个窗口作为一个训练样本。设定时间步长为 $T=60$ ，则第 i 个样本的输入序列为：

$$X_i = [x_i, x_{i+1}, \dots, x_{i+T-1}] \tag{2}$$

对应的输出标签为第 $T+1$ 个时刻的温度值 y_{i+T} ，通过滑动窗口机制，构建出包含时序依赖关系的训练数据集。本研

究采用双层 LSTM 结构，其核心计算过程为：

使用遗忘门 f_t 控制前一时刻细胞状态保留程度：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{3}$$

使用输入门 i_t 决定当前输入信息的更新程度：

$$i_t = \tanh(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{4}$$

使用 $\tilde{C}_t$ 和 C_t 决定候选细胞状态和细胞更新状态：

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \tag{5}$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \tag{6}$$

式中： σ 为 Sigmoid 激活函数， $\tanh$ 为双曲正切激活函数， W 、 b 分别为权重矩阵和偏置向量， h_t 为隐藏状态。

输出门控制细胞状态输出到隐藏层的信息量：

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{7}$$

$$h_t = o_t \odot \tanh(C_t) \tag{8}$$

为增强模型对关键时间步特征的关注能力，本研究引入注意力机制对传统的最后时间步提取方式进行替代。上下文向量通过加权求和获得。LSTM 层输出的上下文向量经过浅层 BP 神经网络进行非线性映射。为避免过拟合和梯度消失问题，本研究设计包含两层的浅层 BP 网络结构：

$$z_1 = \text{ReLU}(W_1 \cdot c + b_1) \tag{9}$$

$$z_2 = \text{Dropout}(z_1, p = 0.05) \tag{10}$$

$$\hat{y} = W_2 \cdot z_2 + b_2 \tag{11}$$

式中： W_1 、 W_2 为全连接层权重矩阵， b_1 、 b_2 为偏置向量，ReLU 为修正线性单元激活函数，Dropout 为随机失活层，失活概率 $p = 0.05$ ， $\hat{y}$ 为模型最终预测输出。

为缓解深度网络训练过程中的退化问题，引入残差连接机制，将 LSTM 上下文向量通过线性投影后与 BP 网络输出相加，优化器采用 Adam 算法。为防止梯度爆炸，对梯度范数进行裁剪，引入早停策略防止过拟合。若验证集损失在连续 20 轮内未降低，则提前终止训练并恢复最佳模型参数。LSTM-BP-Average Pooling 模型整体流程如图 2 所示，训练过程采用早停机制，评价指标为均方误差 MSE、平均绝对误差 MAE 和决定系数 R^2 。

2 实验结果与分析

2.1 不同模型效果对比

为系统评估 LSTM-BP 模型中各关键模块的贡献，本研究设计多组消融实验。构建了 BP 神经网络和 LSTM 网络作为基准模型，用以验证时序建模和深度融合架构的必要性。三种模型均采用相同的输入特征和时间窗口设置，并在 ablation 数据集上进行训练和测试。

图 3 展示了 BP、LSTM 和 LSTM-BP 三种模型的预测结果对比。可以看出，BP 模型的预测效果最差，散点比较分散，LSTM 模型的精度比 BP 有所提升，LSTM-BP 的预测值与真实值高度重合，散点紧密集中在对角线附近，预测性能最优。




图2 LSTM-BP-Average pooling 模型整体流程图




图3 LSTM-BP 与 BP、LSTM 预测结果对比图

表3为 LSTM-BP 与 BP、LSTM 三种模型动力电池温度预测相关误差指标情况，从表中可知传统 BP 神经网络的预测误差最大，单一的前馈神经网络难以有效捕捉温度变化的时序规律，在处理动态工况下的温度预测任务时能力不足。引入 LSTM 网络后，模型性能显著提升，体现了 LSTM 门控机制在捕获温度演化长期依赖关系方面的有效性。然而，LSTM 模型仅依赖最后时间步的隐藏状态输出，未能充分利用整个时间序列的全局信息，为进一步提升模型性能，本研

究设计了多种优化方案，包括浅层结构、注意力机制、残差连接及平均池化，性能对比如表4所示，表中展示不同优化策略的效果，对比结果表明，最优模型是 LSTM-BP-Average Pooling。

表3 模型预测误差指标统计

模型	MSE	MAE	R ²
BP	6.691 8	1.238 8	0.757 0
LSTM	1.232 8	0.502 8	0.955 2
LSTM-BP	0.128 1	0.152 5	0.995 6

表4 不同 LSTM-BP 变体的测试集预测性能对比

模型	MSE	MAE	R ²
LSTM-BP-Shallow	0.247 9	0.177 9	0.991 0
LSTM-BP-Attention	0.131 3	0.145 0	0.995 2
LSTM-BP-residual	0.123 7	0.140 1	0.995 5
LSTM-BP-Attention-residual	0.142 8	0.138 4	0.994 8
LSTM-BP-Average pooling	0.104 9	0.153 7	0.996 2

在 LSTM-BP-Average pooling 模型中，平均池化作为 LSTM 与 BP 间的特征聚合方式，通过整合所有时间步隐藏状态获取全局特征，计算公式为：

$$\mathbf{h}_{\text{pool}} = \frac{1}{T} \sum_{t=1}^T \mathbf{h}_t \quad (12)$$

式中： $\mathbf{h}_{\text{pool}}$ 为平均池化后的特征向量， T 为时间序列长度其数值为 60， $\mathbf{h}_t$ 为第 t 个时间步的 LSTM 隐藏状态。

优化器采用 Adam 算法，学习率设置为 0.000 5，并引入权重衰减系数以防止过拟合，模型参数 θ 计算公式为：

$$\theta_{t+1} = \theta_t - \eta \cdot \frac{\mathbf{m}_t}{\sqrt{\mathbf{v}_t + \epsilon}} - \lambda \cdot \theta_t \quad (13)$$

式中： η 为学习率， $\mathbf{m}_t$ 、 $\mathbf{v}_t$ 分别为梯度的一阶和二阶矩估计， ϵ 为平滑项。

池化后的特征向量输入浅层 BP 神经网络进行非线性映射，输出预测结果 $\hat{\mathbf{y}}$ 的计算公式为：

$$\hat{\mathbf{y}} = \hat{\mathbf{y}}_{\text{norm}} \cdot \sigma_y + \mu_y \quad (14)$$

式中： σ_y 、 μ_y 分别为输出目标的标准差和均值。

经过消融实验对比分析，平均池化机制避免注意力机制可能出现的过拟合风险，也无需残差连接的额外参数，实现模型性能与复杂度的最佳平衡。

2.2 LSTM-BP-Average Pooling 泛化能力评估

为评估 LSTM-BP-Average Pooling 模型的泛化能力和实用性，本研究采用交叉验证策略，在不同数据集上测试模型的预测性能。这些数据集涵盖不同的运行场景、温度范围和采样频率，能够充分检验模型对未知数据的适应能力。测试集 (a) ~ (e) 使用相同的数据预处理流程和时间窗口设置，预测值与真实值对比如图4所示。




图 4 预测结果对比图

由表 5 可知，在 5 个测试数据集中， R^2 始终保持在 0.98 以上，证明模型能够有效捕捉温度变化的主要趋势，且具有良好的泛化能力。

表 5 模型评估指标数值

数据集	MSE	MAE	R^2
ablution	0.116 7	0.152 6	0.995 8
(a)	0.221 8	0.347 6	0.985 7
(b)	0.348 9	0.403 2	0.984 6
(c)	0.197 6	0.308 0	0.985 3
(d)	0.479 4	0.508 5	0.988 3
(e)	0.588 2	0.544 2	0.989 7

综上所述，LSTM-BP-Average Pooling 模型能够在不同工况下保持高精度预测。模型无需针对每个应用场景重新训练，一次训练即可适用于多种电池管理系统，具有良好的实用价值和部署潜力，为动力电池热管理系统的智能化发展提供有效的技术支撑。

3 结论

本研究提出了一种优于传统融合 LSTM 和 BP 神经网络的电池温度预测方法 LSTM-BP-Average Pooling，利用 Z-score 标准化方法对原始数据进行预处理，消除不同特征之间的量纲差异，采用滑动窗口机制构建时间序列数据集，多维特征转换为固定长度的时序输入，设计双层 LSTM 网络提取时序特征，通过平均池化机制融合全局时间步信息，浅层 BP 神经网络进行非线性映射输出预测温度值。对模型进行量化评估，得到相关指标如下：MSE=0.104 9，MAE=0.153 7， R^2 =0.996 2，实现了对电池温度的预测。消融实验对比浅层 BP、注意力机制、残差连接、注意力+残差、平均池化五种模型变体，实验结果表明，LSTM-BP-Average Pooling 取得最优性能，验证了该模型在电池温度预测任务中的可行性与有效性。

参考文献：

[1] 陈素华,白莹. 锂离子电池动力电池热失控机理及热管理技术研究进展[J]. 中国科学基金,2023,37(2):187-198.

[2] 吕杰,王敬翰,宋文吉,等. 储能用锂离子电池电热耦合模型研究进展[J]. 电池,2023,53(6):668-672.

[3]Wang Bingchuan, Feng Yun, Wang Shuqiang. Two-phase separation based spatiotemporal modeling of thermal processes with applications to lithium-ion batteries[J]. Journal of Energy Storage, 2022, 49: 104050.

[4]AI Tahhan A, Ramadan M, Choi D S, et al. Recent advancements in Artificial Neural Network-based temperature prediction and management of lithium-ion batteries: a comprehensive review[J]. AI Thermal Fluids, 2025,4:100014.

[5]Yang Duo, Wang Yujie, Pan Rui, et al. A neural network based state-of-health estimation of lithium-ion battery in electric vehicles[J]. Energy Procedia, 2017, 105: 2059-2064.

[6]Xie Yuyang. Analysis of new energy vehicle battery temperature prediction by combining BP neural network[J/OL]. Applied Mathematics and Nonlinear Sciences,2024[2026-07-01].https://www.researchgate.net/publication/378615195_Analysis_of_new_energy_vehicle_battery_temperature_prediction_by_combining_BP_neural_network.DOI:10.2478/amns-2024-0585.

[7]Cho G. Artificial neural network methods for lithium-ion battery behavior predictions[D].Ann Arbor: University of Michigan, 2022.

[8]Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural computation, 1997, 9(8): 1735-1780.

[9]Wang Boyu, Chen Zheyang, Zhang Puhuan, et al. The lithium-ion battery temperature field prediction model based on CNN-Bi-LSTM-AM[J]. Sustainability, 2025, 17(5): 2125.

[10]Yi Yahui, Xia Chengyu, Feng Chao, et al. Digital twin-long short-term memory (LSTM) neural network based real-time temperature prediction and degradation model analysis for lithium-ion battery[J]. Journal of Energy Storage, 2023, 64: 107203.

[11]Jin Shengyuan, Hong Yan, Jin Changyong, et al. Data-driven research on battery pack temperature prediction[J]. Journal of Power Sources, 2025, 613: 237102.

[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: 1137.

【作者简介】

张浩（2005—），男，湖南长沙人，本科，研究方向：深度学习。

林华艳（1997—），通信作者（email:1633136264@qq.com），女，重庆人，硕士研究生，研究方向：深度学习。

（收稿日期：2025-11-14 修回日期：2026-07-10）