

面向 eVTOL 动力电池的多源迁移 GPR-SOC 估计方法

李元元¹, 时晓宇^{2*}, 樊宇³

¹西南民族大学电气工程学院 四川成都

²西华大学电气与电子信息学院 四川成都

³内蒙古电子信息职业技术学院电子与自动化系 内蒙古呼和浩特

【摘要】电动垂直起降飞行器 (electric vertical take-off and landing, eVTOL) 动力电池在飞行任务中存在负载变化快、功率波动明显和工况持续时间差异较大等特点, 对荷电状态 (state of charge, SOC) 估计的跨工况适应性提出了较高要求。针对公开 eVTOL 电池数据缺少独立开路电压曲线、脉冲功率测试参数和完整等效电路辨识条件的问题, 本文提出一种面向 eVTOL 动力电池的多源迁移 GPR-SOC 估计方法。该方法以安时积分结果作为 SOC 先验, 将容量构造标称 SOC 与先验 SOC 之间的偏差作为残差学习目标, 并利用多个源域迁移高斯过程回归子模型进行残差预测, 最后根据预测不确定度对各子模型结果进行加权融合。基于公开 eVTOL 电池数据的仿真结果表明, 所提方法能够在保持安时积分长期变化趋势的基础上, 对局部估计偏差进行有效补偿, 提高目标域样本有限条件下相对于容量构造标称 SOC 的拟合精度。由于数据集未提供独立 OCV 标定或专门实验测量得到的真实 SOC, 本文报告的误差结果主要反映模型对容量构造标称 SOC 的残差修正能力, 不能直接等同于实际 BMS 场景中的真实 SOC 绝对估计误差。该方法可为公开数据条件受限下的 eVTOL 动力电池 SOC 估计研究提供一种可复现的残差修正思路。

【关键词】eVTOL; 动力电池; 荷电状态; 迁移学习; 高斯过程回归

【基金项目】国家自然科学基金项目 (62503406); 四川省科技计划资助项目 (2024NSFSC2039); 西南民族大学大学维州团队项目 (SMUWZ202411); 内蒙古自治区直属高校基本科研业务费项目 (JBYWF2026011)

【收稿日期】2026 年 5 月 15 日

【出刊日期】2026 年 6 月 20 日

【DOI】10.12208/j.jeea.20260017

Multi-source transfer GPR-Based SOC estimation method for eVTOL power batteries

Yuanyuan Li¹, Xiaoyu Shi^{2*}, Yu Fan³

¹College of Electrical Engineering, Southwest Minzu University, Chengdu, Sichuan

²School of Electrical Engineering and Electronic Information, Xihua University, Chengdu, Sichuan

³Inner Mongolia Electronic Information Vocational Technical College, Hohhot, Inner Mongolia

【Abstract】Electric vertical take-off and landing (eVTOL) power batteries are characterized by rapid load changes, pronounced power fluctuations, and large differences in operating duration during flight missions, which impose high requirements on the cross-condition adaptability of state-of-charge (SOC) estimation. To address the lack of independent open-circuit voltage curves, pulse power test parameters, and complete equivalent-circuit identification conditions in public eVTOL battery datasets, this paper proposes a multi-source transfer GPR-SOC estimation method for eVTOL power batteries. The proposed method uses coulomb counting as the SOC prior, takes the deviation between the capacity-derived nominal SOC and the prior SOC as the residual learning target, and constructs multiple source-domain transfer Gaussian process regression submodels for residual prediction. The final residual correction is obtained by weighting the outputs of these submodels according to their predictive uncertainty. Simulation results based on public eVTOL battery data show that the proposed method can compensate for local estimation deviations while preserving the long-term trend of coulomb counting, thereby improving the fitting accuracy with respect to capacity-derived nominal SOC under limited target-domain samples. Since the dataset does not provide independently OCV-calibrated or experimentally measured true SOC, the

*通讯作者: 时晓宇

reported errors mainly reflect the residual correction ability of the model for capacity-derived nominal SOC and cannot be directly regarded as the absolute true SOC estimation errors in practical BMS scenarios. This method provides a reproducible residual correction approach for eVTOL battery SOC estimation under limited public data conditions.

【Keywords】eVTOL; Power battery; State of charge; Transfer learning; Gaussian process regression

1 引言

电动垂直起降飞行器 (electric vertical take-off and landing, eVTOL) 是城市空中交通、低空经济和航空电动化的重要发展方向^[1]。动力电池作为 eVTOL 的核心能源部件, 不仅决定飞行任务的续航能力和功率输出能力, 也直接关系到飞行过程中的能量管理、剩余航程评估和安全裕度判定。荷电状态 (state of charge, SOC) 是表征动力电池可用电量的重要状态量, 其估计精度会影响电池管理系统的功率限制、任务规划和故障预警效果^[2]。与地面电动车辆相比, eVTOL 在起飞、巡航和降落等阶段存在更明显的负载差异和功率切换特征, 电池在短时间内可能经历高倍率放电和快速工况变化, 因此开展面向 eVTOL 动力电池的 SOC 估计研究具有重要工程意义^[3-4]。

现有 SOC 估计方法主要可分为基于模型的方法和基于数据驱动的方法^[5-6]。基于模型的方法通常以安时积分、等效电路模型或电化学模型为基础, 并结合扩展卡尔曼滤波、无迹卡尔曼滤波、粒子滤波等状态估计算法实现 SOC 在线估计^[7-8]。该类方法能够利用电池内部机理或等效动态关系描述电压、电流与 SOC 之间的联系, 具有较好的物理可解释性和在线递推能力; 在模型结构合理、参数辨识充分的条件下, 可以取得较高的估计精度。然而, 基于模型的方法对初始 SOC、容量参数、开路电压曲线、内阻和极化参数等较为敏感, 当电池温度、倍率、老化状态或运行工况发生变化时, 模型参数容易产生漂移, 进而影响估计稳定性^[9-10]。此外, 复杂电化学模型虽然机理更完整, 但参数数量多、计算量较大, 工程应用中常需要在精度和实时性之间进行折中^[11]。

基于数据驱动的方法则主要利用支持向量回归、随机森林、高斯过程回归、长短期记忆网络、门控循环单元和 Transformer 等机器学习或深度学习模型, 从电压、电流、温度等可测信号中学习 SOC 与外部响应之间的非线性映射关系^[12-15]。该类方法不需要显式建立电池等效电路或电化学方程, 能够刻画复杂工况下的非线性特征, 对多维测量数据具有较强的表达能力。其不足在于模型性能通常依赖训练样本的数量、覆盖范围和标签质量, 当训练域与测试域之间存在分布差

异时, 模型泛化能力可能下降; 同时, 部分深度学习模型参数规模较大, 可解释性和不确定度表达能力相对不足, 在小样本目标场景中容易出现过拟合或外推误差。

针对跨电池、跨任务或跨工况条件下的数据分布差异, 迁移学习为 SOC 估计提供了新的思路^[16]。通过利用源域中已有的历史数据或模型知识, 迁移学习能够在目标域样本较少时改善模型训练效果, 降低完全依赖目标域数据建模的难度^[17]。高斯过程回归 (Gaussian process regression, GPR) 是一类非参数贝叶斯回归方法, 具有小样本建模能力较强、预测结果可同时给出均值和方差的特点, 适合用于目标样本有限且需要评价预测可信度的电池状态估计问题^[18]。进一步地, 多源域迁移 GPR 可从多个源域学习可迁移的残差信息, 并利用预测不确定度评估不同源域子模型对目标样本的可靠程度。与直接提出新的 SOC 理论模型不同, 本文重点在于关注在公开 eVTOL 数据条件受限时, 如何把容量先验、跨任务残差学习和不确定度融合结合起来, 形成一种可实施的 SOC 修正框架。

基于上述分析, 本文提出一种基于多源域迁移高斯过程回归的 eVTOL 动力电池 SOC 残差估计方法。首先, 利用累计放电容量与电流积分关系构造片段内 SOC 标称标签及安时积分 SOC 先验, 为后续估计提供具有容量变化趋势约束的物理参考。随后, 将安时积分先验与 SOC 标称标签之间的偏差定义为残差学习目标, 并将不同电池文件或不同飞行任务文件划分为多个源域。针对每一个源域, 构建包含源域知识迁移和目标域少量样本校正能力的迁移高斯过程回归 (Transfer Gaussian Process Regression, TR-GPR) 子模型, 通过迁移机制建立源域与目标域之间的相关性, 实现跨域残差特征学习。进一步地, 考虑不同源域与目标域之间存在不同程度的相关性, 本文利用各迁移 GPR 子模型输出的预测方差表征其对当前样本的预测不确定度, 并基于不确定度设计多源域加权融合策略, 获得最终 SOC 残差修正量。该方法的创新性主要体现在面向 eVTOL 公开任务数据的数据条件适配、容量先验约束下的残差建模方式以及多源子模型不确定度融合策略, 而不是提出全新的 GPR 基础理论。

本文的主要贡献包括: 1) 面向 eVTOL 飞行放电任务, 在缺少独立 OCV 曲线和完整等效电路参数的公开数据条件下, 构建基于安时积分先验的 SOC 残差估计框架, 将 SOC 估计问题转化为容量先验误差的学习与修正问题; 2) 将多源域迁移 GPR 引入 eVTOL 动力电池 SOC 残差修正, 利用多个源域任务的残差信息改善目标域小样本条件下的标称 SOC 拟合效果; 3) 基于 GPR 预测不确定度设计多源子模型加权集成策略, 使最终估计结果能够综合不同源域模型的可靠性, 降低单一源域事先选择带来的不稳定性; 4) 结合 eVTOL 动力电池飞行任务数据开展迁移率扫描、子模型集成和消融对比实验, 并对标称 SOC 标签、样本划分和迁移适用边界进行讨论。

2 多源域迁移 GPR 残差修正方法

本文面向 eVTOL 动力电池飞行放电片段的 SOC 估计问题, 构建基于安时积分先验的多源域迁移高斯过程回归残差修正方法。该方法不直接以数据驱动模型输出最终 SOC, 而是首先依据容量计量和安时积分关系形成具有物理趋势约束的 SOC 先验, 再由迁移 GPR 模型学习先验估计与容量构造标称 SOC 之间的残差, 最后通过多源子模型的不确定度加权融合得到最终修正结果。由于本文数据未提供独立标定的真实 SOC, 以下方法和误差评价均以标称 SOC 为基准进行说明。

2.1 SOC 先验构建与残差定义

设某一飞行放电片段第 k 个采样点的端电压、电流、温度、累计放电容量和采样时刻分别为 $U_k, I_k, T_k, Q_{dis,k}$ 和 t_k 。设片段起始点累计放电容量为 $Q_{dis,0}$, 参考容量为 Q_{ref} , 则第 k 个采样点的标称 SOC 定义为

$$z_k = 1 - (Q_{dis,k} - Q_{dis,0}) / Q_{ref} \quad (1)$$

需要说明的是, 式 (1) 所得是基于容量计量构造的标称 SOC, 用于模型训练与仿真评价, 不等于由独立 OCV 标定或专门实验测量获得的真实 SOC。因此, 后文所述误差主要反映模型对该标称 SOC 的拟合和残差修正能力, 不能直接等同于实际 BMS 中相对于真实 SOC 的绝对估计误差。

在标称 SOC 基础上, 采用安时积分构造 SOC 先验。设放电电流取正, 采样间隔为 $\Delta t_k = t_k - t_{k-1}$, 库仑效率为 η , 且 Q_{ref} 以 Ah 为单位, 则安时积分先验可递推表示为

$$z_{cc,k} = z_{cc,k-1} - \frac{\eta I_{k-1} \Delta t_k}{3600 Q_{ref}}, \quad k = 1, 2, \dots, L \quad (2)$$

式中, $z_{cc,k}$ 为第 k 个采样点的安时积分 SOC 先验, L 为片段长度, 并且 $z_{cc,0} = z_0$ 。

考虑到所选用的开源数据 (数据介绍见本文的第二部分), 本文不直接训练模型预测标称 SOC, 而是学习标称 SOC 与安时积分先验之间的残差。残差及最终估计结果分别定义为

$$r_k = z_k - z_{cc,k} \quad (3)$$

$$\hat{z}_k = \text{clip}(z_{cc,k} + \hat{r}_k, 0, 1) \quad (4)$$

式中, 为训练阶段的残差标签, 为模型预测残差, 为修正后的 SOC 估计值。clip($\cdot$) 表示将估计值限制在 $[0, 1]$ 范围内, 以避免出现不符合 SOC 物理边界的结果。采用残差形式的目的, 是使 GPR 模型重点修正安时积分先验的局部偏差, 而不是完全由数据驱动模型重新学习 SOC 的整体递减趋势。

2.2 源域、目标域与迁移任务构造

为描述跨电池或跨飞行任务条件下的迁移建模过程, 共有 N 个源域数据集 $S_1, S_2, \dots, S_N$, 每个源域可对应一个电池文件、一个工况文件或一个与目标电池不同的飞行任务集合。目标域记为 T , 并划分为少量有标签训练样本、验证样本和测试样本。

设第 k 个采样点的输入特征向量为 x_k , 具体特征构造方式在数据集与实验设置部分给出。对于第 i 个源域, 其迁移任务定义为

对于第 i 个源域, 将源域训练样本与目标域少量训练样本共同构成一个迁移子任务:

$$D_i = \{(X_i^S, r_i^S), (X_{tr}^T, r_{tr}^T)\}, \quad i = 1, 2, \dots, N \quad (5)$$

其中 X_i^S 和 r_i^S 分别为第 i 个源域的输入特征和残差标签, X_{tr}^T 和 r_{tr}^T 为目标域少量训练样本的输入特征和残差标签。本文为每个源域分别训练一个迁移 GPR 子模型, 使模型能够在利用源域信息的同时, 通过少量目标域样本校正源域与目标域之间的分布差异, 并为后续多源加权集成提供子模型基础。

2.3 单源域迁移 GPR 残差模型

第 i 个迁移子任务中, 采用迁移高斯过程回归建立输入特征到残差标签之间的非线性映射。设残差函数 $f_i(x)$ 服从零均值高斯过程, 则有

$$f_i(x) \sim \mathcal{GP}(0, k_i(\cdot, \cdot)) \quad (6)$$

为描述源域样本与目标域样本之间的相关性, 引入域标识 d 。若两个样本来自同一域, 则采用标准平方指数核; 若两个样本来自不同域, 则通过迁移率 λ_i 对跨

域协方差进行缩放。核函数可表示为

$$k_{SE}(x, x') = \sigma_f^2 \exp\left(-\frac{|x - x'|^2}{2l^2}\right) \quad (7)$$

$$k_i((x, d), (x', d')) = \begin{cases} k_{SE}(x, x'), & d = d', \\ \lambda_i k_{SE}(x, x'), & d \neq d'. \end{cases} \quad (8)$$

其中 σ_f 为信号标准差, l 为核函数长度尺度, $\lambda_i \in [0, 1]$ 表示第 i 个源域与目标域之间的迁移相关程度。 λ_i 越大, 说明源域样本对目标域预测的贡献越强; λ_i 越小, 则模型更倾向于依赖目标域少量训练样本。该参数并不表示物理意义上的电池相似度, 而是迁移核函数中用于调节跨域协方差强度的超参数。

为避免迁移率取值完全依赖经验, 本文采用目标域验证误差确定。设候选集合 $\Lambda = \{0, 0.05, 0.10, \dots, 0.95\}$, 则每个源域子模型均在该集合内单独搜索其迁移率; 第 i 个源域子模型的迁移率由下式确定:

$$\lambda_i^* = \arg \min_{\lambda \in \Lambda} \text{RMSE}_{\text{val}}^{(i)}(\lambda) \quad (9)$$

式中, λ_i^* 表示给定迁移率时, 第 i 个迁移 GPR 子模型在目标域验证样本上的残差预测误差。通过式 (9) 确定迁移率, 可以使源域知识利用程度与目标域验证表现相对应, 从而降低负迁移风险。需要指出的是, 当目标域验证样本较少时, 迁移率选择仍可能受到样本划分影响, 因此本文在实验分析中结合固定扫描结果讨论其敏感性, 并将更大规模的多目标域验证作为后续工作。

训练完成后, 第 i 个迁移 GPR 子模型在测试样本 x_k 上输出残差预测均值和预测方差。其中 $\mu_{i,k}$ 表示该源域子模型给出的 SOC 残差修正量, $\sigma_{i,k}^2$ 反映该模型对当前样本预测的不确定性。

2.4 多源域不确定性加权集成

由于不同源域与目标域之间的相似性并不一致, 直接将所有源域样本合并为单一模型可能引入无关信息或负迁移。为此, 本文在获得多个单源迁移 GPR 子模型后, 根据各子模型的预测不确定度对其残差输出进行加权融合。对于第 j 个测试样本, 第 j 个子模型的权重定义为

$$w_{i,k} = \frac{(\sigma_{i,k}^2 + \varepsilon)^{-1}}{\sum_{j=1}^N (\sigma_{j,k}^2 + \varepsilon)^{-1}} \quad (10)$$

式中, ε 为防止分母为零的极小正数。若某一子模型对当前样本的预测方差较小, 说明其预测可信度较

高, 则对应权重较大; 反之, 若预测方差较大, 则其权重相应降低。最终残差预测值和 SOC 估计值分别为

$$\hat{r}_k = \sum_{i=1}^N w_{i,k} \mu_{i,k} \quad (11)$$

$$\hat{z}_k = \text{clip}(z_{\text{cc},k} + \hat{r}_k, 0, 1) \quad (12)$$

式 (10) 至式 (12) 体现了本文方法的多源集成含义, 每个源域对应一个残差子模型, 最终结果不是对各子模型 SOC 输出进行简单平均, 而是根据预测不确定度对各子模型的残差修正量进行自适应融合。

2.5 方法流程

综上, 本文所提方法的实现流程如下。首先, 对飞行放电数据进行片段划分, 并根据累计放电容量构造标称 SOC, 同时利用安时积分得到 SOC 先验; 其次, 以标称 SOC 与安时积分先验之间的差值作为残差标签, 构建源域和目标域样本; 再次, 将每个源域分别与目标域少量训练样本组成迁移子任务, 训练单源迁移 GPR 残差模型, 并通过目标域验证误差逐源域确定迁移率; 最后, 在目标域测试样本上获得多个子模型的残差预测均值和方差, 采用不确定度加权方式得到最终残差修正量, 并叠加到安时积分先验上形成 SOC 估计结果。

该流程在方法层面保留了安时积分的容量递减趋势, 同时利用多源迁移 GPR 学习跨任务残差信息, 并通过预测不确定度抑制不可靠源域对最终结果的影响。具体数据字段、输入特征构造、飞行工况编码、源域和目标域文件划分以及评价指标设置, 统一放在后续“数据集与实验设置”部分说明。需要强调的是, 本文结果的适用范围与所采用的公开数据字段和标称 SOC 构造方式密切相关。

3 数据集与实验设置

3.1 数据来源与文件说明

本文采用公开 eVTOL Battery Dataset 作为实验数据来源^[9]。该数据集由 Carnegie Mellon University 相关研究团队发布, 每个 CSV 文件记录一个锂离子电池在不同实验协议下的循环测试数据。与常规恒流放电数据不同, 该数据集包含模拟 eVTOL 任务的放电过程, 能够反映飞行任务中功率水平、巡航持续时间、充电策略和环境温度等因素变化对电池外部响应的影响。

3.2 输入特征构造与飞行工况表征

数据预处理时, 先根据循环编号和片段编号提取放电相关片段, 去除明显缺失、长度过短或字段异常的片段。考虑到不同文件采样点数和任务持续时间并不

完全一致, 本文不将完整任务持续时间作为在线输入, 而是按照统一长度构造片段样本; 若片段长度超过设定长度, 则按时间顺序截取样本, 若片段长度不足, 则不纳入训练和测试。样本划分在片段层面完成, 训练集、验证集和测试集不共享同一测试片段。输入特征归一化参数仅由源域训练样本和目标域训练样本统计得到, 并固定用于验证集和测试集, 迁移率选择只使用目标域验证集, 测试集不参与模型参数、迁移率或归一化统计量确定。

在第 2 节中, 输入特征统一记为 x_k 。本节给出其具体构造方式。对于第 k 个采样点, 本文从原始测量量和相邻采样点变化量中构造输入向量:

$$x_k = [z_{cc,k}, U_k, I_k, T_k, P_k, \Delta U_k, \Delta I_k, \Delta P_k, s_k]^T \quad (13)$$

式中, $z_{cc,k}$ 为安时积分 SOC 先验, U_k, I_k 和 T_k 分别为端电压、电流和温度, $P_k = U_k I_k$ 为瞬时功率; $\Delta U_k, \Delta I_k$ 和 ΔP_k 分别为端电压、电流和功率的一阶差分, 用于描述短时动态变化; s_k 为工况片段编码, 用于补充阶段性信息。

在该数据集中, 字段表示循环片段编号, 可用于区分测试过程中的不同片段。本文不将该字段简单等同于人工标注的“起飞、巡航、降落”标签, 而是将其作为工步或片段标识参与特征构造; 同时, 结合功率水平和功率变化率, 使模型能够从数据中识别不同任务阶段下残差变化的差异。若采用 one-hot 编码, 则不同 N_s 取值被映射为互斥的工况向量, 避免直接使用编号数值时引入不必要的大小顺序假设; 若采用归一化编号, 则其仅作为连续辅助变量输入。本文仿真中优先采用 one-hot 形式。

输入特征中加入 $z_{cc,k}$ 的目的, 是使模型学习安时积分先验的局部误差, 而不是从零开始拟合 SOC。加入功率及其变化量, 是为了反映 eVTOL 放电任务中的负载强度和切换过程; 加入温度和工况片段编码, 则用于补充热状态与阶段差异信息。上述特征均可由当前时刻或历史时刻测量量计算得到, 不依赖未来测试信息。

3.3 源域、目标域与样本划分

结合本文多源域迁移建模需求, 对比实验选取 VAH01、VAH06、VAH12、VAH13、VAH15 和 VAH16 作为源域文件, 选取 VAH30 作为目标域文件。其中, VAH01 为基准实验文件, VAH12 和 VAH13 对应较短巡航时间工况, VAH15 对应延长巡航时间工况, VAH06 和 VAH16 对应不同充电电流策略, VAH30

对应 35 °C 环境温度条件。选择 VAH30 作为主目标域, 主要是考虑其环境温度条件与常温源域文件存在差异, 可用于构造跨温度、跨任务的小样本目标域迁移场景。为避免结论仅依赖单一目标域划分, 本文进一步设置 leave-one-file-out 验证, 即轮流选取一个 VAH 文件作为目标域, 其余文件作为源域, 并在相同的特征构造、容量先验和残差修正流程下进行评价。

多源域迁移实验中, 每个源域文件单独训练一个迁移 GPR 子模型, 目标域少量训练样本用于建立源域与目标域之间的迁移关系。本文将 VAH01、VAH06、VAH12、VAH13、VAH15 和 VAH16 分别视为六个源域, 记为 S_1 至 S_6 ; 将 VAH30 作为目标域 T。目标域样本按片段顺序划分为训练集、验证集和测试集, 分别用于模型适配、迁移率选择和最终性能评价。测试样本仅用于最终统计, 不参与迁移率选择或模型参数调整。

在本文主对比仿真设置中, 目标域训练、验证和测试样本数量分别取 200、50 和 50。训练样本参与各单源迁移 GPR 子模型训练, 验证样本用于确定迁移率和相关模型参数, 测试样本仅用于最终结果统计。这样的划分方式能够模拟目标域标注数据较少而历史源域数据相对充足的应用情形, 也便于比较不同源域子模型及其集成结果的差异。需要说明的是, 测试样本数量较少, 所得结果可能受具体划分影响; 因此本文在第 4.5 节开展多目标域 leave-one-file-out 验证, 并在第 4.6 节通过不同目标域训练样本规模下的重复随机抽样进一步检验结果稳定性。

为保证对比公平, 所有方法使用相同的样本划分、相同的容量构造标称 SOC 和相同的输入特征。除特别说明外, 训练集、验证集和测试集之间不交叉使用, 测试阶段不再调整模型参数。本文的结论主要基于该统一划分下的相对性能比较, 而不将单次数值结果泛化为所有 eVTOL 电池任务下的绝对性能。

4 实验设计与结果分析

4.1 对比方法与评价指标

为验证多源域迁移 GPR 残差修正方法的有效性, 本文设置多组对比模型, 并在相同目标域、相同训练/验证/测试划分下进行比较。对比模型包括: 安时积分先验, 即仅利用安时积分结果作为 SOC 估计值, 不进行残差修正; 目标域 GPR 模型, 即仅使用目标域少量训练样本建立普通 GPR 残差模型; 样本合并 GPR 模型, 即将多个源域样本与目标域训练样本直接合并后建立普通 GPR 模型; 最佳单源迁移 GPR 模型, 即从各单源迁移 GPR 子模型中选取测试误差最低的模型; 平均

集成迁移 GPR 模型, 即对多个单源迁移模型的残差预测结果进行简单平均; 本文方法为多源迁移 GPR 残差修正方法, 根据各子模型预测不确定度进行加权融合。

除总体对比外, 本文还设置消融实验以分析关键模块的作用。消融项包括, 去除源域迁移, 仅采用目标域 GPR 模型, 以检验源域知识的贡献; 去除飞行阶段 one-hot 特征, 以分析工况片段信息对估计结果的影响; 将不确定度加权替换为简单平均集成, 以检验预测方差权重分配的作用; 去除安时积分先验, 直接由模型预测 SOC, 以验证物理先验和残差建模形式的必要性; 完整模型保留安时积分先验、源域迁移、工况特征和不确定度加权集成, 用作综合对照。

模型性能采用平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Square Error, RMSE)、最大绝对误差 (Maximum Absolute Error, MAXE)、平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE) 和决定系数进行评价, 定义如下:

$$MAE = \frac{1}{M} \sum_{k=1}^M |\hat{z}_k - z_k| \quad (14)$$

$$RMSE = \sqrt{\frac{1}{M} \sum_{k=1}^M (\hat{z}_k - z_k)^2} \quad (15)$$

$$MAXE = \max_{1 \leq k \leq M} |\hat{z}_k - z_k| \quad (16)$$

$$MAPE = \frac{100\%}{M} \sum_{k=1}^M \left| \frac{\hat{z}_k - z_k}{z_k} \right| \quad (17)$$

$$R^2 = 1 - \frac{\sum_{k=1}^M (z_k - \hat{z}_k)^2}{\sum_{k=1}^M (z_k - \bar{z})^2} \quad (18)$$

式中, M 为测试样本数, z_k 为第 k 个样本的容量构造标称 SOC, $\hat{z}_k$ 为模型估计 SOC, $\bar{z}$ 为测试样本标称 SOC 的平均值。MAE、RMSE 和 MAXE 越小, 表示相对于容量构造标称 SOC 的误差越低; R^2 越接

近 1, 说明模型对标称 SOC 变化的拟合程度越高。本文所有误差均以归一化 SOC 为量纲, 由于评价基准并非独立 OCV 标定或专门实验测得的真实 SOC, 相关误差不宜直接解释为实际 BMS 中相对于真实 SOC 的绝对估计误差。

4.2 总体性能对比

不同方法在 VAH30 目标域测试样本上的整体误差见表 1 和图 1。安时积分先验能够保持 SOC 随放电过程下降的基本趋势, 但由于参考容量、初始值和局部工况变化等因素影响, 其相对于容量构造标称 SOC 的残差仍较为明显。在安时积分先验基础上进行残差修正后, MAE 由 0.0055 降至 0.0003, RMSE 由 0.0059 降至 0.0010, 分别降低约 94.9% 和 83.3%。上述改善说明模型能够更好地逼近容量构造标称 SOC, 但并不表示已经验证了相对于独立真实 SOC 的绝对估计精度。

与仅使用目标域少量样本的 GPR 相比, 所提方法在主对比实验中的 RMSE 降低约 26.8%; 与样本合并 GPR 模型相比, RMSE 降低约 2.8%。最佳单源迁移 GPR 模型的 RMSE 略低于多源集成结果, 但该结果依赖事后选择最优源域, 实际应用中通常无法预先确定哪个源域最适合当前目标任务。因此, 多源集成的意义不在于每次都超过事后最佳单源模型, 而在于不预先指定某一个源域, 使多个源域子模型依据预测不确定度共同参与目标域残差估计, 从而降低源域选择风险。该结论与本文将创新性定位为“数据条件受限下的工程适配和残差修正框架”是一致的。

4.3 典型片段与逐片段误差分析

图 2 给出了目标域典型测试片段中的 SOC 估计曲线。可以看出, 安时积分先验与容量构造标称 SOC 的整体变化趋势基本一致, 说明安时积分能够较好反映片段内 SOC 的长期下降过程; 但在部分时刻, 先验曲线与标称 SOC 之间仍存在一定偏差。这说明所提方法并非替代安时积分先验, 而是在其提供的长期趋势基础上进行局部残差补偿, 从而提高相对于容量构造标称 SOC 的拟合精度。

表 1 VAH30 目标域下不同 SOC 估计模型的误差对比 (相对于容量构造标称 SOC)

模型	MAE	RMSE	MAXE	MAPE/%	R^2
安时积分先验	0.005476	0.005904	0.006753	0.7558	0.997908
目标域 GPR 模型	0.000368	0.001344	0.007215	0.0483	0.999892
样本合并 GPR 模型	0.000623	0.001013	0.008422	0.0783	0.999938
最佳单源迁移 GPR 模型	0.000281	0.000934	0.005701	0.0374	0.999948
平均集成迁移 GPR 模型	0.000281	0.000989	0.005174	0.0368	0.999941
多源迁移 GPR 残差修正方法	0.000279	0.000984	0.005154	0.0366	0.999942




图1 VAH30 目标域下不同 SOC 估计模型的 MAE 与 RMSE 对比




图2 VAH30 目标域典型测试片段 SOC 估计曲线

逐片段统计结果如图 3 所示。在 30 个测试片段中, 有 29 个片段的多源迁移 GPR 残差修正方法 RMSE 低于安时积分先验。多数片段中, 模型 RMSE 集中在 4.0×10^{-4} 左右, 而安时积分先验的 RMSE 多在 6.0×10^{-3} 附近。第 22 个测试片段的模型 RMSE 为 0.0050, 明显高于其他片段, 说明局部工况突变或片段边界仍可能导致残差估计误差增大。

4.4 迁移率与多源集成分析

图 4 给出了以 VAH06 为源域、VAH30 为目标域时, 不同固定迁移率下的目标域 RMSE 变化曲线。可以看出, 随着 λ 从 0 增大到 0.95, RMSE 由 0.001337 降至 0.000882, 整体呈下降趋势。该结果表明, 在该源

域-目标域组合下, 适当增强源域样本与目标域样本之间的相关性有利于改善残差估计精度; 同时也说明 λ 不是任意设定的经验参数, 而是通过目标域验证误差扫描得到的迁移核超参数。需要注意的是, 单个源域的扫描结果不能代表全部源域组合, 因此本文进一步给出各源域子模型的 λ 与测试误差对比。

单源子模型的最优 λ_i 和测试误差见表 2 和图 5。六个源域子模型的最优 λ_i 主要分布在 0.90 至 0.95 之间, 说明源域数据并非完全无关; 但各子模型 RMSE 仍存在差异, 其中 VAH16 子模型 RMSE 最低, 为 0.000934, VAH06 子模型 RMSE 最高, 为 0.001050。因此, 多源集成不宜简单假定所有源域贡献相同, 而应

结合预测不确定度调整各子模型权重。若某一源域在当前测试样本上的预测方差较小, 则其残差修正量在

融合中占更大权重; 反之, 预测方差较大的子模型会被赋予较小权重。




图3 VAH30 目标域逐测试片段 RMSE 分布

表2 各源域迁移 GPR 子模型的迁移率与测试误差 (VAH30 为目标域)

源域子模型	最优迁移率 λ_i	RMSE
VAH01	0.95	0.001006
VAH12	0.90	0.001023
VAH13	0.90	0.000970
VAH15	0.95	0.000998
VAH06	0.95	0.001050
VAH16	0.95	0.000934




图4 固定 λ 扫描下的 VAH30 目标域 RMSE 曲线 (以 VAH06 为源域)




图5 VAH30 目标域下各源域子模型迁移率与 RMSE 对比

4.5 多目标域 leave-one-file-out 验证

为考虑单一目标域实验代表性不足的问题, 进一步开展多目标域 leave-one-file-out 验证。实验中依次将 VAH01、VAH12、VAH13、VAH15、VAH06、VAH16 和 VAH30 作为目标域, 其余 6 个文件作为源域; 每个目标域按片段顺序选取少量样本用于迁移适配, 其后的 30 个片段作为测试片段。除目标域文件轮换外, SOC 先验构造、输入特征、迁移 GPR 子模型训练、迁移率选择和不确定度加权融合方式均与前述实验保持一致。

由表 3 可见, 轮流更换目标域后, 所提方法在 7 个目标域文件上的 RMSE 均低于安时积分先验。各目标域的多源迁移 GPR 残差修正方法 RMSE 分布在 0.000094 至 0.000561 之间, 平均 RMSE 为 0.000305; 相较于安时积分先验, 平均 RMSE 降低约 94.15%。该结果说明, 在不同飞行任务文件作为目标域时, 基于容量先验的多源域迁移残差修正仍能保持较稳定的局部误差补偿能力。需要说明的是, 该实验仍以容量构造标称 SOC 为评价基准, 主要用于支撑跨文件任务适配能力, 而不直接等同于真实 SOC 在线估计精度验证。

表 3 多目标域 leave-one-file-out 验证结果

目标域	源域数	训练/测试片段	安时积分先验 RMSE	本文方法 RMSE	RMSE 降幅/%
VAH01	6	80/30	0.005244	0.000401	92.35
VAH12	6	80/30	0.003124	0.000139	95.56
VAH13	6	80/30	0.003621	0.000159	95.61
VAH15	6	80/30	0.004797	0.000094	98.05
VAH06	6	80/30	0.005961	0.000503	91.56
VAH16	6	80/30	0.005928	0.000561	90.53
VAH30	6	80/30	0.005986	0.000276	95.40
均值	6	80/30	0.004952	0.000305	94.15

表 4 目标域训练样本规模敏感性实验结果

训练样本点数	重复次数	安时积分先验 RMSE	本文方法 RMSE	RMSE 降幅/%
20	3	0.005926	0.000905±0.000102	84.729495±1.717488
50	3	0.005926	0.000681±0.000223	88.500291±3.767287
100	3	0.005926	0.000367±0.000246	93.806738±4.152377
200	3	0.005926	0.000243±0.000163	95.891455±2.755569

4.7 消融实验分析

消融实验结果见表 5 和图 6。直接 SOC 回归模型的误差明显增大, RMSE 达到 0.0297, 说明在当前数据条件下直接从输入特征拟合 SOC 并不稳定; 相比之下, 以安时积分为先验并学习残差, 能够显著降低模

4.6 目标域训练样本规模敏感性分析

为进一步检验结果是否依赖固定目标域样本规模, 本文以 VAH30 为目标域、VAH01、VAH12、VAH13、VAH15、VAH06 和 VAH16 为源域, 开展目标域训练样本点数敏感性实验。实验保持 SOC 先验构造、输入特征、源域抽样规模、迁移 GPR 子模型训练和不确定度加权融合方式不变, 仅改变目标域用于迁移适配的训练样本点数, 分别取 20、50、100 和 200。每种样本规模下进行 3 次随机抽样, 测试集保持一致, 并统计评价指标的均值和标准差。

由表 4 可见, 在 20、50、100 和 200 个目标域训练样本点条件下, 所提方法的平均 RMSE 分别为 0.000905、0.000681、0.000367 和 0.000243, 均明显低于对应的安时积分先验 RMSE。随着目标域训练样本点数增加, 模型平均误差整体呈下降趋势, RMSE 降幅由 84.73%提高至 95.89%。同时, 各组标准差表明随机抽样仍会带来一定波动, 特别是在样本规模较小或局部片段分布差异较明显时, 估计结果可能受样本选择影响。因此, 本文将样本规模敏感性结果作为稳定性补充验证, 而不将单一划分下的最优结果作为唯一依据。

型学习难度。这一结果表明, 安时积分先验是本文框架中最关键的基础模块。

消融结果也显示, 并非所有简化模型都会在当前划分下变差。例如, 仅使用目标域训练样本的 GPR 在该组消融实验中取得了较低 RMSE, 这可能与 VAH30

目标域训练样本和测试样本局部分布较接近有关。该现象提示, 迁移模型的优势不宜表述为任何划分下均最优, 而应理解为, 当目标域样本不足或覆盖范围有限时, 多源域残差模型提供了一种利用历史任务信息的建模方式; 不确定度加权则用于减弱不可靠子模型对

最终结果的影响。结合表 3 的多目标域结果和表 4 的样本规模敏感性结果, 本文方法在跨文件目标域和不同目标样本规模下均表现出较稳定的残差补偿能力, 在后续工作中其泛化边界仍需在更多电池、更多温度条件和更严格片段隔离条件下继续验证。

表 5 消融实验结果

模型	MAE	RMSE	MAXE	MAPE/%	R ²
按时积分先验	0.005476	0.005904	0.006753	0.7558	0.997908
无迁移: 目标域 GPR 模型	0.000328	0.000582	0.004278	0.0433	0.999980
无阶段标识	0.000270	0.000955	0.005194	0.0352	0.999945
无不确定度加权: 平均集成迁移 GPR 模型	0.000281	0.000989	0.005174	0.0368	0.999941
无按时积分先验	0.023880	0.029666	0.129596	3.2198	0.947189
完整模型	0.000279	0.000984	0.005154	0.0366	0.999942




图 6 VAH30 目标域下消融实验 RMSE 对比

4.8 本章小结

本章在统一的数据划分和评价指标下验证了所提多源迁移 GPR 残差修正方法。主对比结果表明, 该方法能够降低按时积分先验相对于容量构造标称 SOC 的误差, 并在目标域小样本 GPR 和样本合并 GPR 模型基础上进一步改善 RMSE。典型片段和逐片段结果说明, 残差修正在大多数测试片段上有效, 但局部片段仍可能出现误差放大的情况。迁移率扫描和子模型对比表明, 不同源域对目标域的适配程度不同, 采用不确定度加权集成比简单指定单一源域更符合多源迁移建模需求。Leave-one-file-out 验证和目标域样本规模敏感性实验进一步说明, 所提方法在多个目标文件和不同目标训练样本规模下具有一定稳定性; 但本文误差评价仍以容量构造标称 SOC 为基准, 结论仍限定在

现有公开数据和仿真设置范围内。

5 结论

本文针对公开 eVTOL 动力电池数据中 OCV 曲线、HPPC 参数和等效电路辨识条件不足的问题, 提出了一种多源迁移 GPR-SOC 估计方法。该方法以按时积分结果作为 SOC 先验, 将容量构造标称 SOC 与先验 SOC 之间的偏差作为残差学习对象, 并通过多个源域迁移 GPR 子模型对目标域 SOC 进行修正。仿真结果表明, 在现有数据条件下, 按时积分能够提供较稳定的 SOC 变化趋势, 但仍存在一定局部偏差; 引入迁移 GPR 残差修正和不确定度加权集成后, 可在主目标域、多目标域 leave-one-file-out 验证和不同目标域样本规模条件下改善对标称 SOC 的拟合效果。需要指出的是, 本文方法并非提出新的 SOC 基础理

论或新的 GPR 基础模型, 其主要价值在于面向 eVTOL 公开任务数据条件受限场景, 提供一种由容量先验、残差学习、多源迁移和不确定度融合构成的可实现修正框架。由于本文误差评价对象为容量计量得到的标称 SOC, 后续仍需结合独立 OCV 标定、HPPC 参数辨识或 BMS 实测 SOC 数据, 进一步验证其在真实在线估计场景中的绝对精度和工程适用性。

参考文献

- [1] Xiao J Q, Salk N, Haran K. Conceptual design of an eVTOL air shuttle for rapid intercity transport[C]. Urbana-Champaign: 2020 IEEE Power and Energy Conference at Illinois, 2020.
- [2] 赵志斌, 袁鸿明, 刘炳辰, 等. eVTOL 飞行器电池 SOC 估计: 内嵌等效电路模型的神经网络[J]. 推进技术, 2026(006): 047.
- [3] Zhou Q, Tan F. Avionics of electric vertical take-off and landing in the urban air mobility: a review[J]. IEEE Aerospace and Electronic Systems Magazine, 2024, 39: 1-26.
- [4] Phung M T, Nguyen T C H, Akhtar M S, et al. Machine learning approaches for assessing rechargeable battery state-of-charge in unmanned aircraft vehicle-eVTOL[J]. Journal of Computational Science, 2024, 81: 102380.
- [5] Hannan M A, Lipu M S H, Hussain A, et al. A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations[J]. Renewable and Sustainable Energy Reviews, 2017, 78: 834-854.
- [6] How D N T, Hannan M A, Lipu M S H, et al. State of charge estimation for lithium-ion batteries using model-based and data-driven methods: A review[J]. IEEE Access, 2019, 7: 136116-136136.
- [7] Xiong R, Cao J, Yu Q, et al. Critical review on the battery state of charge estimation methods for electric vehicles[J]. IEEE Access, 2018, 6: 1832-1843.
- [8] He W, Williard N, Chen C, et al. State of charge estimation for electric vehicle batteries using unscented Kalman filtering[J]. Microelectronics Reliability, 2013, 53(6): 840-847.
- [9] Van C N, Quang D T. State of charge estimation for Lithium-Ion battery cell considering the influence of aging parameters and operating temperature[J]. International Journal of Electrochemical Science, 2023, 18(12): 100379.
- [10] Yang L, He M, Ren Y, et al. State of charge estimation for lithium-ion batteries via a diffusion-enhanced equivalent circuit model and an improved extended Kalman filter[J]. Energy, 2026, 345: 140181.
- [11] Hu X, Li S, Peng H. A comparative study of equivalent circuit models for Li-ion batteries[J]. Journal of Power Sources, 2012, 198: 359-367.
- [12] Shen H, Zhou X, Wang Z, et al. State of charge estimation for lithium-ion battery using Transformer with immersion and invariance adaptive observer[J]. Journal of Energy Storage, 2022, 45: 103768.
- [13] Liu Y, Shu X, Yu H, et al. State of charge prediction framework for lithium-ion batteries incorporating long short-term memory network and transfer learning[J]. Journal of Energy Storage, 2021, 37: 102494.
- [14] Deng Z, Hu X, Lin X, et al. Data-driven state of charge estimation for lithium-ion battery packs based on Gaussian process regression[J]. Energy, 2020, 205: 118000.
- [15] Liu Y, Li J, Zhang G, et al. State of charge estimation of lithium-ion batteries based on temporal convolutional network and transfer learning[J]. Ieee Access, 2021, 9: 34177-34187.
- [16] Yang Y, Zhao L, Yu Q, et al. State of charge estimation for lithium-ion batteries based on cross-domain transfer learning with feedback mechanism[J]. Journal of Energy Storage, 2023, 70: 108037.
- [17] Wang Y X, Chen Z, Zhang W. Lithium-ion battery state-of-charge estimation for small target sample sets using the improved GRU-based transfer learning[J]. Energy, 2022, 244: 123178.
- [18] Xiao F, Li C, Fan Y, et al. State of charge estimation for lithium-ion battery based on Gaussian process regression with deep recurrent kernel[J]. International Journal of Electrical Power & Energy Systems, 2021, 124: 106369.
- [19] Bills A, Sripad S, Fredericks L, et al. A battery dataset for electric vertical takeoff and landing aircraft[J]. Scientific Data, 2023, 10(1): 344.

版权声明: ©2026 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

<https://creativecommons.org/licenses/by/4.0/>



OPEN ACCESS