



多特征融合的MVMD-VSN_GRU锂离子电池健康状态预测方法研究

吴康佳¹, 姬钰培¹, 冀鹏宇¹, 袁泽宇², 崔方舒¹, 乔钢柱¹

(¹中北大学计算机科学与技术学院, 山西太原 030051; ²中北大学极限环境光电动态测试技术与仪器全国重点实验室, 山西太原 030051)

摘要: 在新能源汽车、大规模储能电站等领域快速发展的背景下, 精准预测锂离子电池健康状态 (state of health, SOH) 对于保障电池系统安全稳定运行以及延长服役寿命具有重要意义。针对锂离子电池健康状态直接性能参数获取困难, 以及传统时序预测模型中单一变量预测精度偏低、多变量权重固定导致SOH预测精度受限的问题, 文章提出一种基于变量选择网络 (variable selection network, VSN) 与门控循环单元 (gated recurrent unit, GRU) 的多特征融合的锂离子电池SOH预测模型。该方法从电池充放电循环数据中提取与SOH高度相关的健康因子 (health indicator, HI) 构成多元特征序列, 采用多元变分模态分解对此多特征序列进行协同自适应分解, 以充分提取并保留变量间的耦合时频特征。在每个分解得到的多元子序列上, 构建基于袋獾优化算法超参数寻优的VSN_GRU模型, 实现对关键健康因子的动态感知与建模预测。最后, 将各分解分量的预测结果叠加求和得到最终SOH预测值。在NASA电池数据集与WZU随机电池退化数据上的实验结果表明, 相较于消融实验中的对比模型, 文中模型可有效提升锂离子电池SOH的预测精度。

关键词: 锂离子电池; 健康状态; 多元变分模态分解; 变量选择网络; 门控循环单元

doi: 10.19799/j.cnki.2095-4239.2026.0198

中图分类号: TM912

文献标志码: A

文章编号: 2095-4239 (XXXX) XX-1-14

Research on State of Health Prediction Method of Lithium-Ion Batteries Based on Multi-Feature Fusion MVMD-VSN_GRU

WU Kangjia¹, JI Yupei¹, JI Pengyu¹, YUAN Zeyu², CUI Fangshu¹, QIAO Gangzhu¹

(¹School of Computer Science and Technology, North University of China, Taiyuan 030051, Shanxi China;

²State key Laboratory of Extreme Environment Optoelectronic Dynamic Measurement Technology and Instrument, North University of China, Taiyuan 030051, Shanxi, China)

Abstract: Against the backdrop of the rapid development of new energy vehicles, large-scale energy storage power stations and other fields, the accurate prediction of the state of health (SOH) of lithium-ion batteries is of great significance for ensuring the safe and stable operation of battery systems and extending their service life. Aiming at the difficulties in directly acquiring the performance parameters of lithium-ion battery state of health, as well as the limited SOH prediction accuracy of traditional time-series prediction models caused by low single-variable prediction precision and fixed multi-variable weights, this paper proposes a multi-feature fusion lithium-ion battery SOH prediction model based on the variable selection

收稿日期: 2026-03-10; 修改稿日期: 2026-04-29。

基金项目: 山西省基础研究计划 (202303021222084); 山西省基础研究计划 (202303021222120)。

第一作者: 吴康佳 (2001—), 女, 硕士研究生, 研究方向为储能电池健康管理, E-mail: kja0215@163.com; 通信作者: 乔钢柱, 教授, 研究方向为物联网技术及应用、大数据处理技术等, E-mail: qiaogz@nuc.edu.cn。

引用本文: 吴康佳, 姬钰培, 冀鹏宇, 等. 多特征融合的MVMD-VSN_GRU锂离子电池健康状态预测方法研究[J]. 储能科学与技术, XXXX, XX(XX): 1-14.

Citation: WU Kangjia, JI Yupei, JI Pengyu, et al. Research on State of Health Prediction Method of Lithium-Ion Batteries Based on Multi-Feature Fusion MVMD-VSN_GRU[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-14.

network (VSN) and gated recurrent unit (GRU). Health indicators (HIs) highly correlated with SOH are extracted from battery charge-discharge cycle data to form a multivariate feature sequence, which is then adaptively decomposed collaboratively via multivariate variational mode decomposition to fully extract and preserve the coupled time-frequency features among variables. For each decomposed multivariate subsequence, a VSN_GRU model with hyperparameter optimization by the Tasmanian devil optimization algorithm is constructed to realize dynamic perception, modeling and prediction of key HIs. Finally, the final SOH prediction value is obtained by superposing and summing the prediction results of all decomposed components. Experimental results on the NASA battery dataset and WZU random battery degradation dataset demonstrate that compared with the comparison models in ablation experiments, the proposed model can effectively improve the prediction accuracy of lithium-ion battery SOH.

Keywords: lithium-ion battery; health state; multivariate variational mode decomposition; variable selection network; gated recurrent unit

在全球能源转型加速与新能源产业蓬勃发展的背景^[1]下, 锂离子电池凭借高能量密度、低自放电率及长循环寿命等核心优势, 已成为电子设备、电动汽车及储能系统的核心动力支撑^[2]。锂离子电池的性能稳定性与使用寿命也受到了广泛关注, 我们对其健康状态 (state of health, SOH)^[3-4]的精准评估需求日益迫切。

然而锂离子电池在充放电过程中, 内部会伴随着锂离子脱嵌、电极材料结构演变及固态电解质界面膜生长等复杂的物理化学变化^[5], 这些变化会使电池阻抗升高、容量衰减, 进而导致性能退化。因此, 精准预测电池 SOH, 可为用户制定科学的使用与维护方案^[6]提供依据, 对延长电池寿命具有重要意义^[7]。

此外, 当前锂离子电池 SOH 预测研究多以容量、内阻为单一健康因子 (health indicator, HI), 但这些 HI 在实际场景中难以直接提取。相比之下, 提取电压、电流、温度等易采集参数构建多特征间接 HI, 可全面表征电池退化特性, 有效规避单一 HI 无法反映的局部退化信息, 有效提升预测可靠性^[8]。

目前, 锂离子电池 SOH 预测研究主要分为基于机理模型^[9]与数据驱动^[10-13]的方法。由于锂离子电池结构复杂且性能退化存在显著不确定性, 基于机理模型的方法不仅精确建模难度大、所需参数多, 还难以全面涵盖环境、负载等各类影响因素^[14]。而数据驱动方法^[15-19]依托电池运行数据, 无需依赖电

池内部物理化学机理的精确认知, 其中, 循环神经网络^[20], 特别是门控循环神经网络^[21-23] (gated recurrent unit, GRU), 擅长处理复杂非线性数据, 通过神经网络从原始数据中提取多层次特征实现对时间序列的精准预测, 具备强大的非线性建模能力与较好的泛化性能。但是, 传统 GRU 模型在处理锂电池多维 HI 时, 对电池电压、电流、温度等特征的重要性缺乏区分能力, 导致模型对关键 HI 的学习不足, 预测精度受限。为此, 本文将时域融合 Transformers (temporal fusion transformers, TFT)^[24]中的变量选择网络 (variable selection network, VSN) 与 GRU 相结合, 使其兼具 VSN 的动态变量筛选能力与 GRU 的时序建模优势。

从电池充放电数据中提取的、与 SOH 强相关的多维间接 HI, 往往具有非平稳、非线性的信号特性。传统单维度信号分解方法^[25]在处理多维 HI 时, 不仅需要对各维度特征逐一重复分解, 还会破坏不同特征间的内在关联性。为此, 本文引入多元变分模态分解^[26] (multivariate variational mode decomposition, MVMD), 对多维 HI 开展协同分解, 既保留了不同特征间的固有关联, 又维持了数据的整体一致性。针对传统超参数寻优方法效率低下、易陷入局部最优解的缺陷, 本文进一步引入袋獾优化算法^[27] (tasmanian devil optimization, TDO) 对模型超参数进行全局寻优, 从而有效规避局部最优陷阱, 获取全局最优超参数组合, 最终显著提升预测精度^[28]。

综上，文中提出了一种多特征融合的MVMD-VSN_GRU锂离子电池健康状态预测方法，首先从电池数据集的电流、电压、温度等时序数据中，提取与SOH具有较高相关性的HI并构建多维特征序列；其次采用MVMD对多特征时间序列进行信号分解，提升预测精度；接着对不同分辨率的分解信号，分别采用经TDO超参数寻优的VSN_GRU模型进行建模，融合各模型预测结果得到SOH预测值；最后分别基于NASA电池数据集与WZU随机电池退化数据开展实验，验证所提方法的可行性与优越性。

1 实验数据及特征提取

1.1 数据集介绍

文章选取两类锂离子电池数据集开展研究，分别为美国国家航空航天局（NASA）研制的18650型2Ah锂离子电池数据集（数据集A），以及温州大学联合南卡罗来纳大学、巴黎矿校团队开发的WZU随机电池退化数据（wenzhou randomized battery data）^[29]（数据集B）。

1.1.1 数据集A

数据集A源自NASA PCoE的首批公开数据，实验对象为标称容量2Ah的18650锂离子电池，包含B0005（B05）、B0006（B06）和B0007（B07）三块电池的充放电老化测试数据，该批次电池的正极材料为钴酸锂/镍钴铝酸锂，负极材料为石墨，额定电压为4.2V。电池具体测试流程如下：首先以1.5A恒流充电至4.2V，随后切换至恒压充电模式，直至充电电流降至20mA停止充电；充电完成后，以2A恒流进行放电，其中三块电池的放电截止电压分别设定为2.7V、2.5V和2.2V，当电池实际容量较初始容量下降30%时，终止整个老化测试实验。其容量衰退曲线如图1所示。

1.1.2 数据集B

数据集B是当前全球规模最大、最贴近实际应用场景且持续时间最长的电池退化实验数据集。该数据集涵盖300个电池单体在实验室与实际应用场景下的性能退化数据，包括150个标称容量1Ah的A型电池和150个标称容量0.8Ah的B型电池。标准模式实验条件下采用恒流-恒压（CC-CV）方式以1C电流充电至4.2V，再恒压至电流降至1/4C；放电则以1C恒流（CC）进行至2.7V。本文






图1 NASA数据集电池容量衰退曲线
Fig. 1 Battery Capacity Fade Curve of NASA

选取标准模式下标称容量为1Ah的电池中01号（WZU_A01）、44号（WZU_A44）电池与标称容量为0.8Ah的电池中18号（WZU_B18）、49号（WZU_B49）和51号（WZU_B51）电池进行分析，其容量衰退曲线如图2所示。



(a) WZU_A组电池容量衰退曲线



(b) WZU_B组电池容量衰退曲线

图2 WZU数据集电池容量衰退曲线
Fig. 2 Battery Capacity Fade Curve of WZU

1.1.3 SOH定义

本文通过健康状态SOH来确定电池的老化程度，其定义为电池容量下降的百分比，如公式（1）所示：

$$SOH = \frac{C_{\text{actual}}}{C_{\text{rated}}} \times 100\% \quad (1)$$

其中， C_{actual} 和 C_{rated} 分别表示锂电池当前的实

际可用容量和电池额定容量。

1.2 特征提取及相关性分析

针对数据集A与数据集B的特性差异,分别开展特征提取及相关性分析,筛选与SOH高度相关的HI用于预测模型构建。

1.2.1 数据集A特征提取及相关性分析

随着充放电循环次数增加,电池内部活性物质持续消耗,导致充放电过程中电压、温度及电流曲线呈现规律性变化。以B05电池为例,其充放电过程中电压、温度及电流曲线如图3所示。

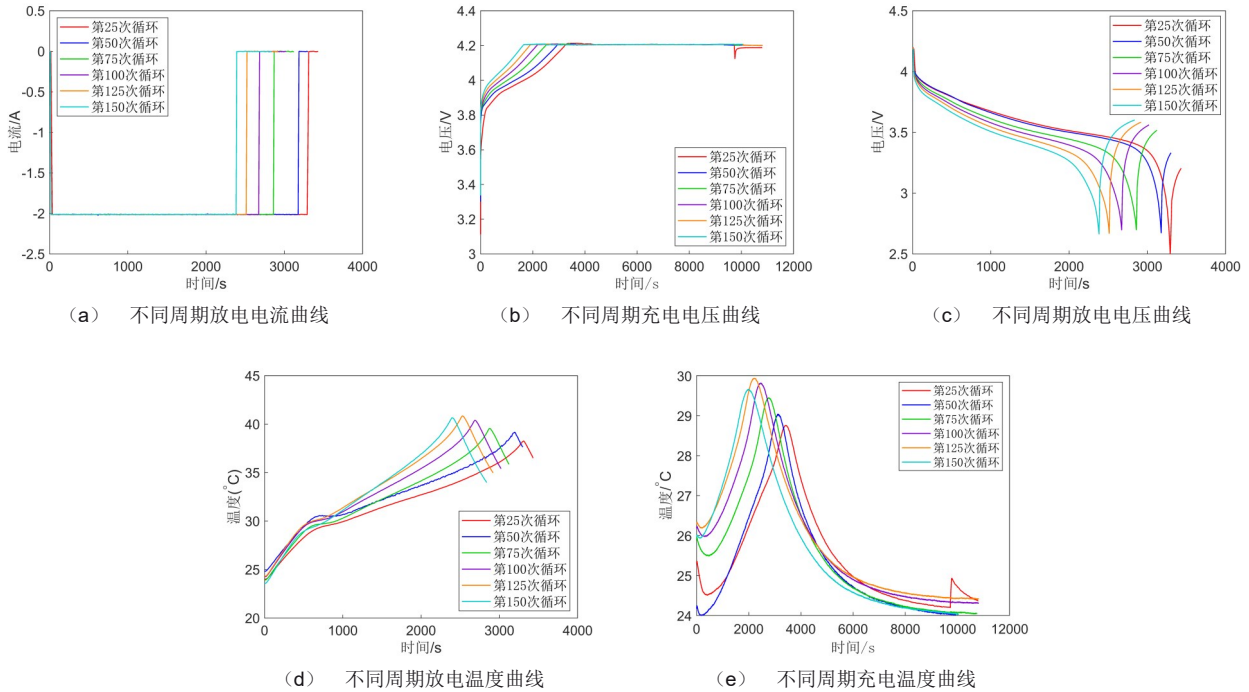


图3 不同循环次数下充放电电流电压温度变化图(数据集A)

Fig. 3 Variations of Charge-Discharge Current, Voltage and Temperature under Different Cycle Numbers (Dataset A)

由图3中曲线特征可知,充电电压在3.8 V-4.2 V区间变化最为显著,据此计算每次循环中该区间的平均电压上升速率,定义为充电电压上升速率(charging voltage rise rate, CVRR);放电过程中,计算电池从4.2 V降至截止电压的全程电压平均下降速率,作为放电电压下降速率(discharging voltage drop rate, DVDR)。充电电流遵循先恒流后恒压的规律:先以1.5 A恒定电流充电,电压升至4.2 V后转为恒压充电,直至电流降至0.02 A,放电过程以2 A恒定电流进行至切断电压,提取该过程中从2 A到切断电压对应的放电电流上升速率(discharging current rise rate, DCRR)。在温度变化方面,充放电过程中温度均随时间逐步升高,且循环次数增加会使电池达到峰值温度的速度显著加快,据此分别提取充电过程峰值温度上升速率(charging temperature rise rate,

CTRR)与放电过程峰值温度上升速率(discharging temperature rise rate, DTRR)。

文中通过计算所提取指标与SOH的皮尔逊相关系数来量化它们之间的相关性,结果如表1所示。从中可以发现, DVDR、DCRR、CTRR、DTRR与SOH相关系数的绝对值均大于99%,而CVRR达到了97%,表明了这5个指标与SOH具有极强的相关性,因此本文选用其作为数据集A电池SOH预测的间接HI。

1.2.2 数据集B特征提取及相关性分析


数据集B选取温州大学公开数据中标准模式下的B型锂电池,确定49号与51号电池为分析样本。以充放电循环过程的时序数据为基础开展特征提取,首先对两款电池全生命周期的原始充放电曲线进行分段处理,按循环周期截取各阶段的电流和电压时序数据,计算每个循环阶段的平均电流和平均

表1 NASA数据集提取指标相关性分析


Table 1 Correlation Analysis of Extracted Indicators from the NASA Dataset

数据集 指标	CVRR	DVDR	DCRR	CTRR	DTRR
B05	-0.9742	0.9966	0.9969	-0.9914	-0.9961
B06	-0.9431	0.9905	0.9796	-0.9711	-0.9868
B07	-0.9698	0.9987	0.9978	-0.9872	-0.9942

电压值，构建特征向量用于后续分析。以49号电池为例，其充电过程的电压和电流曲线如图4所示。



(a) 不同周期充电电流曲线



(b) 不同周期充电电压曲线

图4 不同循环次数下充放电电流电压温度变化图(数据集B)

Fig. 4 Variations of Charge-Discharge Current, Voltage and Temperature under Different Cycle Numbers(Dataset B)

图4中的曲线分析结果表明，随着循环次数增加，充电电流和充电电压的变化规律与数据集A保持一致。本研究提取平均电流（average current, AC）和平均电压（average voltage, AV）分别在恒流充电阶段与恒压充电阶段提取，并计算其与SOH的皮尔逊相关系数如表2所示。结果显示，AC与AV和SOH的相关系数均高于90%，因而确定AC与AV作为数据集B电池健康状态评估的HI。

表2 WZU随机电池退化数据提取指标相关性分析

Tab.2 Correlation Analysis of Extracted Indicators from the Wenzhou Randomized Battery Data

数据集\指标	AC	AV
WZU_A01	0.9842	-0.9856
WZU_A44	0.9924	-0.9116
WZU_B01	0.9896	-0.9513
WZU_B49	0.9901	-0.9439
WZU_B51	0.9900	-0.9440

2 理论

2.1 多元变分模态分解

MVMD是变分模态分解（variational mode decomposition, VMD）的扩展形式，它适用于多元时间序列信号分解，旨在从多通道数据中分离出具有跨通道同步特性的固有模态函数（intrinsic mode functions, IMF），以此规避单通道独立分解引发的模态分量错位问题^[26]。MVMD核心是最小化所有通道IMF的带宽之和，同时满足所有IMF重构原始信号的约束。数学表达式如（1）所示：

$$\min_{\{\mathbf{u}_{k,c}\}, \{\omega_k\}} \sum_{k=1}^K \sum_{c=1}^C \left\| \partial_t [\mathbf{u}_{k,c}^+(t) e^{-j\omega_k t}] \right\|_2^2 \text{ s.t. } \sum_{k=1}^K \mathbf{u}_{k,c}(t) = x_c(t) \quad c = 1, 2, \dots, C \quad (2)$$

式中： $\mathbf{u}_{k,c}(t)$ 第c通道第k个IMF； $\mathbf{u}_{k,c}^+(t)$ 为第c通道中第k个IMF的振荡解析信号； ω_k 为 $\mathbf{u}_{k,c}(t)$ 的中心频率； $x_c(t)$ 为第c通道的输入数据。

最终MVMD分解过程如下：

第一步：初始化：输入原始多通道信号 $x_c(t)$ ；初始化分解组数K，惩罚参数 α 等所需参数。

第二步：对原始多通道信号 $x_c(t)$ 进行离散傅里叶变换，得到 $\hat{x}_c(\omega)$ 。

第三步：迭代更新：由于时域求导和卷积运算在傅里叶域可转化为简单的乘法运算，MVMD通常在傅里叶域进行迭代求解。

①IMF分量的更新

$$\hat{\mathbf{u}}_{k,c}^{(n+1)}(\omega) = \frac{\hat{x}_c(\omega) - \sum_{i=1}^K \hat{\mathbf{u}}_{i,c}^{(n)}(\omega)}{1 + 2\alpha(\omega - \omega_k^{(n)})^2} + \frac{\hat{\lambda}_c^{(n)}(\omega)}{1 + 2\alpha(\omega - \omega_k^{(n)})^2} \quad (3)$$

②中心频率的更新

$$\omega_k^{(n+1)} = \frac{\int_0^\infty \omega \cdot \sum_{c=1}^C |\hat{\mathbf{u}}_{k,c}^{(n+1)}(\omega)|^2 d\omega}{\int_0^\infty \sum_{c=1}^C |\hat{\mathbf{u}}_{k,c}^{(n+1)}(\omega)|^2 d\omega} \quad (4)$$

③拉格朗日乘子的更新

$$\hat{\lambda}_c^{(n+1)}(\omega) = \hat{\lambda}_c^{(n)}(\omega) + \beta \left(\hat{x}_c(\omega) - \sum_{k=1}^K \hat{u}_{k,c}^{(n+1)}(\omega) \right) \quad (5)$$

第四步：迭代停止条件：MVMD的迭代过程持续到重构误差足够小，残差的 L_2 范数相对变化小于阈值 ϵ 即可停止，公式如（5）所示：

$$\frac{\sum_{c=1}^C \frac{\|\sum_{k=1}^K \hat{u}_{k,c}^{(n+1)} - \hat{x}_c\|_2}{\|\hat{x}_c\|_2}}{C} < \epsilon \quad (6)$$

第五步：逆傅里叶变换与结果输出：对收敛后的 $\hat{u}_{k,c}(\omega)$ 进行逆离散傅里叶变换，得到 $\mathbf{u}_k(t) = [u_{1,1}(t), u_{1,2}(t), \dots, u_{k,c}(t)]^T$ ，以及最终的残差信号 $r_c(t) = x_c(t) - \sum_{k=1}^K \mathbf{u}_{k,c}(t)$ 。

2.2 VSN_GRU

2.2.1 变量选择网络

VSN是VSN_GRU实现动态变量筛选的核心模块，其功能是对预处理后的多维变量进行非线性增强与权重分配，筛选出与锂电池SOH强相关的关键特征。

设 $\xi_t^{(j)} \in R^{d_{\text{model}}}$ 表示时间 t 时第 j 个变量的变换后输入， d_{model} 为特征维度， m_x 为输入变量总数。定义 $\Xi_t = [\xi_t^{(1)^T}, \dots, \xi_t^{(m_x)^T}]^T$ 为时间 t 所有过去输入的扁平向量。通过将 Ξ_t 输入门控残差网络（gated residual network, GRN）进行特征增强，再经过Softmax层，生成变量选择权重 v_{xt} ，公式为：

$$v_{xt} = \text{Softmax}(\text{GRN}_{v_x}(\Xi_t)) \quad (7)$$

在每个时间步，每个变量均需通过GRN进行非线性处理，确保变量重要性评估一致性。最终经过GRN处理的特征会根据权重加权融合，得到GRU的输入特征矩阵。

2.2.2 门控残差网络

为适配锂电池HI与SOH之间复杂的映射关系，同时提升模型在小样本场景下的鲁棒性，VSN采用GRN作为核心处理单元，并结合门控线性单元（gated linear units, GLUs）给模型自适应调整非线性处理强度的能力。其具体计算流程如下：首先通过线性变换与ELU激活函数（exponential linear unit, ELU）实现初步特征提取与非线性增强；然后对非线性处理结果进行dropout正则化抑制过拟合，再通过线性变换与层归一化优化特征分布，线性变换和归一化之后进行ELU激活函数

（exponential linear unit, ELU）激活。最后引入门控线性单元（gated linear units, GLUs）动态调控GRN的特征输出强度。

2.2.3 VSN_GRU模块

VSN_GRU通过VSN变量筛选与GRU时序建模的两阶段架构实现锂电池SOH预测，模型架构如图5所示，具体步骤如下：

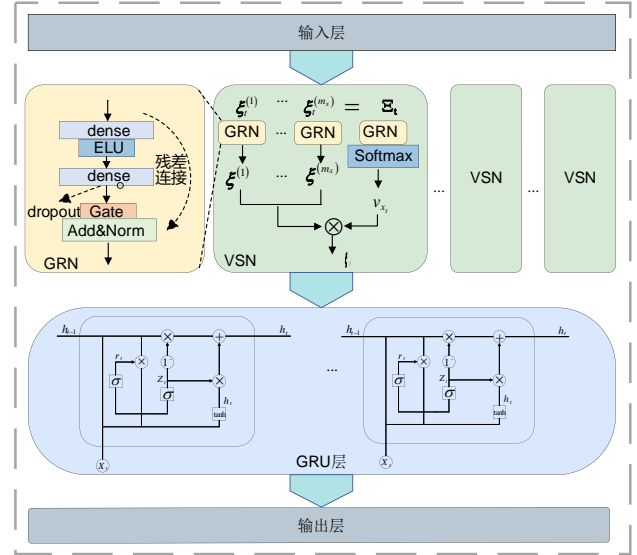


图5 VSN_GRU架构图

Fig.5 Architecture Diagram of VSN_GRU

第一步：输入预处理：对锂电池原始时序数据进行特征提取后，通过VSN进行差异化预处理。

第二步：GRN线性增强：每个 $\xi_t^{(j)}$ 输入专属GRN得到增强后的特征 $\tilde{\xi}^{(j)}$ 。

第三步：动态变量筛选与融合：拼接所有 $\tilde{\xi}^{(j)}$ 得到特征矩阵，输入GRN与Softmax层生成变量权重 v_{xt} ，通过加权融合得到筛选后的高质量特征 $\tilde{\xi}_t = \sum_{j=1}^{m_x} v_{xj} \tilde{\xi}^{(j)}$ 。

第四步：GRU时序建模与预测：将融合特征序列 $\tilde{\xi}_1, \tilde{\xi}_2, \tilde{\xi}_3, \dots, \tilde{\xi}_T$ 输入GRU单元，通过更新门与重置门捕捉时序依赖关系，输出各时间步隐藏状态 \tilde{h}_t 。最终通过线性输出层将GRU最终隐藏状态 h_t 映射为锂电池SOH预测值。

2.3 袋獾优化算法

TDO是2022年由Mohammad Dehghani等人提出的一种元启发式智能优化算法，其灵感来源于袋獾的觅食行为。TDO通过探索与开发的动态平

衡机制，在单峰、多峰函数寻优中可有效跳出局部最优并收敛至全局最优，相比粒子群优化（particle swarm optimization, PSO）、遗传算法（genetic optimization, GA）等传统算法适配性与鲁棒性更强。在单峰函数上，TDO收敛更快，可避免PSO后期收敛缓慢与GA最优解震荡问题；在多峰函数上，其全局搜索能力更强，能克服PSO早熟收敛、GA局部搜索不足的缺陷。借助双策略动态切换，TDO可兼顾解空间遍历与精细挖掘，在各类测试函数中稳定获得全局最优，而传统算法易陷入局部最优难以全局收敛^[27]。该算法通过模拟袋獾以腐肉为食的全局探索策略和捕食猎物的局部开发策略，实现了优化过程中探索与开发的平衡。其算法步骤如下：

第一步：初始化种群：

$$x_{ij} = lb_j + r \cdot (ub_j - lb_j) \quad (8)$$

式中， x_{ij} 表示第*i*个个体的第*j*维变量， lb_j 和 ub_j 分别为第*j*维的下界和上界， r 为区间(0,1)内的随机数。

第二步：腐肉觅食策略（探索阶段）

①腐肉位置选择：随机选择种群中的一个个体作为腐肉位置：

$$C_i = x_k (k \neq i) \quad (9)$$

②位置更新：根据腐肉的适应度值决定移动方向：

$$x_i^{new} = x_i + r \cdot (C_i - x_i) \text{ 若 } f(C_i) < f(x_i) \quad (10)$$

$$x_i^{new} = x_i - r \cdot (C_i - x_i) \text{ 若 } f(C_i) \geq f(x_i) \quad (11)$$

式中， $f(\cdot)$ 为目标函数值。若新位置的适应度更优，则接受该位置，否则保持原位置。

第三步：猎物捕食策略（开发阶段）

①攻击阶段：随机选择一个猎物位置 P_i （种群中的其他个体），并根据猎物适应度值更新位置：

$$x_i^{new} = x_i + r \cdot (P_i - x_i) \text{ 若 } f(P_i) < f(x_i) \quad (12)$$

$$x_i^{new} = x_i - r \cdot (P_i - x_i) \text{ 若 } f(P_i) \geq f(x_i) \quad (13)$$

②追逐阶段：以当前位置为中心，在半径为*R*的邻域内精细搜索：

$$R = 0.01 \cdot \left(1 - \frac{t}{T}\right) \quad (14)$$

$$x_i^{new} = x_i + R \cdot (ub_j - lb_j)(2r - 1) \quad (15)$$

式中， t 为当前迭代次数， T 为最大迭代次数，邻域半径*R*随迭代次数增加而减小，确保搜索精度逐渐提升。

2.4 MVMD-TDO-VSN_GRU模型

为实现锂离子电池SOH的高精度预测，本文提出一种新型的多特征融合的MVMD-TDO-VSN_GRU联合预测模型。针对锂离子电池多元时序数据在时域与频域层面存在的耦合关联特性，模型首先通过MVMD对原始数据进行分解处理；随后采用VSN_GRU捕捉分解后各子序列的时空域特征；考虑到VSN_GRU模型超参数的人工设定易导致其陷入局部最优解，进一步引入TDO对VSN_GRU的关键超参数进行全局寻优，实现模型性能的优化提升。MVMD-TDO-VSN_GRU模型的整体框架如图6所示，其具体预测步骤如下：

第一步：特征提取与数据处理。首先，在锂离子电池充放电全生命周期过程中，提取间接HI与电池SOH指标构建多元时序数据集。对该数据集进行归一化处理以消除量纲差异与数据分布偏移影响后，采用MVMD算法将预处理后的多元时序数据分解为*K*个具有不同频率特性的多元IMF子序列；最后按照预设比例划分训练集与测试集，为后续模型训练与验证提供数据支撑。

第二步：TDO-VSN_GRU网络。选取VSN_GRU网络的迭代次数、时间窗口长度、批量样本大小及学习率作为待优化超参数，将其输入TDO算法中并完成种群初始化。以VSN_GRU网络在训练集上的预测结果均方根误差（root mean square error, RMSE）作为TDO算法的适应度函数，驱动VSN_GRU网络进行迭代训练。上述寻优训练过程持续进行，直至满足预设的最优解终止条件，此时输出的种群最优位置即为VSN_GRU网络的全局最优超参数组合。

第三步：锂离子电池SOH预测。将全局最优超参数代入VSN_GRU网络，分别对MVMD分解得到的*K*个多元子序列测试集进行SOH预测。待所有子序列的预测任务完成后，对*K*个独立子序列的预测结果进行叠加重构处理，最终得到锂离子电池SOH的预测结果。

3 实验结果及分析

3.1 模型评估指标

为了更好地验证MVMD-TDO-VSN_GRU模型的预测性能，本实验采用的评价指标包括均方误差（mean square error, MSE）、平均绝对误差

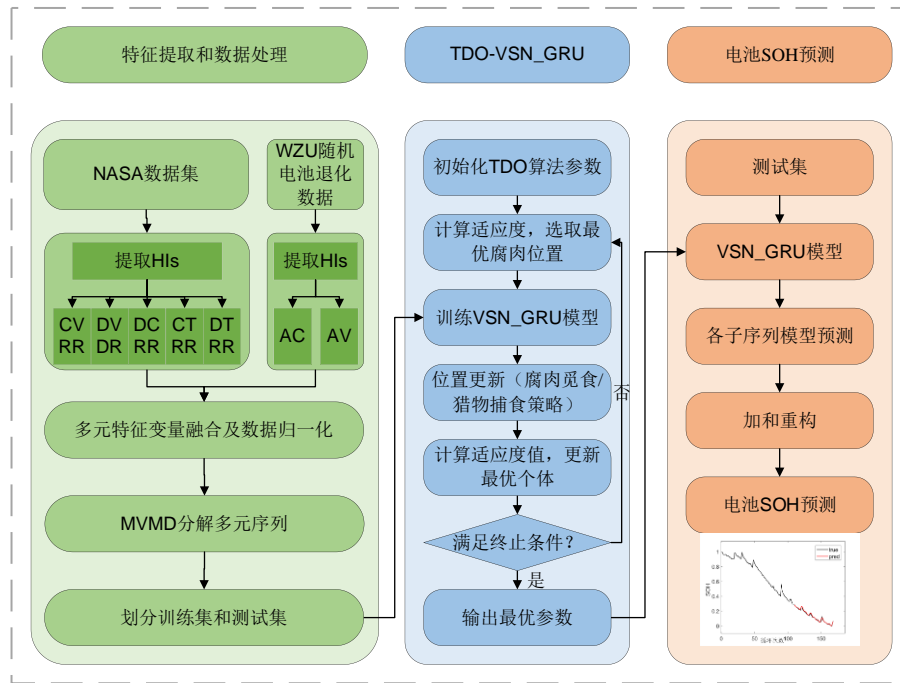


图6 总技术路线架构图

Fig.6 Architecture Diagram of the Overall Technical Route

(mean absolute error, MAE)、均方根误差 (root mean square error, RMSE) 和 决定系数 (coefficient of determination, R^2), 其计算公式如下所示:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (16)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (17)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (18)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (19)$$

式中: \hat{y}_i 为模型预测值; y_i 为实际测量值; \bar{y} 为测量平均值, $i \in [1, n]$; n 为循环次数。

通常情况下, MSE , MAE 和 $RMSE$ 越接近 0, 则说明该模型的预测效果越接近于实际情况, 对应的预测效果也越好。 R^2 值越接近 1, 表明模型的预测效果越好。

3.2 MVMD 分解

MVMD 分解中, 模态个数 K 的选取直接影响后续模型的预测精度: 若 K 值过小, 难以充分挖掘时间序列中隐含的特征信息, 可能导致关键有效成分遗漏; 若 K 值过大, 则易引发模态过度分解与冗

余, 甚至出现模态混叠问题。为此, 本文提出通过分析多元序列在不同 K 值下的分解结果及对应模态中心频率实现 K 值的最优选取。以 B05 号锂离子电池为例: 当 $K=6$ 与 $K=7$ 时, 新增模态与 $K=6$ 时的已有模态中心频率高度相近, 表明 $K=7$ 时存在明显的模态重叠与冗余风险, 因此确定 $K=6$ 为最优模态分解个数。分解结果如图 7 所示。




图7 MVMD 分解结果

Fig.7 MVMD Decomposition Results

3.3 消融实验

为了验证所提出的MVMD-TDO-VSN_GRU模型在锂离子电池SOH预测中的精确度与稳定性，本文设计消融实验，构建了包括GRU (M1)、VSN_GRU (M2)、TDO-GRU (M3)、TDO-VSN_GRU (M4)、MVMD-GRU (M5)、MVMD-VSN_GRU (M6)、MVMD-TDO-GRU (M7) 以及

MVMD-TDO-VSN_GRU (M8) 在内的8种模型进行对比。实验基于两个数据集进行：NASA数据集选用3个电池的前60%数据作为训练集，WZU电池退化数据集选用5个电池的前80%数据作为训练集。各模型的预测曲线对比见图8、图9，评价指标统计于表3和表4，MSE、RMSE和MAE的柱状堆叠对比图如图10所示。




图8 消融实验结果图 (数据集A)

Fig.8 Ablation Experiment Results Plot (Dataset A)

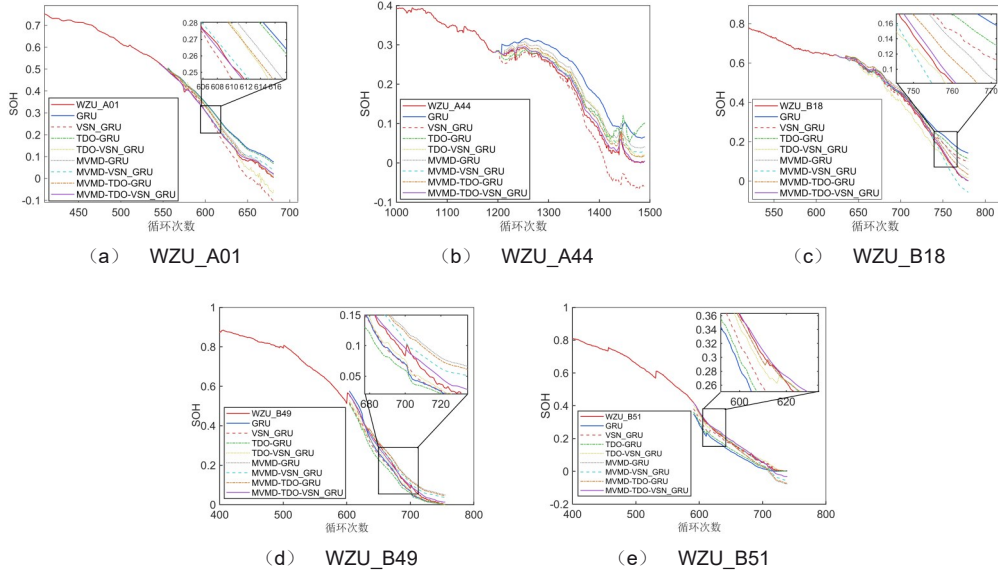


图9 消融实验结果图 (数据集B)

Fig.9 Ablation Experiment Results Plot (Dataset B)

由图8，图9的预测曲线对比可见，文中提出的MVMD-TDO-VSN_GRU方法预测结果最贴近真实退化轨迹，尤其在曲线拐点处的预测精度，显著优于其余对比模型。其中，单一GRU网络的预测曲线与真实SOH偏差最大，但在引入VSN模块后，通过其实现多元HI动态筛选功能，从而使预测性能有效提升。融合MVMD分解方法对多元序

列进行处理，将其分解为中心频率一致的子序列后，MVMD-GRU与MVMD-VSN_GRU的拟合轨迹在峰值区域的表现，显著优于未采用MVMD的模型。在融入具备全局寻优能力的TDO算法后，模型综合性能得到进一步提高。最后多算法组合验证表明，该框架的预测表现全面优于其他对比组合模型。

表3 模型评价指标 (数据集A)

Tab.3 Model Evaluation Metrics(Dataset A)

电池	模型	MSE/%	RMSE	MAE	R ²
B05	M1	0.1455	0.0381	0.0314	0.7996
	M2	0.0777	0.0279	0.0219	0.8608
	M3	0.0992	0.0315	0.0225	0.8361
	M4	0.0363	0.0190	0.0165	0.9350
	M5	0.0205	0.0143	0.0120	0.9802
	M6	0.0104	0.0102	0.0076	0.9899
	M7	0.0156	0.0125	0.0094	0.9849
	M8	0.0094	0.0097	0.0071	0.9909
B06	M1	0.1501	0.0387	0.0357	0.7608
	M2	0.0797	0.0282	0.0229	0.8690
	M3	0.0671	0.0259	0.0235	0.8931
	M4	0.0389	0.0197	0.0187	0.9360
	M5	0.0292	0.0171	0.0140	0.9643
	M6	0.0189	0.0138	0.0107	0.9769
	M7	0.0263	0.0162	0.0133	0.9679
	M8	0.0140	0.0119	0.0095	0.9828
B07	M1	0.1535	0.0392	0.0351	0.7606
	M2	0.0649	0.0255	0.0243	0.9019
	M3	0.0875	0.0296	0.0252	0.8636
	M4	0.0369	0.0192	0.0168	0.9466
	M5	0.0211	0.0145	0.0118	0.9785
	M6	0.0105	0.0103	0.0082	0.9893
	M7	0.0185	0.0136	0.0112	0.9812
	M8	0.0099	0.0099	0.0079	0.9898


表4 模型评价指标 (数据集B)

Tab.4 Model Evaluation Metrics(Dataset B)


电池	模型	MSE/%	RMSE	MAE	R ²
WZU_A01	M1	0.2739	0.0523	0.0484	0.8833
	M2	0.2466	0.0496	0.0370	0.08949
	M3	0.2338	0.0483	0.0448	0.9004
	M4	0.1014	0.0318	0.0266	0.9568
	M5	0.0790	0.0281	0.0260	0.9712
	M6	0.0467	0.0216	0.0167	0.9830
	M7	0.0464	0.0215	0.0197	0.9831
	M8	0.0151	0.0122	0.0098	0.9945
WZU_A44	M1	0.3344	0.0578	0.0536	0.7110
	M2	0.1610	0.0401	0.02992	0.8617
	M3	0.1354	0.0367	0.0265	0.8829
	M4	0.0657	0.0256	0.0212	0.9434
	M5	0.1015	0.0318	0.0295	0.9128
	M6	0.0307	0.0175	0.0148	0.9736
	M7	0.0318	0.0178	0.0166	0.9727
	M8	0.0090	0.0095	0.0083	0.9922
WZU_B18	M1	0.3968	0.0629	0.0448	0.9002
	M2	0.1447	0.0380	0.0246	0.9636
	M3	0.2501	0.0500	0.0351	0.9371
	M4	0.0776	0.0278	0.0227	0.9804
	M5	0.1313	0.0362	0.0318	0.9687
	M6	0.0439	0.0209	0.0137	0.9895
	M7	0.0475	0.0218	0.0200	0.9886
	M8	0.0065	0.0080	0.0074	0.9984
WZU_B49	M1	0.2522	0.0502	0.0491	0.7872
	M2	0.1831	0.0428	0.0372	0.8534
	M3	0.2207	0.0470	0.381	0.8138
	M4	0.1130	0.0336	0.0303	0.8919
	M5	0.1054	0.0325	0.0281	0.9634
	M6	0.0379	0.0195	0.0147	0.9868
	M7	0.0838	0.0290	0.0250	0.9709
	M8	0.0097	0.0098	0.0086	0.9966
WZU_B51	M1	0.3740	0.0612	0.0557	0.4724
	M2	0.2494	0.0450	0.0484	0.6039
	M3	0.2889	0.0539	0.0500	0.5911
	M4	0.1020	0.0319	0.0313	0.8380
	M5	0.1029	0.0321	0.0229	0.9238
	M6	0.0448	0.0212	0.0139	0.9668
	M7	0.0844	0.0291	0.0205	0.9375
	M8	0.0218	0.0147	0.0120	0.9838

结合表3、表4及图10的定量分析结果可知,本文提出的MVMD-TDO-VSN_GRU模型展现出最优预测性能。具体而言,在NASA数据集上,以B05为例,该模型的MSE为0.0094%、RMSE为0.0097、R²为0.9909、MAE为0.0071;在WZU_A01数据集上,对应指标分别为MSE为0.0151%、RMSE为0.0122、R²为0.9945、MAE为0.0098;在WZU_B49数据集上,对应指标分别为MSE为0.0097%、RMSE为0.0098、R²为0.9966、MAE为0.0086。性能对比结果显示,在B05数据集的预测任务中,相较于预测效果最差的单一GRU模型,本文所提方法的MSE、RMSE及MAE优化幅度分别达到93.53%、74.54%、77.38%;相较于未引入VSN模块的MVMD-TDO-GRU模型,上述指标也实现了39.74%、22.4%、24.46%的提升。在WZU随机电池退化数据集中,本文模型的性能提升规律与B05数据集一致。以A组中的WZU_A01为例,相较于单一GRU模型,

MSE、RMSE及MAE的优化幅度分别达到94.48%、76.67%、79.75%;相较于MVMD-TDO-GRU模型,优化幅度分别提升67.45%、43.25%、50.25%。类似地,B组中的WZU_B49也呈现出相同规律,相较于单一GRU模型,三项指标的优化



(a) 数据集A指标对比图



(b) 数据集B指标对比图

图10 各数据集指标对比图

Fig.10 Comparison of Indicators Across Datasets

幅度分别达到96.15%、80.47%、82.48%；相较于MVMD-TDO-GRU模型，优化幅度分别提升88.42%、66.20%、65.60%。综上，通过MVMD多元分解策略，并结合TDO优化算法对融合VSN模块的GRU模型超参数进行寻优，可显著提升模型预测精度。此外，该模型在所有测试电池数据集上均取得最小的MSE、RMSE及MAE值，同时获得最大的R²值，充分验证了其卓越的预测精度与优异的鲁棒性。

3.4 对比实验

3.4.1 与主流优化算法对比

为进一步验证TDO在超参数全局寻优中的有效性，以NASA数据集集中的B05电池为例，将TDO算法与PSO算法分别应用于VSN_GRU和MVMD-VSN_GRU进行对比试验。实验对比了两者优化得到的模型预测结果，对比结果如表5所示。

结果表明，TDO优化的模型在引入MVMD和不引入MVMD的情况下，各项性能评价指标均显著优于PSO优化：在未采用MVMD预处理的情况下，TDO-VSN_GRU的MSE、RMSE、MAE分别较PSO-VSN_GRU降低29.4%、15.9%、18.4%，R²提升2.97%；在引入MVMD预处理后，MVMD-

表5 PSO与TDO优化结果对比

Tab.5 Comparison of Optimization Results between PSO and TDO

模型	评价指标			
	MSE/%	RMSE	MAE	R ²
PSO-VSN_GRU	0.0514	0.0226	0.0201	0.9079
TDO-VSN_GRU	0.0363	0.0190	0.0164	0.9350
MVMD-PSO-VSN_GRU	0.0438	0.0209	0.0155	0.9215
MVMD-TDO-VSN_GRU	0.0094	0.0097	0.0071	0.9909

TDO-VSN_GRU的MSE、RMSE、MAE较MVMD-PSO-VSN_GRU分别降低78.5%、53.6%、54.2%，R²提升7.53%。上述结果表明，TDO算法相较于PSO具备更优异的全局寻优能力，能够更有效地找到VSN_GRU网络的最优超参数组合，为锂离子电池SOH的预测提供了更优选择。

3.4.2 与主流模型对比

为了进一步证明所提出的MVMD-TDO-VSN_GRU预测方法的优越性，以电池B05为例，在相同的初始条件下，将本文所提方法的预测结果分别与LSTM、TCN等主流模型的预测结果进行比较，比较结果如图11和表6所示。从表6中可以看出，本文所提MVMD-TDO-VSN_GRU方法显著优于其他模型。具体而言，相比单一LSTM和TCN模型，本文方法的RMSE分别降低了83.9%和83.01%，MAE分别降低了86.3%和82.8%，MSE分别降低了97.44%和97.11%，此外，本文方法的R²达到0.9909，远高于其对比模型。综合分析表明，本文所提出的方法具有更高的预测精度，其RMSE和MAE均远低于其他主流算法，这一结果证明了所提方法的有效性。

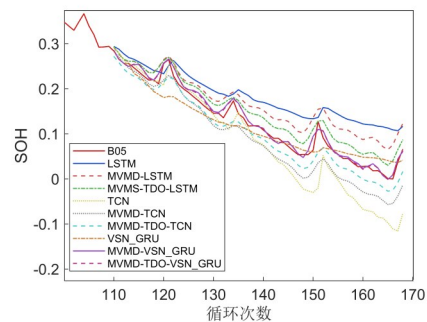


图11 与主流模型预测结果对比图

Fig.11 Figure comparing prediction results with mainstream models

表6 与主流模型预测结果对比

Tab.6 Comparison with mainstream model predictions 模型	评价指标			
	MSE/%	RMSE	MAE	R ²
LSTM	0.3678	0.0606	0.0520	0.6452
MVMD-LSTM	0.1707	0.0413	0.0351	0.8360
MVMD-TDO-LSTM	0.0524	0.0229	0.0210	0.9496
TCN	0.3258	0.0571	0.0414	0.6858
MVMD-TCN	0.1463	0.0382	0.0321	0.8595
MVMD-TDO-TCN	0.0593	0.0243	0.0229	0.9430
VSN_GRU	0.0777	0.0279	0.0219	0.8608
MVMD-VSN_GRU	0.0104	0.0102	0.0076	0.9899
MVMD-TDO-VSN_GRU	0.0094	0.0097	0.0071	0.9909

4 结论

为了提升锂离子电池SOH的预测精度，本文提出了MVMD-TDO-VSN_GRU预测模型，并通过NASA数据集与WZU随机电池退化数据验证了该方法的精确性与稳定性。研究结论如下：

(1) 提出基于MVMD的多特征序列分解策略，先提取间接HI构建多特征序列，再对其开展时频同步分解，得到中心频率对齐的IMFs，有效保留特征间内在关联，显著提升SOH预测精度。

(2) 引入VSN与GRU网络融合，利用其对复杂时序规律的适配性与深层特征提取优势，捕捉SOH衰减的细微特征与演化规律，支撑高精度预测。

(3) 融入TDO算法优化超参数，凭借其全局寻优特性克服传统调参局限，匹配最优超参数组合，提升模型预测性能。

(4) 通过消融实验结果表明，MVMD-TDO-VSN_GRU模型的预测精度显著优于其他对比模型，其中，在NASA数据集的三块电池上，RMSE优化幅度分别为74.54%、69.25%和74.74%。在WZU随机电池退化数据集中，A组两块电池的优化幅度达到76.67%和83.56%，B组三块电池则分别为87.28%、80.47%及76.21%，R²均达到0.98以上。这证实了该方法具有良好的预测性能与鲁棒性。

(5) 在对比实验中，本文从常用优化算法和预测模型两个层面进行验证。优化算法方面，TDO的优化效果明显优于PSO，其MSE、RMSE、MAE最优提升幅度分别达到78.5%、53.6%、54.2%，R²达0.9909。主流模型对比方面，本文所

提MVMD-TDO-VSN_GRU较单一LSTM、TCN等模型，RMSE与MAE均降低80%以上，MSE降低超97%。综上，该方法在SOH预测中具有优异的寻优能力与预测精度。

此外，本文模型目前侧重于预测精度的验证，对其在新能源汽车、储能电站等实际落地场景中可尝试通过离线训练与在线部署进行应用。然而锂离子电池老化过程受多种复杂因素耦合影响，且本模型因MVMD分解与重构步骤导致计算复杂度有一定程度的增加，在实时性要求较高的工程场景中需谨慎权衡计算资源与预测性能。未来研究将针对典型应用场景开展适应性分析，并探索模型轻量化与工况拓展的可能性。

参考文献

- [1] TIAN HX, PENG L, QIN K, et al. A review of the state of health for lithium-ion batteries: research status and suggestions[J]. Journal of Cleaner Production, 2020, 261: 120813.
- [2] 张昊哲,蔡志端,吴成傲,等. 基于变分模态分解与特征增强的锂电池健康状态估计方法[J]. 储能科学与技术,2025,14(9): 3599-3610.
ZHANG Wuzhe, CAI Zhiduan, WU Chengao, et al. State-of-health assessment of lithium batteries using variational mode decomposition and feature enhancement under capacity regeneration phenomena[J]. Energy Storage Science and Technology, 2025, 14(9): 3599-3610.
- [3] 晋殿卫,顾则宇,张志宏. 锂电池健康度和剩余寿命预测算法研究[J]. 电力系统保护与控制, 2023, 51(01): 122-130.
JIN Dianwei, GU Zeyu, ZHANG Zhihong. Lithium battery health degree and residual life prediction algorithm[J]. Power System Protection and Control, 2023, 51(01): 122-130.
- [4] 张朝龙,陈阳,刘梦玲,等. 一种基于ICA-T特征和CNN-LA-BiLSTM的锂离子电池健康状态估计方法[J]. 储能科学与技术,2025,14(3): 1258-1269.
ZHANG Chaolong, CHEN Yang, LIU Mengling, et al. A state of health estimation method for lithium-ion batteries using ICA-T

- features and CNN-LA-BiLSTM[J]. *Energy Storage Science and Technology*, 2025, 14(3): 1258-1269.
- [5] LIU YW, SUN J, SHANG YL, et al. A novel remaining useful life prediction method for lithium-ion battery based on long short-term memory network optimized by improved sparrow search algorithm [J]. *Journal of Energy Storage*, 2023, 61: 106645.
- [6] RUI ZHU, BIN DUAN, JUNMING ZHANG, et al. Co-estimation of model parameters and state-of-charge for lithium-ion batteries with recursive restricted total least squares and unscented Kalman filter[J]. *Applied Energy*, 2020, 277: 115494.
- [7] 樊欣欣, 丁晖, 陈秀国, 等. 基于模糊逻辑的变电站蓄电池在线健康状态评估[J]. *电子器件*, 2021, 44(1): 136-140.
FAN Xinxin, DING Hui, CHEN Xiuguo, et al. On-line health assessment of substation battery based on fuzzy logic[J]. *Chinese Journal of Electron Devices*, 2021, 44(1): 136-140.
- [8] 顾菊平, 蒋凌, 张新松, 等. 基于特征提取的锂离子电池健康状态评估及影响因素分析[J]. *电工技术学报*, 2023, 38(19): 5330-5342.
GU Juping, JIANG Ling, ZHANG Xinsong, et al. Estimation and influencing factor analysis of lithium-ion batteries state of health based on features extraction[J]. *Transactions of China Electrotechnical Society*, 2023, 38(19): 5330-5342.
- [9] 娄岚浩, 杨立鹏, 杨晓光. 锂离子电池电化学机理模型参数辨识研究综述[J]. *化工学报*, 2025, 76(9): 4369-4382.
LOU Lanhao, YANG Lipeng, YANG Xiaoguang. Review of parameter identification for physics-based lithium-ion battery models [J]. *CIESC Journal*, 2025, 76(9): 4369-4382.
- [10] CHEN DQ, ZHOU XZ. AttMoE: attention with mixture of experts for remaining useful life prediction of lithium-ion batteries[J]. *Journal of Energy Storage*, 2024, 84: 110780.
- [11] 陈峥, 多功东, 申江卫, 等. 基于容量增量分析与VMD-GWO-KELM的锂电池健康状态估计[J]. *储能科学与技术*, 2025, 14(6): 2476-2487.
CHEN Zheng, DUO Gongdong, SHEN Jiangwei, et al. State of health estimation for lithium battery based on incremental capacity analysis and VMD-GWO-KELM[J]. *Energy Storage Science and Technology*, 2025, 14(6): 2476-2487.
- [12] 董作林, 宋金岩, 孟子迪. 基于模态分解和深度学习的锂离子电池寿命预测[J]. *储能科学与技术*, 2025, 14(4): 1645-1653.
DONG Zuolin, SONG Jinyan, MENG Zidi. Lithium-ion battery life prediction based on mode decomposition and deep learning[J]. *Energy Storage Science and Technology*, 2025, 14(4): 1645-1653.
- [13] 李嘉波, 王志璇, 田迪, 等. 变模态分解下SSA-LSTM组合的锂离子电池剩余使用寿命预测方法[J]. *储能科学与技术*, 2025, 14(2): 659-670.
LI Jiabo, WANG Zhixuan, TIAN Di, et al. Prediction method for remaining service life of lithium batteries using SSA-LSTM combination under variable mode decomposition[J]. *Energy Storage Science and Technology*, 2025, 14(2): 659-670.
- [14] STREB M, OHROLIUS M, SIDDIQUI A, et al. Diagnosis and prognosis of battery degradation through reevaluation and gaussian process regression of electrochemical model parameters[J]. *Journal of Power Sources*, 2023, 588: 233686.
- [15] ZHANG XUGANG, WANG ZE, GONG QINGSHAN, et al. State of health estimation of lithium-ion batteries based on hybrid neural networks with residual connections[J]. *Journal of the Electrochemical Society*, 2025, 172(2).
- [16] 尹杰, 刘博, 孙国兵, 等. 基于迁移学习和降噪自编码器-长短期记忆的锂离子电池剩余寿命预测[J]. *电工技术学报*, 2024, 39(1): 289-302.
YIN Jie, LIU Bo, SUN Guobing, et al. Transfer learning denoising autoencoder-long short term memory for remaining useful life prediction of li-Ion batteries[J]. *Transactions of China Electrotechnical Society*, 2024, 39(1): 289-302.
- [17] 李英顺, 阚宏达, 郭占男, 等. 基于数据预处理和VMD-LSTM-GPR的锂离子电池剩余寿命预测[J]. *电工技术学报*, 2024, 39(10): 3244-3258.
LI Yingshun, KAN Hongda, GUO Zhanan, et al. Prediction of remaining useful life of ; lithium-Ion battery based on data preprocessing and VMD-LSTM-GPR[J]. *Transactions of China Electrotechnical Society*, 2024, 39(10): 3244-3258.
- [18] WANG JIAOLONG, ZHANG FODE, ZHANG JIANCHUAN, et al. A flexible RUL prediction method based on poly-cell LSTM with applications to lithium battery data[J]. *Reliability Engineering & Systems Safety*, 2023, 231: 108976.
- [19] 时洪雷, 刘喜军, 高竟译, 等. 基于超参数优化和混合神经网络的锂硫电池健康状态估计[J]. *储能科学与技术*, 2025, 14(12): 4721-4731.
SHI Honglei, LIU Xijun, GAO Jingyi, et al. State of health estimation of lithium-sulfur batteries based on hyperparameter optimization and hybrid neural networks[J]. *Energy Storage Science and Technology*, 2025, 14(12): 4721-4731.
- [20] 孙中麟, 李嘉波, 田迪, 等. 基于COA-LSTM和VMD的锂离子电池剩余寿命预测[J]. *储能科学与技术*, 2024, 13(9): 3254-3265.
SUN Zhonglin, LI Jiabo, TIAN Di, et al. Remaining Useful life prediction for lithium-ion batteries based on COA-LSTM and VMD [J]. *Energy Storage Science and Technology*, 2024, 13(9): 3254-3265.
- [21] 张安安, 谢琳惺, 杨威. 基于CNN-GRU组合神经网络的锂电池寿命预测模型研究[J]. *电测与仪表*, 2025, 62(7): 77-84.
ZHANG An'an, XIE Linxing, YANG Wei. Research on Lithium battery life prediction model based on CNN-GRU combined neural network[J]. *Electrical Measurement & Instrumentation*, 2025, 62(7): 77-84.
- [22] WANG XH, DAI K, HU M, et al. Lithium-ion battery health state and remaining useful life prediction based on hybrid model MFE-GRU-TCA[J]. *Journal of Energy Storage*, 2024, 95: 112442.
- [23] 莫易敏, 余自豪, 叶鹏, 等. 基于迁移学习与GRU神经网络结合的锂电池SOH估计[J]. *太阳能学报*, 2024, 45(3): 233-239.
MO Yimin, YU Zihao, YE Peng, et al. Lithium battery SOH estimation method based on combination of transfer learning and GRU neural network[J]. *Acta Energetica Solaris Sinica*, 2024, 45(3): 233-239.
- [24] LIM B, ARIK SÖ, LOEFF N, et al. Temporal fusion transformers for interpretable multi-horizon time series forecasting[J]. *International Journal of Forecasting*, 2021, 37(4): 1748-1764.

- [25] 郭鑫喆,王业琴,王超,等. 基于多目标模态分解与NAHL神经网络的电动汽车充电负荷预测方法[J]. 电测与仪表, 2025, 62(3):20-29.
GUO Xinzhe, WANG Yeqin, WANG Chao, et al. Electric vehicle charging load prediction method based on multi-objective modal decomposition and NAHL neural network[J]. Electrical Measurement & Instrumentation, 2025, 62(3): 20-29.
- [26] UR REHMAN N, AFTAB H. Multivariate variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2019, 67(23): 6039-6052.
- [27] D M, Hubálovský Š, Trojovský P. Tasmanian devil optimization: a new bio-inspired optimization algorithm for solving optimization problems[J]. IEEE Access, 2022, 10: 19599-19620.
- [28] 李泽龙,乔钢柱,崔方舒,等. 应用VMD-HPO-NBEATS模型的锂离子电池SOH预测[J]. 中国测试, 2024, 50(9): 65-73.
LI Zelong, QIAO Gangzhu, CUI Fangshu, et al. State of health prediction of lithium-ion batteries based on VMD-HPO-NBEATS model[J]. China Measurement & Test, 2024, 50(9): 65-73.
- [29] DONGZHEN LYU, BIN ZHANG, ENRICO ZIO, JIAWEI XIANG, et al. Battery cumulative ;lifetime prognostics to bridge laboratory and Real-Life scenarios[J]. Cell Reports Physical Science, 2024. <https://doi.org/10.1016/j.xcrp.2024.102164>.