http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2025.0180

基于MTL-sLSTM的低空载具锂电池RUL预测

张慧珊[1]，沈吉英[2]，刘东升[1,*]，周志凯[3]，胡一凡[1]，徐扬波[1]

(1. 浙江工商大学 计算机科学与技术学院，杭州 310020；2. 杭州市科技信息研究院，杭州 310053；
3. 杭州数政科技有限公司，杭州 310020)

摘　　要：针对低空经济载具锂离子电池在多工况耦合下的剩余寿命（RUL）预测问题，提出一种基于多任务学习的标量长短期记忆网络（MTL-sLSTM）预测方法。该方法通过多源异构输入层融合跨飞行工况的多维度时序数据，采用层级堆叠的sLSTM结构作为共享特征提取器，实现跨时间尺度的深度特征融合与非线性退化共性特征提取；结合任务ID硬编码索引动态调整网络权重，通过多任务学习机制自适应捕捉不同工况的退化模式，同步实现跨工况知识共享与独立RUL预测。实验结果表明：MTL-sLSTM的预测性能显著优于注意力混合专家模型（AttMoE）、双通道LSTM（Dual-LSTM）等6种时序方法，在eVTOL数据集上均方根误差（RMSE）较对比方法降低60.7%～92.3%，验证了多任务学习机制在增强复杂工况下退化特征泛化能力与提升预测精度方面的有效性。

关 键 词：剩余寿命预测；多任务学习；长短期记忆网络；锂离子电池；电动垂直起降飞机；低空经济载具

中图分类号：TM912; V242.2; V241.6; V271.3

文献标志码：A　　**文章编号**：1001-5965(2026)09-3125-11

低空经济作为战略性新兴产业，依托无人机、电动垂直起降飞行器（electric vertical takeoff and landing, eVTOL）等载具在物流、救援等领域快速发展。2024年中国市场规模已超6 000亿元，预计2026年突破万亿，全球市场同步呈现指数增长。锂离子电池作为核心动力组件，其剩余使用寿命（remaining useful life, RUL）的精准预测直接影响飞行安全。美国联邦航空管理局（Federal Aviation Administration, FAA）报告指出，2018—2023年23%的电动航空器事故与电池衰退相关，容量衰减超20%的电池电压崩溃风险骤增3.7倍。

低空载具的“充电-飞行”双模态运行场景对RUL预测提出特殊需求：充电工况可通过恒流/恒温模式下的容量增量曲线等参数建模[1-3]；飞行工况则需应对动态三阶段放电（高倍率起飞/着陆与中倍率巡航），尤其是着陆阶段的高负载冲击加剧容量与内阻的耦合衰减。研究指出结合飞行中电压动态特性和温度场数据可提升预测精度[4]，但现有方法多聚焦单一工况建模，尚未建立多工况耦合预测体系。

近年来，航空动力电池RUL预测研究取得显著进展。纳米磷酸铁锂电池的航空适用性验证为电池选型奠定基础[5]，长短期记忆网络（long short-term memory, LSTM）、灰色Verhulst-神经网络等模型在小样本场景展现潜力，而卷积神经网络-长短期记忆网络-深度神经网络（convolutional neural network-long short-term memory-deep neural network multimodal network, CNN-LSTM-DNN）多模态网络虽将误差降

收稿日期：2025-04-03；录用日期：2025-04-29；网络出版时间：2025-06-04 11:09
网络出版地址：link.cnki.net/urlid/11.2625.V.20250604.0851.001
基金项目：浙江省万人计划项目 (2022R52048)；浙江省科技计划项目 (2024C01028,2024C01211)
*通信作者. E-mail：lds1118@zjgsu.edu.cn

引用格式：张慧珊，沈吉英，刘东升，等. 基于MTL-sLSTM的低空载具锂电池RUL预测 [J]. 北京航空航天大学学报，2026，52（9）：3125-3135.
Zhang H S，Shen J Y，Liu D S，et al. Remaining useful life prediction of lithium-ion batteries in low-altitude vehicles based on MTL-sLSTM[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（9）：3125-3135 （in Chinese）.

至1.8%，却因结构复杂导致训练耗时激增[6-7]。当前研究趋势转向多源信息融合与动态建模，贺宁等[8]开发的粒子滤波-门控循环单元(particle filter-gated recurrent unit, PF-GRU)混合框架，有效抑制了容量再生现象干扰。董渊昌等[9]采用奇异值分解-高斯过程回归方法构建的不确定性预测模型，其预测区间覆盖率提升至95.2%，但健康因子与多工况衰减机理的普适关联仍需深入验证。陈欣等[10]使用Transformer和GRU的联合方法提升了锂电池的剩余使用寿命预测鲁棒性。Chen等[11]基于Transformer模型，将注意力机制与混合专家(mixture of experts, MoE)相结合，相对误差方面实现了10%～20%的改进。尽管Transformer在理论上具备强大的特征捕获能力，但受限于自注意力机制的非线性建模缺陷，难以满足机载实时性需求[12]。当前研究多聚焦单一充电或飞行工况建模，尚未建立适应低空经济载具动力电池多工况耦合特性的预测体系，特别是在跨工况迁移学习与多任务协同优化领域。

迁移学习成为突破跨工况预测瓶颈的新方向。现有迁移学习方法如对抗性域适应、统计匹配[13-15]，虽能缓解数据分布偏移问题，但其依赖目标域充足的历史数据，而低空经济载具多模态飞行任务(城市物流、应急救援等)导致目标工况数据极度稀缺。相比之下，多任务学习(multi-task learning, MTL)通过共享-特异双路架构同步挖掘多工况共性特征与个性化退化规律，在有限数据条件下实现知识迁移，而传统MTL模型多采用CNN或GRU[16-18]作为主干网络，难以有效捕获电池容量衰减的长程时序依赖。

本文面向低空经济载具多工况场景，提出一种基于多任务学习的标量长短期记忆网络(multi-task learning scalar long short-term memory, MTL-sLSTM)预测方法，其主要创新点体现在三方面。

1) 多任务协同优化机制：设计多源异构输入层、共享特征提取器与多任务预测器，通过输入层融合飞行工况异构数据，共享层学习跨工况退化共性，任务特异层捕捉不同工况的独有衰减模式，解决传统单任务模型对工况敏感性问题。

2) sLSTM时序建模增强：作为共有特征提取器，承担不同飞行工况退化模式泛化表征的关键任务。通过深度可分离卷积消除锂电池不同飞行工况特异性噪声；利用层级堆叠结构逐层提取从局部退化片段到全局老化趋势的多粒度信息；建立参数共享机制迫使网络学习工况不变性特征，为目标域零样本预测提供基础。

3) 轻量化多任务预测架构：基于任务ID硬编码索引定位私有预测头参数，共享特征截取末端状态输入任务私有全连接层，实现多电池退化模式差异化建模，解决了传统多任务模型计算冗余与航空场景实时性需求的矛盾。

1 基于MTL-sLSTM的锂电池RUL预测方法

1.1 问题设定

锂离子电池广泛应用于低空经济载具中，其RUL的精准预测直接影响飞行安全[11]。现有基于实验电池测量的研究将电池容量衰减至初始额定值的70%或80%时，即判定达到寿命终止(end-of-life, EOL)阈值[19]。RUL定义为电池在EOL之前剩余的循环次数[20]，其数学表征为

$$N_{\mathrm{RUL}}^{k}=N_{\mathrm{EOL}}^{k}-N_{\mathrm{ECL}}^{k} \tag{1}$$

式中：N_{RUL}^{k}、N_{EOL}^{k}、N_{ECL}^{k}分别为任务k下的RUL、电池达到EOL时的循环次数、等效循环寿命(equivalent cycle life, ECL)。

1.2 本文方法架构

针对工况转换场景下低空经济载具锂电池的RUL预测，本文MTL-sLSTM旨在通过多源数据融合与跨工况知识共享，缓解工况偏移导致的泛化问题。图1为MTL-sLSTM框架，由多源异构输入层、共享特征提取器和多任务预测器构成。

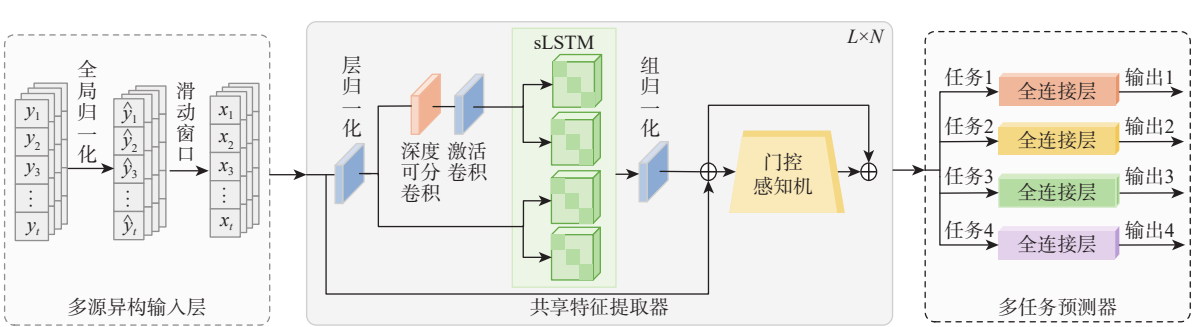

图1 MTL-sLSTM框架

Fig. 1 MTL-sLSTM framework

1.2.1　多源异构输入层

对于低空经济载具锂电池在复杂工况下的多源数据融合问题, 实现多工况数据统一表征与对齐至关重要。多工况数据统一表征能够将不同工况下的数据转化为统一的表示形式, 消除数据间的差异和不一致性。

首先, 基于锂电池的电化学过程与任务配置特征, 提取具有代表性的退化特征集合。

其次, 所有子任务数据统一进行全局对比度归一化处理(global contrast normalization, GCN), 计算式为

$$\hat{x} = (x - \mu_{\text{globle}})/\sigma_{\text{globle}} \tag{2}$$

式中: x 为原始特征值; μ_{globle} 和 σ_{globle} 分别为跨电池数据的全局均值和标准差。全局对比度归一化能够消除不同电池个体间由于制造差异、使用条件等因素导致的数据分布差异, 确保不同工况数据的分布对齐, 从而使模型在处理不同电池数据时具有更好的一致性和稳定性, 提升模型的泛化能力。

最后, 通过滑动窗口生成时序样本, 样本构造如下:

$$\boldsymbol{X}_t = [\boldsymbol{x}_{t-T+1}, \boldsymbol{x}_{t-T+2}, \cdots, \boldsymbol{x}_t] \in \mathbf{R}^{T\times s} \tag{3}$$

式中: $\boldsymbol{X}_t \in \mathbf{R}^d$ 为第 t 个循环的特征向量, d 为维度; T 为窗口长度; s 为每个时间点特征向量的维度。

滑动窗口生成时序样本的好处在于能够捕捉电池在连续循环周期内的动态变化模式, 将静态的特征数据转化为具有时间序列信息的样本, 有助于模型学习到电池性能随时间的变化规律。

1.2.2　共享特征提取器

共享特征提取器作为模型实现跨工况知识迁移的核心模块, 承担跨工况退化模式泛化表征的关键任务。针对锂电池多源异构数据中存在的工况漂移和局部退化突变问题, 本文基于 sLSTM 构建层级特征蒸馏架构, 其核心目标在于多尺度特征抽象, 利用层级堆叠结构 $L\times N$ 逐层提取从局部退化片段到全局老化趋势的多粒度信息, 并且建立参数共享机制迫使网络学习工况不变性特征, 为目标域零样本预测提供基础。

共享特征提取器由多层改进型 sLSTM 模块堆叠而成, 每层通过门控残差连接实现特征精炼, 其技术实现包含 3 个阶段:

1) 深度可分离卷积增强门控机制

深度可分离卷积将标准卷积分解为深度卷积和逐点卷积两部分, 如图 2 所示。深度卷积对每个输入通道独立进行卷积操作, 逐点卷积则使用 1×1 的卷积核在通道维度上进行线性组合, 以融合不同通道的信息。在传统 LSTM 遗忘门中引入深度可分离卷积核, 重构其预激活计算流程为

$$\tilde{\boldsymbol{f}}_t = \boldsymbol{W}_{\text{dw}} \otimes [\boldsymbol{h}_{t-1}; \boldsymbol{x}_t] + \boldsymbol{b}_f \tag{4}$$

$$\tilde{\boldsymbol{i}}_t = \boldsymbol{W}_{\text{dw}} \otimes [\boldsymbol{h}_{t-1}; \boldsymbol{x}_t] + \boldsymbol{b}_i \tag{5}$$

式中: $\tilde{\boldsymbol{f}}_t$、$\tilde{\boldsymbol{i}}_t$ 分别为遗忘门、输入门的预激活值; $\boldsymbol{W}_{\text{dw}} \in \mathbf{R}^{k\times(d+s)\times m}$ 为深度可分离卷积核参数, 其中, k 为卷积核大小, d 为隐藏状态 $\boldsymbol{h}_{t-1}$ 的维度, s 为输入特征 $\boldsymbol{x}_t$ 的维度, m 为通道数; $\otimes$ 为深度可分离卷积操作; $\boldsymbol{h}_{t-1} \in \mathbf{R}^d$ 为上一时间步的隐藏状态; $\boldsymbol{x}_t \in \mathbf{R}^s$ 为当前时间步输入的 s 个特征; $\boldsymbol{b}_f$、$\boldsymbol{b}_i \in \mathbf{R}^m$ 为相应偏置向量。

2) 多块对角线性层

如图 3 所示, 候选记忆与输出门的预激活值通过块对角线性层(即多头全连接)计算。该层将权重矩阵分解为多个对角块(“头”), 每个头独立学习, 以增强参数效率。在本框架中, 头数设置为 4(图中简写为 N_{H}=4)。候选记忆与输出门的预激活计算式为

$$\tilde{\boldsymbol{z}}_t = \boldsymbol{W}_z \boldsymbol{x}_t + \boldsymbol{R}_z \boldsymbol{h}_{t-1} + \boldsymbol{b}_z \tag{6}$$

$$\tilde{\boldsymbol{o}}_t = \boldsymbol{W}_o \boldsymbol{x}_t + \boldsymbol{R}_o \boldsymbol{h}_{t-1} + \boldsymbol{b}_o \tag{7}$$

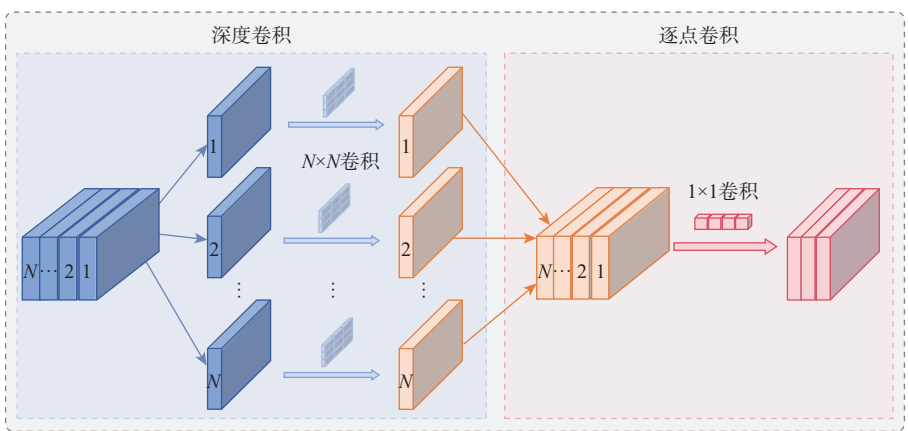

图 2　深度可分离卷积示例图

Fig. 2　Example diagram of depthwise separable convolution

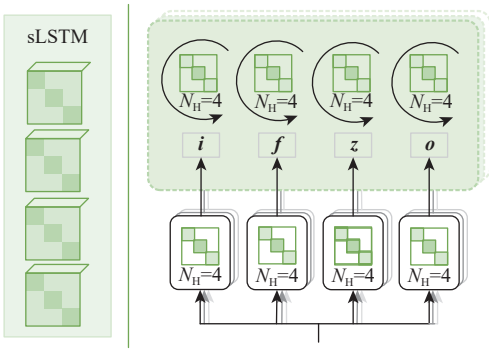

图3 多块对角线性层

Fig. 3 Multi-block diagonal linear layer

式中：$\tilde{\boldsymbol{z}}_t$、$\tilde{\boldsymbol{o}}_t$分别为候选记忆、输出门的预激活值；$\boldsymbol{W}_z$、$\boldsymbol{W}_o \in \mathbf{R}^{d\times s}$、$\boldsymbol{R}_z$、$\boldsymbol{R}_o \in \mathbf{R}^{d\times d}$为块对角权重矩阵(每个“头”对应一个对角块)；$\boldsymbol{b}_z$、$\boldsymbol{b}_o \in \mathbf{R}^{d}$为偏置向量。

sLSTM在原始LSTM上引入标量记忆和指数门控来管理长期依赖关系，获得上述预激活值后，首先，计算稳定状态以保障指数门控的数值稳定性：

$$\boldsymbol{m}_t = \max(\boldsymbol{f}_t + \boldsymbol{m}_{t-1}, \boldsymbol{i}_t) \tag{8}$$

式中：$\boldsymbol{m}_t$为当前时刻的稳定状态；$\boldsymbol{m}_{t-1}$为上一时刻的稳定状态；max(·)为逐元素取最大值函数。随后，对遗忘门、输入门施加指数激活，对候选记忆施加双曲正切激活，对输出门施加Sigmoid激活：

$$\boldsymbol{i}_t = \exp(\tilde{\boldsymbol{i}}_t - \boldsymbol{m}_t) \tag{9}$$

$$\boldsymbol{f}_t = \exp(\tilde{\boldsymbol{f}}_t + \boldsymbol{m}_{t-1} - \boldsymbol{m}_t) \tag{10}$$

$$\boldsymbol{z}_t = \tanh(\tilde{\boldsymbol{z}}_t) \tag{11}$$

$$\boldsymbol{o}_t = \sigma(\tilde{\boldsymbol{o}}_t) \tag{12}$$

式中：exp(·)为自然指数函数；tanh(·)为双曲正切函数；σ(·)为Sigmoid函数。指数门控使网络能够动态调节信息存储与遗忘的幅度，而稳定状态$\boldsymbol{m}_t$有效防止了指数运算的数值溢出。

$$\boldsymbol{c}_t = \boldsymbol{f}_t \odot \boldsymbol{c}_{t-1} + \boldsymbol{i}_t \odot \boldsymbol{z}_t \tag{13}$$

$$\boldsymbol{n}_t = \boldsymbol{f}_t \odot \boldsymbol{n}_{t-1} + \boldsymbol{i}_t \tag{14}$$

$$\boldsymbol{h}_t = \boldsymbol{o}_t \odot (\boldsymbol{c}_t \oslash \boldsymbol{n}_t) \tag{15}$$

式中：$\boldsymbol{c}_t$为细胞状态(长时记忆)；$\boldsymbol{n}_t$为归一化状态；$\boldsymbol{h}_t$为当前时刻的隐藏状态；⊙和⊘分别表示逐元素乘法和逐元素除法。通过归一化状态$\boldsymbol{n}_t$，sLSTM将细胞状态缩放至合理范围，缓解了传统LSTM中状态值无界增长的问题，从而提升了长序列建模的稳定性。

3) 任务感知特征投影

在共享层末端引入门控多层感知机(gated multi-layer perceptron, gMLP)，如图4所示，其上投影和下投影调整特征的维度，并通过高斯误差线性单元(Gaussian error linear unit, GeLU)激活函数引入非线性响应，有助于模型学习电池退化特征的复杂映射关系。此外在上下投影前使用了层归一化(layer normalization, LN)，对每个样本的所有激活进行归一化。最后，残差堆叠通过在网络中引入跳过连接来实现，将输入直接添加到输出上，形成残差连接。

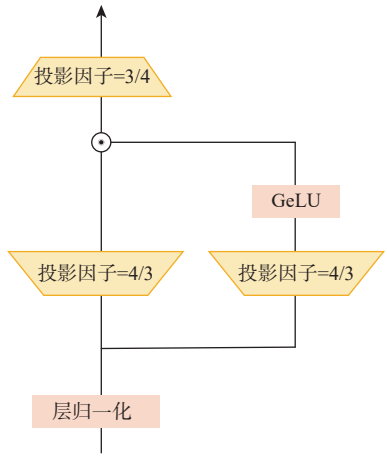

图4 门控多层感知机

Fig. 4 Gated multi-layer perceptron

最后，共享特征提取器通过残差堆叠，能够构建深层网络，提高模型的表达能力和处理复杂长序列数据的能力。

1.2.3 多任务预测器

为实现多电池退化模式的差异化建模，设计了任务自适应预测结构，其核心思想是将共享特征投影至各任务私有的退化轨迹空间。每条样本在通过共享特征提取器后输出序列特征，取最后一个时间步的隐藏状态表示当前退化状态。该状态特征作为输入，分别送入任务对应的私有全连接回归层中实现预测。任务编号作为静态输入参与权重选择，每个任务拥有独立的参数组以建模其特有的退化形态，该机制能有效实现在共享建模能力基础上的任务分离预测能力。

2 实验验证与分析

2.1 数据集

本文对3个公开数据集进行实验验证：CALCE数据集[21]来自马里兰大学高级生命周期工程中心；NASA数据集[22]由美国国家航空航天局提供的锂电池老化测试数据，广泛用于寿命预测领域研究；eVTOL数据集由美国卡内基梅隆大学和Airbus A^{3}公司测量获取[23]，针对eVTOL运行场景采集的多工况电池使用数据。

为实现多工况建模的全面性与代表性，本文基于放电电压差异对跨领域电池数据集进行系统性筛

选: 从 CALCE 数据集中选定 CS2_35～CS2_38 这 4 个子集, 同时采用 NASA 数据集中的 B0005、B0006、B0007 和 B0018 作为样本; 在 eVTOL 数据集应用场景方面, 则选取具有典型工况特征的 VAH27、VAH15、VAH28 及 VAH30 这 4 组飞行数据。在特征维度构建方面, 综合 Chen 等 [11] 对 CALCE 和 NASA 数据集的特征重要性研究成果, 选取包含循环次数、容量衰减、健康状态、阻抗特性及充放电时序参数(恒流充电时间、恒压充电时间)等关键指标; 同时结合 Mitici 等[4] 对 eVTOL 数据的分析结论, 整合了涵盖电压动态特性(起飞/巡航阶段电压均值与方差)、极端工况参数(最小电压、最大温度)及容量保持率等 8 项核心特征。特别针对 eVTOL 典型工况, 设置 VAH27 为基础测试场景(起降功率为 54 W, 巡航功率为 16 W, 巡航时间为 800 s, 基准环境温度为 25 ℃), 并差异化构建 VAH15(1 000 s 长时巡航)、VAH28(全阶段 90% 负载)和 VAH35(35 ℃ 高温环境)等对比工况。通过这 3 类数据集——覆盖从受控实验环境到动态真实应用场景的全谱系电池使用模式, 本文建立的验证体系不仅能有效评估电池退化机理, 更能系统检验模型在跨域迁移、变载适应及极端环境下的泛化性能。

图 5～图 7 分别为 CALCE、NASA、eVTOL 数据集子集的容量衰减曲线。与 CALCE 和 NASA 数据集中连续、高频的容量记录不同, eVTOL 数据集子集是模拟真实飞行任务下的电池使用情形, 其容量测试呈现出低频间歇性采样特征, 导致可用于建模的有效 RUL 样本数量非常有限(每个子集仅 11～23 个容量观测点), 且对于 eVTOL 电池, 考虑保守的安全裕度, 本文将 EOL 阈值设置为初始测量电池容量的 85%。

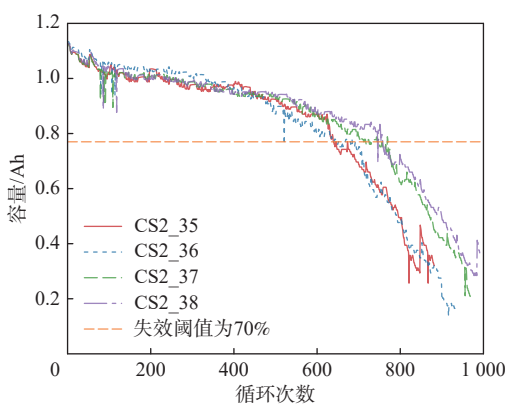

图 5　CALCE 数据集的容量衰退曲线

Fig. 5　Capacity degradation curves of CALCE datase

2.2　评估指标

为了在验证过程中对电池多维特征的寿命预测性能进行定量评估, 采用了 3 个评估标准: 相对误差(relative error, RE)、平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE), 定义如下:

$$R_{\mathrm{E}}=\frac{|y_t-\hat{y}_t|}{y_t} \tag{16}$$

$$M_{\mathrm{AE}}=\frac{1}{S}\sum_{t}^{S}|y_t-\hat{y}_t| \tag{17}$$

$$R_{\mathrm{MSE}}=\sqrt{\frac{1}{S}\sum_{t}^{S}(y_t-\hat{y}_t)^2} \tag{18}$$

式中: y_t 和 $\hat{y}_t$ 分别为第 t 个样本的测量寿命和预测寿命; S 为样本数量; RE、MAE 和 RMSE 的值越小性能越好。

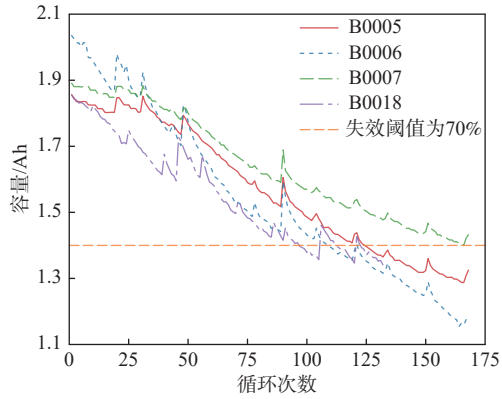

图 6　NASA 数据集的容量衰退曲线

Fig. 6　Capacity degradation curves of NASA Datase

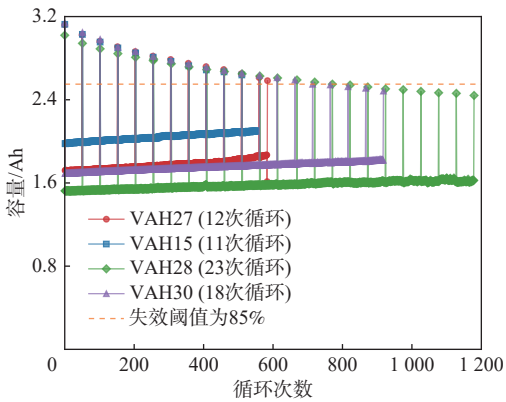

图 7　eVTOL 数据集的容量衰退曲线

Fig. 7　Capacity degradation curves of eVTOL dataset

2.3　实施细节

实验在配备 NVIDIA GeForce RTX 4090 显卡(24 GB 显存)及 128 GB RAM 的工作站上进行, 代码基于 PyTorch 1.12.1 框架实现。

在多源异构输入层的数据处理阶段, 均采用滑动窗口法构造序列样本, eVTOL 数据设定窗口长度为 10, 而 CALCE 和 NASA 数据集采用长度分别为 32 和 64 的窗口以捕获完整退化特征。所有输入序列均进行零均值标准化处理, 容量标签归一化至

[0,1]区间，确保多源数据的一致建模。为验证模型在多任务场景下的鲁棒性与泛化能力，引入任务编号作为条件输入，统一调度不同子任务对应的私有预测器。训练过程采用Adam优化器，基础学习率为1×10^{-3}，并使用梯度裁剪（阈值为5.0）防止梯度爆炸。不同模型结构（如GRU、LSTM、Transformer、sLSTM）下均采用隐藏层维度为64的共享编码器，并基于任务分离回归头输出各子集的RUL预测结果。批量大小根据子集样本规模与显存占用动态在32、64、128之间调整，配合自适应学习率调度与早停机制（50轮验证停滞）实现高效训练。

模型最终性能通过MAE、RMSE和RE指标综合评估，并在3组随机种子（42、123、999）下重复实验取平均，以减弱偶然性误差影响。sLSTM模型结构中进一步设置堆叠块数为7，深度卷积核大小为4，感知机投影因子为1.3，上下文长度为256，并施加1×10^{-4}的权重衰减正则化，从而在保持模型容量的前提下提升泛化能力。

3 实验结果与分析

3.1 总体表现

为进一步验证本文方法的性能，引入当前主流方法在RE、MAE、RMSE进行对比分析。所有方法的得分如表1～表3所示，所有指标均基于5次实验的平均结果计算。最佳结果以粗体突出显示，次佳结果以下划线突出显示。

表1 各方法在CALCE数据集上RUL预测性能对比

Table 1 Comparison of RUL prediction performance of various methods on CALCE dataset

方法	RE	MAE	RMSE
MLP	0.401 8	0.155 7	0.203 8
LSTM	0.090 2	0.058 2	0.073 6
Dual-LSTM	0.088 5	0.063 6	0.087 4
GRU	0.131 9	0.067 1	0.094 6
AttMoE	0.076 1	0.057 7	0.079 4
sLSTM	<u>0.048 5</u>	<u>0.046 9</u>	<u>0.053 7</u>
MTL-sLSTM	**0.012 7**	**0.015 1**	**0.020 2**

由表1～表3可知：①本文MTL-sLSTM在所有方法中取得了最好的结果，体现了其在多工况下复杂时序数据建模中的卓越能力；②sLSTM也能得到较好的性能，表明sLSTM的层级结构有效捕获了多工况锂电池的长期时序依赖关系；③MTL-sLSTM通过联合优化多个相关任务，充分利用任务间的潜在关联性，显著提升了预测精度，与当前主流模型（Dual-LSTM、基于Transformer的AttMoE等）相比，MTL-sLSTM在3项实验中的各项指标均达到最优，尤其在eVTOL数据集小样本下优势更显著，这进一步证明了多任务学习与特征共享机制在复杂工况下时序预测任务中的实际应用价值。

表2 各方法在NASA数据集上RUL预测性能对比

Table 2 Comparison of RUL prediction performance of various methods on NASA dataset

方法	RE	MAE	RMSE
MLP	0.385 1	0.137 9	0.154 1
LSTM	0.264 8	0.082 9	0.090 5
Dual-LSTM	0.255 7	0.081 5	0.087 9
GRU	0.304 4	0.080 6	0.092 1
AttMoE	0.200 0	0.076 0	0.087 2
sLSTM	<u>0.189 8</u>	<u>0.061 7</u>	<u>0.073 5</u>
MTL-sLSTM	**0.058 7**	**0.012 4**	**0.018 1**

表3 各方法在eVTOL数据集上的RUL预测性能对比

Table 3 Comparison of RUL prediction performance of various methods on eVTOL dataset

方法	RE	MAE	RMSE
MLP	0.281 7	0.099 5	0.147 5
LSTM	0.580 1	0.118 9	0.153 7
Dual-LSTM	<u>0.199 6</u>	0.258 7	0.190 0
GRU	0.407 7	0.091 8	0.125 3
AttMoE	0.921 3	0.317 4	0.329 8
sLSTM	0.257 2	<u>0.054 7</u>	<u>0.064 4</u>
MTL-sLSTM	**0.138 6**	**0.018 7**	**0.025 3**

为直观说明MTL-sLSTM的预测表现，如图8～图10所示，分别为MTL-sLSTM模型的CALCE、NASA及eVTOL数据集4个子集的真实值与预测值对比。由图8～图10可知，各个预测模型与真实数据的拟合效果均表现良好。

3.2 多源数据对齐评估

为证明多源异构输入层能有效缩小不同子集的分布差异，本节以eVTOL数据集为例，使用主成分分析（principal component analysis, PCA）将8维特征分别投影到二维空间，如图11所示。

在图11(a)对齐前的PCA投影中，各子集样本点分布明显分离，VAH30总体位于上方，而图11(b)对齐后的PCA投影中，不同类别的数据点在主成分1和主成分2的坐标系中分布更加集中，表明对齐处理有效地减少了不同类别之间的分布差异。

3.3 多任务学习有效性

本文通过使用MTL实现性能增强，为评估这一改进，将MTL与其简化版本进行比较，即多任务和单任务学习的对比。简化版本没有经过多源异构输入层进行数据融合，直接将每个子集单独输入模型进行预测。

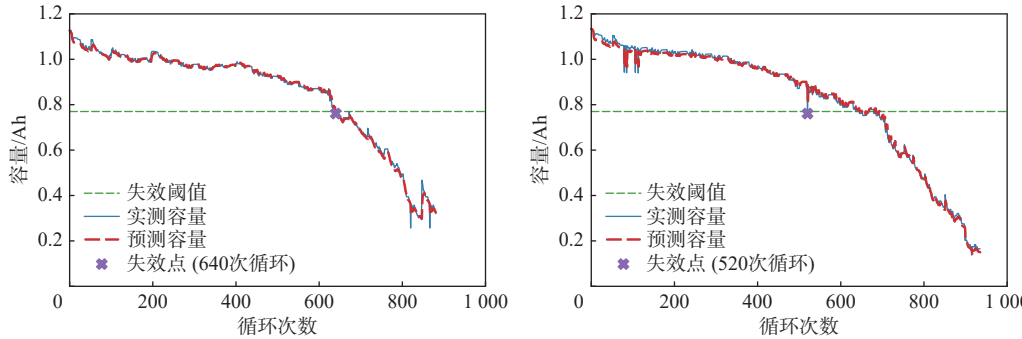

(a) CS2_35, MAE为0.014, RMSE为0.017, RE为0.015 9　　(b) CS2_36, MAE为0.018, RMSE为0.022, RE为0.009 6

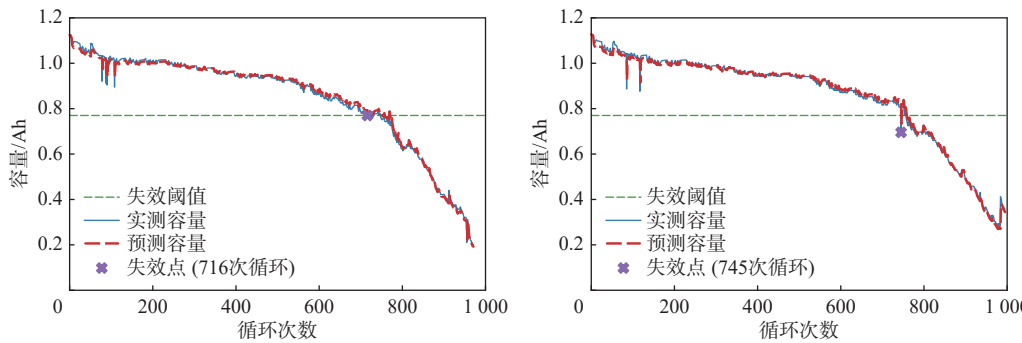

(c) CS2_37, MAE为0.015, RMSE为0.023, RE为0.014 2　　(d) CS2_38, MAE为0.013, RMSE为0.018, RE为0.011 1

图 8　MTL-sLSTM 模型在 CALCE 数据集 4 个子集的真实值与预测值对比

Fig. 8　Comparison of true values and predicted values for MTL-sLSTM model on four subsets of CALCE dataset

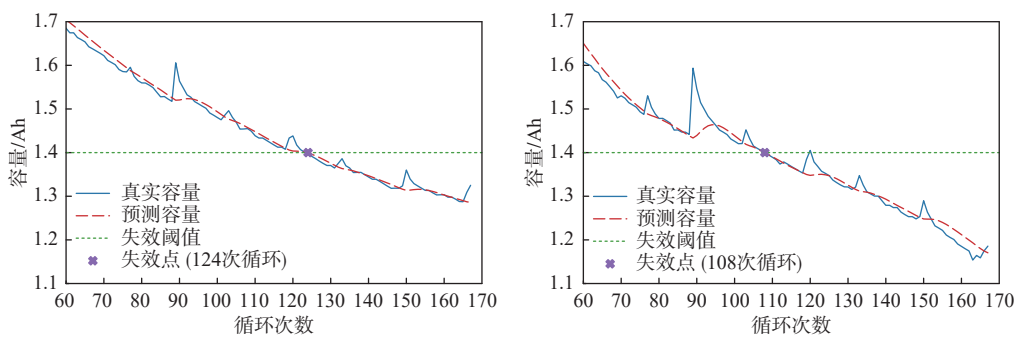

(a) B0005, RMSE为0.018, MAE为0.012, RE为0　　(b) B0006, RMSE为0.032, MAE为0.021, RE为0.011

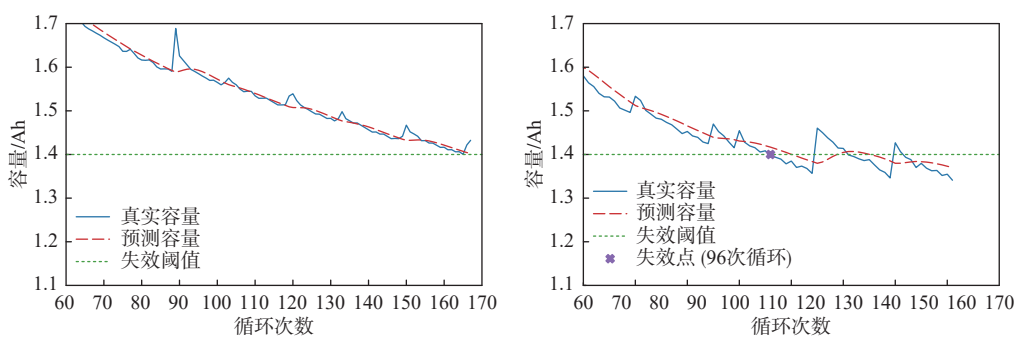

(c) B0007, RMSE为0.016, MAE为0.011, RE为0　　(d) B0018, RMSE为0.029, MAE为0.022, RE为0.062

图 9　MTL-sLSTM 模型在 NASA 数据集 4 个子集的真实值与预测值对比

Fig. 9　Comparison of true values and predicted values for MTL-sLSTM model on four subsets of NASA dataset

以 CALCE 数据集为例, 子集: CS2_35、CS2_36、CS2_37、CS2_38 为不同任务。表 4 为 GRU、LSTM、sLSTM 这 3 种基础模型在启用 MTL 与未启用 MTL 时的评估指标(RE、MAE、RMSE)及对应改进率。如在 CS2_35 数据子集中, LSTM 模型的 RE 值改进率达 0.70; sLSTM 模型启用 MTL 的 RE 值改进率达 0.83。其他数据子集(CS2_36、CS2_37、CS2_38)也以相同逻辑呈现各模型在不同 MTL 状态下的指标数值及改进率, 系统对比了 MTL 对各模型在 RE、MAE、RMSE 指标上的性能提升效果。

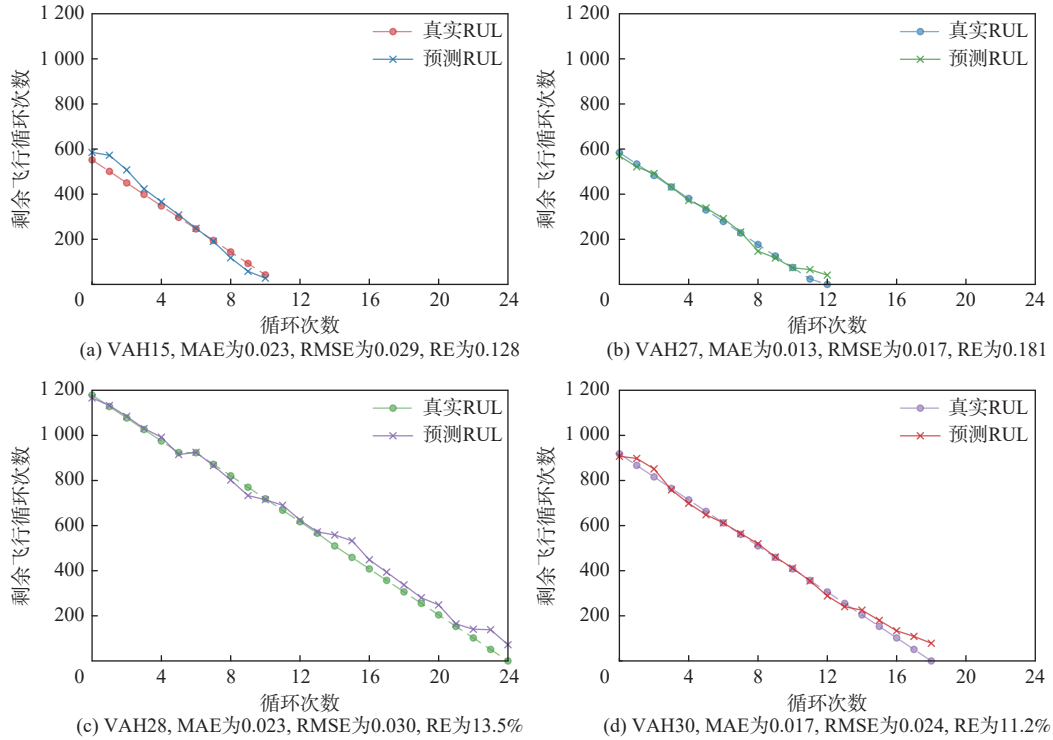

(a) VAH15, MAE为0.023, RMSE为0.029, RE为0.128
(b) VAH27, MAE为0.013, RMSE为0.017, RE为0.181
(c) VAH28, MAE为0.023, RMSE为0.030, RE为13.5%
(d) VAH30, MAE为0.017, RMSE为0.024, RE为11.2%

图 10 MTL-sLSTM 模型在 eVTOL 数据集 4 个子集的真实值与预测值对比

Fig. 10 Comparison of true values and predicted values for MTL-sLSTM model on four subsets of eVTOL dataset

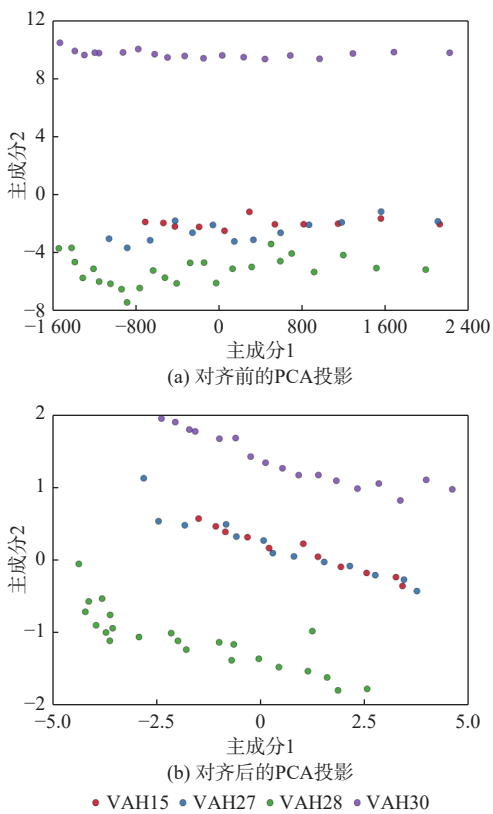

(a) 对齐前的PCA投影
(b) 对齐后的PCA投影

图 11 eVTOL 数据集子集的特征对齐前后对比

Fig. 11 Comparison of feature alignment before and after for eVTOL dataset subsets

图 12 为不同评估指标的 MTL-sLSTM 与 sLSTM 对比，由图可知，对于 CALCE 数据集中的 4 个子集，MTL-sLSTM 的表现始终显著优于其简化版本 sLSTM，表明 MTL 有助于提高不同任务的 RUL 预测性能。

3.4 共享特征提取器采用 sLSTM 的有效性

实验中，首先配置模型核心参数（包括模型模式、窗口大小、隐藏层维度等），如表 5 所示。针对不同模型（如 MTL-CNN、MTL-MLP 等）设定对应参数，通过运行 3 组不同随机种子完成训练并记录损失。随后加载各模型多组种子的训练损失数据，计算均值与标准差，分别构建整体趋势图与局部放大图。整体趋势呈现完整训练轮次的 MSE 损失变化，局部放大图聚焦特定轮次区间，细化损失变化趋势。

本实验采用 log 刻度绘制，由于 MSE 损失值覆盖从 10^{-2}～10^{-5} 的大跨度范围，log 刻度可压缩数值量级，清晰呈现损失在不同数量级的变化，既保留训练初期损失快速下降的细节，又凸显后期收敛阶段的细微差异。

从实验结果看，共享特征提取器采用 sLSTM 具备显著有效性。对比 MTL-sLSTM 与 MTL-Transformer、MTL-GRU、MTL-RNN 等模型，MTL-sLSTM 在训练中损失下降更迅速，且最终稳定于最低水平。图 13(a) 中 MTL-sLSTM 损失曲线始终处于最下方，图 13(b) 也显示其在特定轮次区间内损失均值更低。

另外，将实验 NASA 数据集子集在多任务模型中的评估指标列为表 6 进行对比，MTL-sLSTM 在各子集（如 B0005、B0006 等）的 MAE 和 RMSE 指

表 4　CALCE 数据集子集在基础模型上启用 MTL 与未启用 MTL 时的评估指标对比

Table 4　Comparison of evaluation metrics for CALCE dataset subsets between enabling MTL and not enabling MTL on base model

模型	RE				MAE				RMSE			
	CS2_35	CS2_36	CS2_37	CS2_38	CS2_35	CS2_36	CS2_37	CS2_38	CS2_35	CS2_36	CS2_37	CS2_38
GRU	0.074 2	0.116 8	0.103 0	0.056 0	0.063 5	0.109 1	0.077 7	0.072 7	0.083 4	0.144 1	0.105 1	0.095 5
GRU +MTL	0.026 8	0.024 2	0.020 1	0.020 9	0.025 8	0.029 1	0.026 0	0.020 0	0.034 6	0.036 5	0.031 9	0.029 2
LSTM	0.109 0	0.116 4	0.098 4	0.091 3	0.080 6	0.108 5	0.078 5	0.086 9	0.103 3	0.143 6	0.104 5	0.113 0
LSTM +MTL	0.032 2	0.019 4	0.013 7	0.015 0	0.024 8	0.018 4	0.015 8	0.017 5	0.031 5	0.023 8	0.019 2	0.023 3
sLSTM	0.058 2	0.074 3	0.024 7	0.036 6	0.057 7	0.068 9	0.026 9	0.034 0	0.062 7	0.078 4	0.032 7	0.041 1
sLSTM +MTL	0.009 7	0.007 5	0.007 6	0.007 1	0.014 6	0.009 3	0.012 1	0.009 3	0.017 7	0.012 7	0.010 1	0.011 9

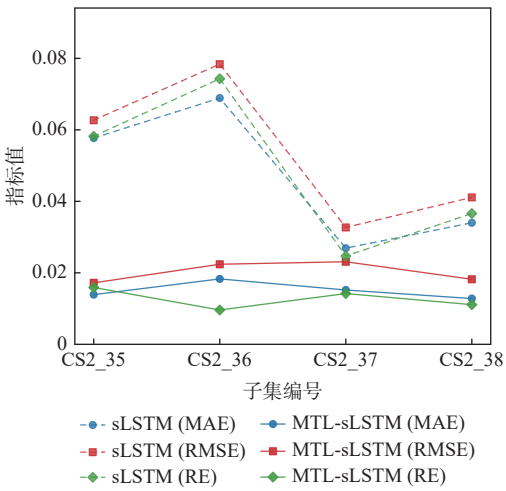

图 12　CALCE 数据集子集评估指标对比

Fig. 12　CALCE dataset subsets evaluation metrics comparison

表 5　本文方法在 NASA 数据集上的超参数

Table 5　Hyperparameters of the proposed method on NASA dataset

参数	数值
滑动窗口大小	32
隐藏层维度	128
循环神经网络层数	2
学习率	0.001
最大训练轮数	1 000
早停耐心参数	50
CNN通道数	16
MLP隐藏层单元数	256

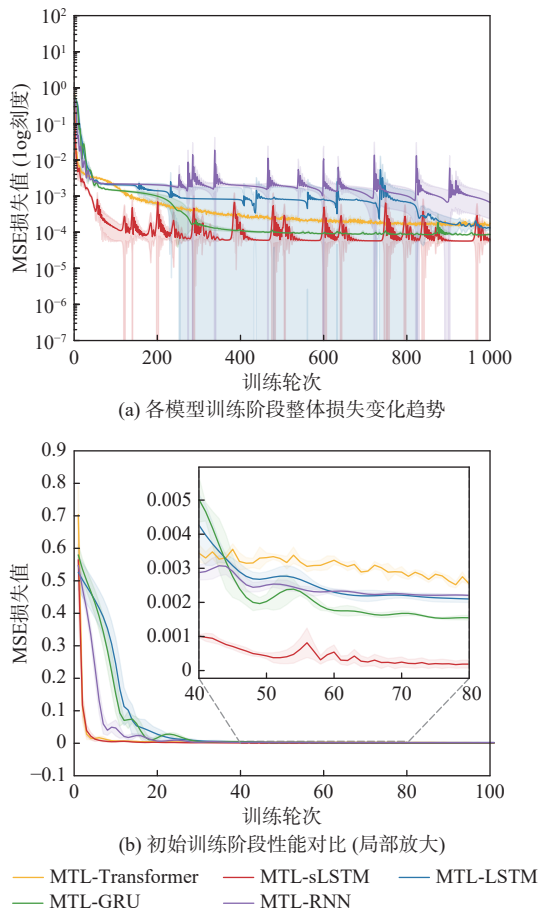

图 13　多任务模型训练损失对比

Fig. 13　Multi-task model training loss comparison

标上全面优于其他模型(见表中加黑数值), 这表明 sLSTM 作为共享特征提取器能更高效地提取特征, 不仅加速训练收敛过程, 还大幅降低预测误差, 充分验证了其在共享特征提取模块中应用的有效性。

3.5　模型规模分析

为量化评估模型效率, 本文以 eVTOL 数据集为例, 从参数量、乘加运算次数(multiply-accumulate operations, MACs)和推理时间 3 个维度进行对比分析, 如图 14 所示。

实验结果表明, 多任务学习框架展现出显著优势: 参数量方面, 多任务模型相比单任务模型总和降低 60% 以上; 计算复杂度方面, MACs 减少 40% 以上; 推理效率方面, AttMoE 的多任务单次推理耗时(0.54 ms)仅为单任务累计推理时间(2.03 ms)的 26.6%。

由图 14 可知, 多任务模型总是低于相应的单任务模型, MTL 模型在参数量、MACs 和推理时间上均优于单任务。

表 6 NASA 数据集子集在多任务模型中的评估指标对比

Table 6 Comparison of evaluation metrics of NASA dataset subsets in multi-task models

模型	MAE				RMSE			
	B0005	B0006	B0007	B0018	B0005	B0006	B0007	B0018
MTL-GRU	0.083 6	0.087 3	0.064 2	0.038 4	0.094 9	0.105 1	0.074 6	0.045 2
MTL-LSTM	0.094 8	0.096 3	0.069 5	0.041 3	0.107 6	0.115 8	0.080 5	0.050 2
MTL-CNN	0.079 3	0.084 1	0.059 2	0.038 1	0.090 0	0.100 5	0.068 7	0.044 7
MTL-MLP	0.081 5	0.078 6	0.058 7	0.040 8	0.092 5	0.096 1	0.068 2	0.048 0
MTL-Transformer	0.082 6	0.084 1	0.061 1	0.041 2	0.093 9	0.100 4	0.070 9	0.048 1
MTL-sLSTM	**0.009 4**	**0.013 8**	**0.007 4**	**0.015 0**	**0.014 3**	**0.022 8**	**0.012 9**	**0.021 3**

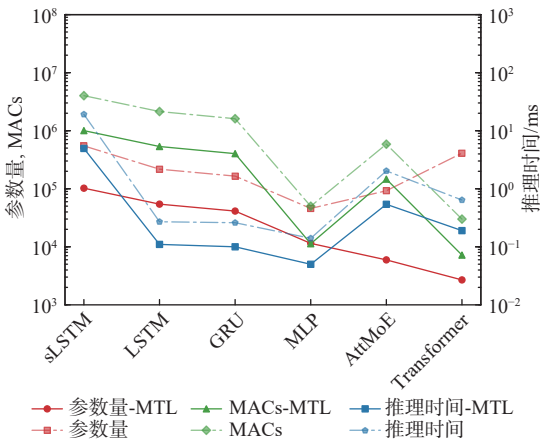

图 14 规模分析对比

Fig. 14 Model scale comparison

4 结 论

1）实验结果表明，本文方法在 3 类数据集上均表现出显著优势。如在 eVTOL 数据集中，相对 AttMoE，MTL-sLSTM 在 RE、MAE 和 RMSE 分别提升约 0.849 7、0.941 2 和 0.923 6。

2）通过对比实验，验证了多任务学习策略的有效性。各模型的 RE、MAE 和 RMSE 改进率普遍超过 60%。共享特征提取器采用 sLSTM 显著提升了特征表达能力，其训练损失较 MTL-LSTM 和 MTL-GRU 降低至少 50%，且在 NASA 数据子集中，MTL-sLSTM 的 MAE 和 RMSE 指标全面优于对比模型，进一步证明了该架构的鲁棒性。

3）模型规模分析表明，多任务学习在资源利用、模型压缩与推理速度方面具备明显优势。各模型在 MTL 下的 MACs 与参数量普遍下降约 1 个数量级；推理时间显著小于单任务模型运行 4 次的总时间，如 AttMoE 从 100 ms 降至 0.1 ms 以下。MTL 架构实现了计算资源、模型规模与推理效率的统一优化。

为进一步增强对低空载具动力电池的 RUL 预测精度和泛化能力，并解决模型规模与推理开销对部署性能的制约。下一步研究将结合在线增量学习技术，动态优化多任务预测头参数，并探索轻量化部署方案，以进一步提升复杂场景下的实时预测精度与稳定性。

参考文献（References）

[1] Mohtat P, Lee S, Siegel J B, et al. Comparison of expansion and voltage differential indicators for battery capacity fade[J]. Journal of Power Sources, 2022, 518: 230714.

[2] Yang J F, Cai Y F, Mi C. Lithium-ion battery capacity estimation based on battery surface temperature change under constant-current charge scenario[J]. Energy, 2022, 241: 122879.

[3] Yang J F, Li X, Sun X D, et al. An efficient and robust method for lithium-ion battery capacity estimation using constant-voltage charging time[J]. Energy, 2023, 263: 125743.

[4] Mitici M, Hennink B, Pavel M, et al. Prognostics for lithium-ion batteries for electric vertical take-off and landing aircraft using data-driven machine learning[J]. Energy and AI, 2023, 12: 100233.

[5] Chang V W, Gallman J W, Richardson M E, et al. Development and test of safe, high power lithium ion main batteries for general aviation aircraft[J]. SAE International Journal of Aerospace, 2008, 1(1): 982-999.

[6] 韩露, 史贤俊, 林云. 航空锂电池寿命预测方法研究[J]. 电子测量技术, 2021, 44(1): 20-25.
Han L, Shi X J, Lin Y. Research on life prediction method of aviation lithium battery[J]. Electronic Measurement Technology, 2021, 44(1): 20-25(in Chinese).

[7] Zraibi B, Okar C, Chaoui H, et al. Remaining useful life assessment for lithium-ion batteries using CNN-LSTM-DNN hybrid method[J]. IEEE Transactions on Vehicular Technology, 2021, 70(5): 4252-4261.

[8] 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(5): 142-151.
He N, Zhang S Y, Li R X, et al. RUL prediction of lithium battery based on particle filter and GRU neural network fusion[J]. Journal of Harbin Institute of Technology, 2024, 56(5): 142-151(in Chinese).

[9] 董渊昌, 庞晓琼, 贾建芳, 等. 基于 SVD-SAE-GPR 的锂离子电池 RUL 预测[J]. 储能科学与技术, 2023, 12(4): 1257-1267.
Dong Y C, Pang X Q, Jia J F, et al. Remaining useful life prediction of lithium-ion batteries based on SVD-SAE-GPR[J]. Energy Storage Science and Technology, 2023, 12(4): 1257-1267(in Chinese).

[10] 陈欣, 李云伍, 梁新成, 等. 基于模态分解的 Transformer-GRU 联

合电池健康状态估计[J]. 储能科学与技术, 2023, 12(9): 2927-2936.
Chen X, Li Y W, Liang X C, et al. Battery health state estimation of combined Transformer-GRU based on modal decomposition[J]. Energy Storage Science and Technology, 2023, 12(9): 2927-2936(in Chinese).
[11] Chen D Q, Zhou X Z. AttMoE: attention with mixture of experts for remaining useful life prediction of lithium-ion batteries[J]. Journal of Energy Storage, 2024, 84: 110780.
[12] Alharthi M, Mahmood A. xLSTMTime: long-term time series forecasting with xLSTM[J]. AI, 2024, 5(3): 1482-1495.
[13] Ragab M, Chen Z H, Wu M, et al. Contrastive adversarial domain adaptation for machine remaining useful life prediction[J]. IEEE Transactions on Industrial Informatics, 2021, 17(8): 5239-5249.
[14] Zhang Z, Wang Y Y, Ruan X X, et al. Lithium-ion batteries lifetime early prediction using domain adversarial learning[J]. Renewable and Sustainable Energy Reviews, 2025, 208: 115062.
[15] Chen J X, Li D P, Huang R Y, et al. Aero-engine remaining useful life prediction method with self-adaptive multimodal data fusion and cluster-ensemble transfer regression[J]. Reliability Engineering & System Safety, 2023, 234: 109151.
[16] Wang H Q, Lin T J, Cui L L, et al. Multitask learning-based self-attention encoding atrous convolutional neural network for remaining useful life prediction[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 3516108.
[17] Kim T S, Sohn S Y. Multitask learning for health condition identification and remaining useful life prediction: deep convolutional neural network approach[J]. Journal of Intelligent Manufacturing, 2021, 32(8): 2169-2179.
[18] Zhang Y, Xin Y Q, Liu Z W, et al. Health status assessment and remaining useful life prediction of aero-engine based on BiGRU and MMoE[J]. Reliability Engineering and System Safety, 2022, 220: 108263.
[19] Park K, Choi Y, Choi W J, et al. LSTM-based battery remaining useful life prediction with multi-channel charging profiles[J]. IEEE Access, 2020, 8: 20786-20798.
[20] Semeraro C, Caggiano M, Olabi A G, et al. Battery monitoring and prognostics optimization techniques: challenges and opportunities [J]. Energy, 2022, 255: 124538.
[21] Pecht M. CALCE battery group [EB/OL]. (2025-06-28)[2026-07-16]. https://doi.org/10.21227/w9rg-7173.
[22] Saha B, Goebel K. Battery data set[EB/OL]. (2025-07-18)[2026-07-16]. http://data.nasa.gov/dataset/li-ion-battery-aging-datasets.
[23] Bills A, Sripad S, Fredericks L, et al. A battery dataset for electric vertical takeoff and landing aircraft[J]. Scientific Data, 2023, 10: 344.

Remaining useful life prediction of lithium-ion batteries in low-altitude vehicles based on MTL-sLSTM

ZHANG Huishan[1], SHEN Jiying[2], LIU Dongsheng[1,*], ZHOU Zhikai[3], HU Yifan[1], XU Yangbo[1]

(1. School of Computer Science and Technology, Zhejiang Gongshang University, Hangzhou 310020, China;
2. Hangzhou Science and Technology Information Institute, Hangzhou 310053, China;
3. Hangzhou Shuzheng Technology Co., Ltd., Hangzhou 310020, China)

Abstract: A prediction technique based on multi-task learning with scalar long short-term memory (MTL-sLSTM) was presented to solve the problem of remaining useful life (RUL) prediction for lithium-ion batteries in low-altitude economy vehicles under multi-condition coupling. Firstly, a heterogeneous input layer integrates multi-dimensional time-series data from diverse flight conditions. Then, a hierarchical stacked sLSTM structure serves as a shared feature extractor, enabling deep cross-scale feature integration and the capture of common nonlinear degradation patterns. Finally, by hard-coding task IDs to dynamically modulate network weights, the multi-task learning mechanism adaptively identifies each operating condition's unique aging behavior while simultaneously promoting knowledge transfer across domains for independent RUL estimation. According to experimental results, MTL-sLSTM achieves a 60.7%–92.3% reduction in root mean square error (RMSE) on the eVTOL dataset, outperforming six temporal approaches, including the attention mixture of experts (AttMoE) and dual-channel LSTM (Dual-LSTM). This validates the effectiveness of the multi-task learning mechanism in enhancing the generalization capability of degradation features and improving prediction accuracy under complex operating conditions.

Keywords: remaining useful life prediction; multi-task learning; long short-term memory network; lithium-ion batteries; electric vertical takeoff and landing; low-altitude economic vehicles

Received: 2025-04-03; **Accepted**: 2025-04-29; **Published Online**: 2025-06-04 11:09
URL: link.cnki.net/urlid/11.2625.V.20250604.0851.001
Foundation items: Zhejiang Ten Thousand Talents Program (2022R52048); Zhejiang Provincial Science and Technology Program (2024C01028, 2024C01211)
* **Corresponding author**. E-mail: lds1118@zjgsu.edu.cn