

DOI: 10.13382/j.jemi.B2407957

联合电池组不一致性评估的 RUL 区间预测方案*

庞晓琼¹ 李笑¹ 李晓杰² 张鑫¹

(1. 中北大学计算机科学与技术学院 太原 030051; 2. 中北大学能源与动力工程学院 太原 030051)

摘要: 为确保锂离子电池组运行的可靠性与安全性, 对其剩余使用寿命(RUL)进行准确且稳健的预测至关重要。然而, 电池组内部的不一致性会加速其退化, 从而增加了 RUL 预测的难度。同时, 传统的数值预测方法难以适应不同安全级别和紧急情况的需求。为此, 提出了一种联合电池组不一致性评估和 RUL 区间预测的方案。首先, 基于电压和温度数据, 提取一系列反映电池组不一致性的健康指标(HI); 其次, 采用样本熵方法对这些 HI 进行客观加权, 以评估电池组的不一致性; 然后, 将不一致性评估结果纳入 HI, 并通过模糊信息粒化(FIG)技术处理, 为区间预测提供上下界; 最终, 利用长短时记忆神经网络建立预测模型, FIG 处理后的上下界序列作为输入, 容量的上下界序列作为输出, 实现电池组 RUL 的点预测和区间预测。实验结果表明, 策略能有效评估电池组的不一致性, 且评估结果与电池组退化程度高度相关。此外, 对于不同起始点的训练数据, 点预测的误差控制在 0.32 Ah 以内, 区间预测的综合评价指标 $P > 1.97$, 表明预测方法具有良好的可行性和有效性。

关键词: 锂离子电池组; 剩余使用寿命; 不一致性评估; 区间预测

中图分类号: TM912; TN919.5 **文献标识码:** A **国家标准学科分类代码:** 120.30

RUL interval prediction scheme combing battery pack inconsistency evaluation

Pang Xiaoqiong¹ Li Xiao¹ Li Xiaojie² Zhang Xin¹

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

2. The School of Energy and Power Engineering, North University of China, Taiyuan 030051, China)

Abstract: To ensure the reliability and safety of lithium-ion battery pack operation, it is very important to accurately and robustly predict its remaining useful life (RUL). However, the inconsistency within the battery pack will accelerate the process of degradation, which increases the difficulty of RUL prediction. At the same time, the traditional numerical prediction method is difficult to adapt to the needs of different security and emergency levels. Therefore, this study proposes a scheme combining battery pack inconsistency evaluation and RUL interval prediction. Firstly, based on the voltage and temperature data, multiple health indicators (HI) reflecting the inconsistency of battery pack were extracted. Secondly, the sample entropy method is used to objectively weight these HIs to evaluate the inconsistency of the battery pack. Then, the inconsistency evaluation results were incorporated into the health indicator system and processed by fuzzy information granulation (FIG) to provide upper and lower bounds for interval prediction. Finally, the long-term and short-term memory (LSTM) neural network was used modeling, taking the upper and lower bound sequences processed by FIG as inputs and the upper and lower bound sequences of capacity as outputs, and the point prediction and interval prediction of RUL is achieved. The experimental results show that this strategy can effectively evaluate the inconsistency of battery pack, and the evaluation results are highly correlated with the degree of battery pack degradation. In addition, for the training data at different starting points, the error of point prediction results is controlled within 0.32 Ah, the comprehensive evaluation criterion P for interval prediction is higher than 1.97, indicating the feasibility and effectiveness of the prediction method.

Keywords: lithium-ion battery pack; remaining useful life; inconsistency evaluation; interval prediction

收稿日期: 2024-11-15 Received Date: 2024-11-15

* 基金项目: 研究生教育创新计划项目(2024AL20)、山西省自然科学基金(202403021211188)、山西省重点研发项目(202102010101011)资助

0 引言

随着环境污染和能源危机问题的日益严峻,锂离子电池因其高能量密度、低自放电率以及较长使用寿命等特点,已在电动汽车、航空航天等众多领域得到广泛应用^[1-3]。为满足高电压和功率的需求,大量电池以串并联的方式形成电池组。然而,在电池组的使用过程中,其性能逐渐退化,当达到失效阈值时,还可能引发安全事故甚至导致灾难性事件^[4-5]。因此,对电池组的健康状态(state of health, SOH)和剩余使用寿命(remaining useful life, RUL)进行准确预测对确保电池组的安全运行和延长其使用寿命具有重要意义。

近年来,许多研究从不同方面对锂离子电池组的SOH或RUL进行预测。目前主要有两种方法,一类将单体电池的SOH或RUL预测直接扩展到电池组。例如,Weng等^[6]将单体增量容量分析(incremental capacity analysis, ICA)方法应用于电池组,提出了一种基于ICA原理的IC峰值跟踪框架来监测电池组的SOH。Song等^[7]采用前馈神经网络建立估计框架,实时监测电动汽车电池组的SOH。Lyu等^[8]通过分析老化数据提取了表征容量退化的老化特征,并构建了一种混合核函数的相关向量机优化模型,以实现电池组的SOH估计和RUL同步预测。然而,大规模的电池组不可避免带来电池单体间的不一致性问题。这种不一致性从生产阶段就存在,并可能在运行过程中逐步恶化^[9],使得电池组的退化过程相较于单个电池更为复杂^[10-11]。以上研究未能充分考虑电池组与单体电池之间的差异,忽略了电池单体间不一致性的影响,这限制了它们在实际应用中的准确性和可靠性。

鉴于这些问题,另一类方法通过分析和考虑不一致性的影响,间接估计电池组的健康状况。其中一些研究通过建立不一致性模型来估计电池组的健康状态。例如,Zhang等^[12]将电池组SOH定义为电池组最大储能的变化,并在该定义中考虑电池单体间的不一致性。然后采用粒子群优化-遗传算法进行电池组模型的参数辨识,从而估计SOH。Song等^[13]提出一种改进的等效电路模型,用于在恒流放电下建模电池单元放电过程,仿真实现了电池组容量和SOH估计。Zhou等^[14]基于不一致分析,总结了电池组容量的计算公式,通过建立老化模型实现对电池组SOH的在线估计。这些方法虽然在一定程度上考虑了不一致性,但建立不一致性模型的过程依赖于参数,需要持续的参数识别和估计来更新模型,这不仅增加了计算复杂度,而且参数识别的准确性直接影响SOH的估计结果。为了克服这些局限性,一些研究提取与电池不一致性相关的参数作为特征输入,并将相应的

SOH或RUL作为输出。例如,Hu等^[15]从部分充电曲线中提取健康指标(health indicator, HI)来反映容量损失、内阻增加和不一致变化,并设计了双高斯过程回归模型来预测整个循环寿命期间的SOH和RUL。Kwon等^[16]在充电阶段提取间接HI,利用Pearson相关系数分析和ICA识别不一致影响,并提出了多级长短时记忆(long short-term memory, LSTM)模型,用于联合预测电池组SOH和RUL。Zhang等^[17]通过使用视觉技术从电压曲线图像中提取特征,并结合电池电压图像和电池组平均电压序列,构建混合卷积神经网络以实现SOH估计。以上研究都为电池组SOH和RUL预测做出贡献,但是往往都依赖于单一或少数几个HI,可能无法全面捕捉电池组内部的不一致性。因此,本文的第1个动机在于构建一种电池组不一致性评估方法,通过融合多个不一致性指标信息,得到不一致性评估结果,从而为后续RUL预测提供支持。

此外,在实际应用中,制定维护策略不仅要依据RUL的预测结果,还需考虑不同级别的安全与紧急需求,这一点在现有研究中并未得到充分考虑。相比传统的点预测方法,区间预测通过提供一个包含上下限的预测范围,可在潜在故障发生前为用户提供更充分的预警,从而支持更加灵活的决策,降低不必要的经济损失和安全风险。模糊信息粒化(fuzzy information granulation, FIG)能够将原始时间序列转化为带有上下界信息的模糊颗粒,为区间预测的实现提供有力支持。在此基础上,一些研究开始探索FIG在区间预测中的应用。2020年,Pan等^[18]结合FIG和最小二乘支持向量机(least squares support vector machine, LSSVM)对锂离子电池SOH进行区间估计。2022年,Pang等^[19]引入语言描述方法实现对RUL的区间预测,并充分考虑了电池退化过程中可能出现的容量回升现象。2023年,为克服FIG过程中窗口分割宽度需人为设定的局限,Pang等^[20]提出一种自适应时间窗口分割算法,该算法能适应不同电池退化数据,从而为RUL区间预测提供更灵活且可靠的解决方案。2025年,Xia等^[21]针对FIG不能区分包含不同退化趋势的时间序列的问题,提出一种考虑时间序列趋势的分割策略,并结合门控循环单元实现锂离子电池RUL的区间预测。尽管上述研究均以区间形式对锂离子电池SOH或RUL进行了预测,但它们的研究对象聚焦于电池单体。然而,在实际应用场景下,电池组由多个电池单体以串联或并联的方式组合而成,单体间在电压、温度等方面存在不可避免的不一致性,这种不一致性在电池组使用过程中不断加剧,显著影响电池组的退化^[22]。基于此,本研究结合FIG与LSTM网络,提出一种联合电池组不一致性评估的RUL区间预测方案。方案首先对电池组的不一致性进行评估,然后将评估结果应用于电池组的RUL区间预测模

型,从而支持用户根据不同紧急程度做出更加合理的维护决策,降低安全事故发生的风险^[19]。

综上所述,本文提出一种联合电池组不一致性评估的 RUL 区间预测方案,方案将不一致性评估结果作为 RUL 预测的基础,以提高预测的准确性。具体步骤如下:首先,从电池组老化数据中提取出多个能揭示不一致性的 HI;接着,采用基于样本熵的方法对这些 HI 进行客观加权,以评估电池组的不一致性;其次,将不一致性评估结果作为一个补充 HI,并利用 FIG 技术将所有 HI 及容量序列转换为包含上界、中值和下界信息的模糊颗粒,为后续点预测和区间预测提供支持;最后,将经过 FIG 处理后的序列作为输入,以容量序列中值、上界和下界作为输出,训练 LSTM 神经网络,进而对电池组 RUL 分别进行点预测和区间预测。

1 不一致性评估

1.1 实验数据

本文使用 Kwon 等^[16]收集的电池组老化数据集。电池组由 8 个单体电池串联而成,单体为棱柱型,阴极材料为锂锰氧化物,阳极为石墨。电池组额定容量为 63 Ah,单体额定电压为 3.7 V。数据集中包括电池组电压、电流,单体电压,以及温度等数据。实验在 60 °C 的高温条件下进行,以在合理的时间内检验电池组的退化性能和 RUL。为了全面监测电池组的温度分布,实验中设置了 10 个温度测量点,数据采集的频率为 1 次/s。

电池组老化测试在恒流恒压条件下进行。其中充电过程包括恒流和恒压两个步骤。恒流充电阶段,充电电流保持在 1 C,直到电池组所有单体的平均电压达到 4.12 V。恒压充电阶段,电池组单体的平均电压保持在 4.12 V,直到充电电流降至 0.05 C。放电过程在 1 C 恒流模式下进行,直到平均电压达到 3 V 截止电压。充电和放电之间有 2 h 休息时间。老化试验重复进行,直到电池组达到失效阈值,即额定容量的 80%。

1.2 健康指标提取

电池组不一致性来源于生产制造过程中的初始性能差异,这些差异导致了电池间初始容量和内阻不同。随着电池组的使用,这些差异逐渐加剧,引发电流分布不均,进一步造成电压、温度以及荷电状态的不一致。准确评估电池组的不一致性和表征其退化状态,关键在于提取能够反映这种不一致性的 HI。

由于电池电压相对易于测量,因此它通常被用作一个关键指标来直观反映电池组的不一致性。同时,电池内部产热与散热存在不均衡,加之电池组内热量沿温度梯度传递并相互作用,进而引发温度分布的不一致性,这

对电池的使用寿命产生了不利影响^[23]。为获得更全面的评估结果,本研究综合考虑了电压和温度两个方面,从中提取了一系列 HI,包括电压变异系数,温度变异系数,电压极差,温度极差,电压四分位差和温度四分位差,作为后续不一致性评估和 RUL 区间预测的基础。

1) 变异系数

变异系数是概率分布中衡量离散度的一个指标,通过标准差与平均值的比值来量化数据的相对波动程度,从而反映不同样本在单位均值基础上的离散度^[24]。本文选择单体电压的变异系数(v_CV)和 10 个温度测量点的变异系数(t_CV)作为 HI,分别从电池组内温度标准差和单体电压的标准差相对于其平均水平的离散程度来反映不一致性。 v_CV 和 t_CV 数值越大,意味着电池组内部不一致性越显著。变异系数的计算公式如式(1)所示。

$$CV = \frac{\sigma}{\mu} \quad (1)$$

式中: σ 表示标准差; μ 表示平均值。

2) 极差

极差是一种衡量数据离散程度的方法,通过计算数据样本中最大值与最小值间的差距,直观表示数据的数值跨度和分布范围。本文采用电压极差(v_range)和温度极差(t_range)作为一组 HI,以量化电池组内电压和温度的不一致性,这些指标直接反映了温度和电压数据的整体数值范围。较大的极差值则表明电池组内部的不一致性较高。极差的计算如式(2)所示。

$$R = x_{\max} - x_{\min} \quad (2)$$

式中: x_{\max} 表示最大值; x_{\min} 表示最小值。

3) 四分位差

四分位差,即上四分位数与下四分位数之间的差值,是衡量数据集中间部分离散程度的一个重要指标。与极值所体现的数据整体范围不同,分位数差反映数据中间区域的波动情况。本文选择电压四分位差(v_iqr)和温度的四分位差(t_iqr)作为一组 HI。若 v_iqr 和 t_iqr 的值较小,意味着数据中间 50% 的部分分布更为密集,显示出较好的一致性;相反,若 v_iqr 和 t_iqr 的值较大,则表明这 50% 的数据分布较为分散,中间部分的一致性较差。具体的计算公式如下:

$$Q = Q_3 - Q_1 \quad (3)$$

式中: Q_3 表示数据中的第 75 百分位数,即将数据集按大小顺序排列后,位于 75% 位置的数据点; Q_1 表示数据中的第 25 百分位数。

本文所提 HI 随循环次数增加的变化趋势如图 1 所示,可以看出,所有 HI 均随着循环次数的增加总体上呈现出上升趋势,这表明电池间不一致性在循环过程中持续加剧。具体地,电压类指标在前 100 个循环周期内变

化趋势较为平缓,之后转为逐步上升的趋势;而温度类指标的变化则表现出明显的阶段性特征,在约 150 个循环

周期处出现拐点,呈现急剧上升趋势。

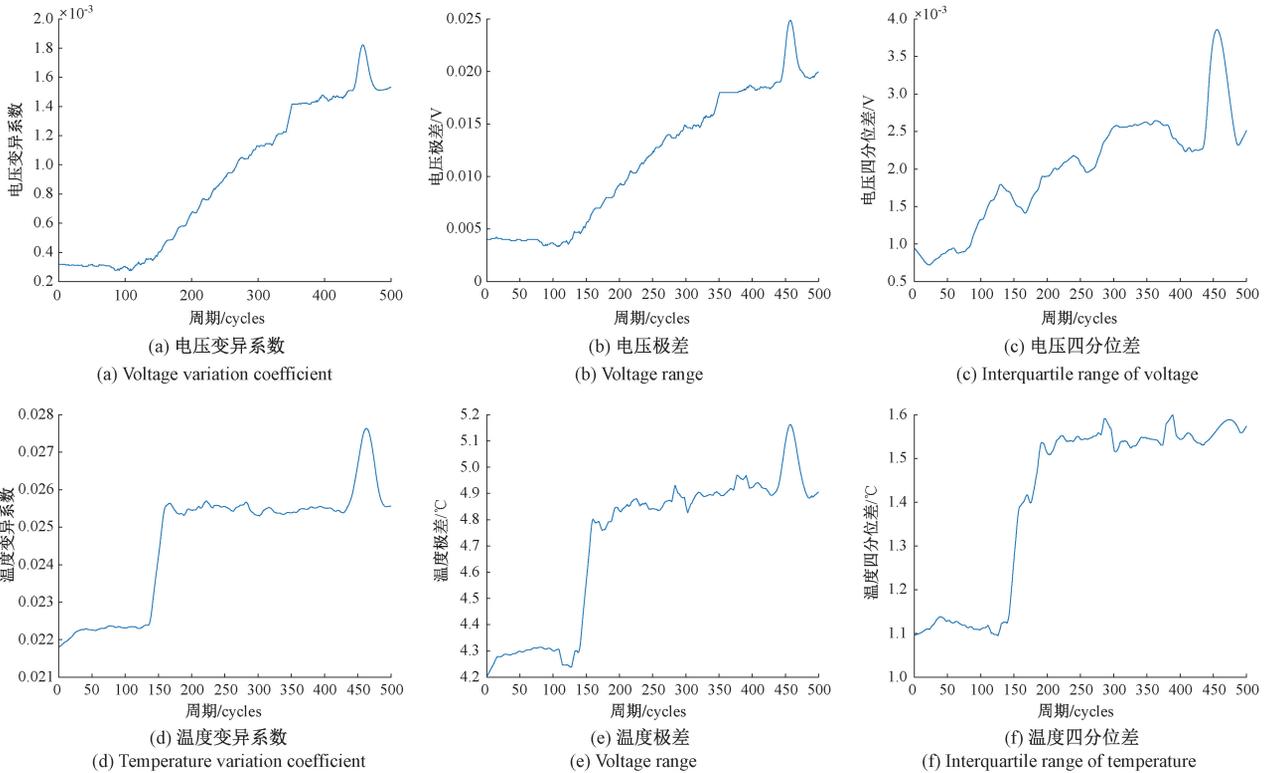


图 1 HI 提取结果

Fig. 1 The results of extracted HIs

此外,为评估所提 HI 的质量,本文使用 Spearman 相关系数对电池组容量与所提 HI 之间的相关性进行分析,结果如表 1 所示。从表 1 可以观察到所有 HI 与容量的相关系数均为负值,表明反映不一致性的 HI 与电池组容量呈负相关。进一步观察,所有相关系数的绝对值均 >

0.77,说明所提 HI 与容量之间具有强相关性。为使分析结果具有统计学意义,进行了 p 值显著性检验。结果表明,在 0.01 的置信水平下,所有 p 值均 < 0.01,表明所提 HI 与容量显著相关。

表 1 提取的 HI 与容量的相关性分析

Table 1 Correlation analysis between extracted HIs and capacity

	v_CV	t_CV	v_range	t_range	v_iqr	t_iqr
相关系数	-0.963 7	-0.773 7	-0.962 4	-0.931 2	-0.912 4	-0.846 3
p 值	$4.050\ 0 \times 10^{-322}$	0	$4.207\ 8 \times 10^{-296}$	$2.431\ 7 \times 10^{-220}$	$2.504\ 5 \times 10^{-195}$	$2.509\ 7 \times 10^{-138}$

1.3 基于样本熵的客观赋权

考虑到各 HI 分别从不同角度刻画电池组不一致性特征,单个指标难以全面反映其整体不一致性,而多个不同指标之间又可能存在信息冗余,因此本文采用信息融合的方法对各个 HI 进行加权,以综合各指标所包含的信息,从而实现电池组不一致性评估。样本熵 (sample entropy, SampEn) 作为一种量化时间序列复杂性和不确定性的客观方法,已被广泛应用于评价系统的随机性和复杂性^[10,25]。其核心思想在于衡量时间序列中新模式

出现的概率,从而反映系统的不可预测性。当序列更加不可预测时,其熵值越高,表明该序列变化模式更复杂,可能包含更丰富的信息;反之,熵值较低的指标通常表现出较强的规律性,对应的信息重要性相对较小^[26]。通过将样本熵值作为权重分配依据,可使不确定性更高、信息量更丰富的指标被赋予更高权重,进而为多个反映不一致性的 HI 在信息融合过程中提供一种基于时间序列波动特征的客观加权依据。

对于一个长度为 N 的时间序列 $\mathbf{X} = [x(1), x(2), \dots, x(N)]$,样本熵的计算步骤如下。

1) 将原始序列重构为 m 维的向量序列:

$$\mathbf{X}_i^m = [x(i), \dots, x(i+m-1)], i = 1, 2, \dots, N-m+1 \quad (4)$$

2) 计算任意两个向量 \mathbf{X}_i^m 和 \mathbf{X}_j^m 的距离, 并将其定义为:

$$d[\mathbf{X}_i^m, \mathbf{X}_j^m] = \max_{k \in (0, m-1)} (|x(i+k) - x(j+k)|) \quad (5)$$

3) 设定一个容差 r , 对于 \mathbf{X}_i^m , 统计距离 $d[\mathbf{X}_i^m, \mathbf{X}_j^m] \leq r$ 的个数, 将其表示为 B_i , 计算 B_i 占向量总数的比例 $B_i^m(r)$, 并计算所有比例的平均值 $B_m(r)$ 。

$$B_i^m(r) = \frac{1}{N-m-1} B_i \quad (6)$$

$$B_m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} B_i^m(r), 0 \leq i \leq N-m+1 \quad (7)$$

4) 将向量长度增加到 $m+1$, 重复步骤 1)~3), 计算 $B_{m+1}(r)$, 那么时间序列的样本熵可以表示为:

$$\text{SampEn}(m, r, N) = -\ln \left[\frac{B_{m+1}(r)}{B_m(r)} \right] \quad (8)$$

在实际应用中, 容差 r 需要根据实际情况来选择, 通常取数据标准差的 0.1~0.25 倍, 本文将其设置为标准差的 0.2 倍。随后, 对样本熵的结果进行归一化处理, 并将其作为权重分配给每个 HI, 通过加权融合各指标信息, 最终获得一个不一致性评估结果。

1.4 不一致性评估和分析

利用 1.3 节得到的基于样本熵的客观赋权结果构建不一致性评估指标。首先将样本熵的值作为权重分配给每个 HI, 以计算不一致性的评价指标 ξ_i :

$$\xi_i = \sum_{j=1}^n w_{ij} x_{ij} \quad (9)$$

式中: i 表示周期数; j 表示特征; n 是特征个数; w_{ij} 是基于样本熵计算得到的第 i 个周期的第 j 个特征的权重; x_{ij} 表示第 i 个周期的第 j 个特征的值。

然后, 通过不一致性评价指标与电池组初始不一致性的比值, 来确定电池组的不一致性程度。这一比值可以量化电池组性能退化的相对变化, 从而更准确地评估其不一致性。

$$\text{Incon}(i) = \frac{\xi_i}{\xi_1} \quad (10)$$

将电池组的初始不一致性设置为 1, 基于样本熵加权的电池组不一致性评估结果如图 2 所示。从图 2 可以看到, 随着充放电周期的增加, 电池组的不一致性整体呈现出上升的趋势。在电池组退化的初期阶段, 不一致性的增长速度相对较缓; 大约在经过 100 个充放电周期之后, 不一致性开始加速增长, 呈现出急剧上升的趋势。

随后, 对上述电池组不一致性评估结果与电池组容量进行相关性分析。采用 Spearman 相关系数进行分析,

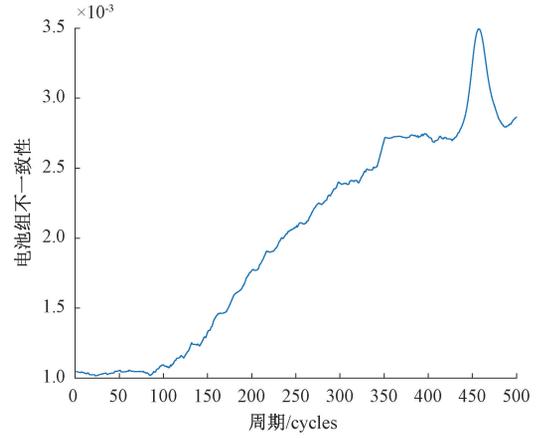


图 2 电池组不一致性评估结果

Fig. 2 The result of battery pack inconsistency evaluation

结果显示相关系数为 -0.9862 , 这一极高的负相关值表明不一致性评估结果能够有效地反映电池组的退化程度。基于这一发现, 将不一致性评估结果作为一个关键特征, 并将其应用于后续 RUL 预测中。

2 电池组 RUL 预测

2.1 模糊信息粒化处理

电池组 RUL 区间预测的本质在于能够给出一个预测范围, 这就需要将原始时间序列处理为包含上下界的形式, FIG 可以实现这一需求^[19]。通过 FIG 处理, 将原始时间序列处理为包含上下界信息的模糊颗粒, 这为区间预测研究提供了一种有效的解决方案。FIG 理论可以表示如下:

$$g \triangleq (x \text{ is } G) \text{ is } \lambda, x \in X \quad (11)$$

FIG 的过程包括两个步骤, 时间窗口分割和模糊颗粒化处理。对于原始时间序列 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$, 使用定宽分割将其划分为宽度为 w 的 t 个子序列 $\{T_1, T_2, \dots, T_t\}$ 每一个子序列 T_i 就是一个时间窗。考虑到数据量的大小, 在本文将窗口宽度设置为 5。

合理划分时间窗口后, 在每一个窗口上创建一个模糊颗粒。这一步骤的关键是选择合适的隶属度函数来构建模糊规则。本文选择三角隶属度函数, 其形式可表示为:

$$f(x) = \begin{cases} 0, & x < a \\ \frac{x-a}{m-a}, & a \leq x \leq m \\ \frac{b-x}{b-m}, & m < x \leq b \\ 0, & x > b \end{cases} \quad (12)$$

式中: a 和 b 分别表示时间窗的下界和上界; m 表示时间

窗的中值。提取的 HI 被 FIG 处理后的结果如图 3 所示。其中 U_p 、 Low 和 R 分别表示颗粒的上界、下界和平均水

平。从图 3 可以看出,通过 FIG,原始时间序列被处理为包含上界,下界以及中值信息的子序列。

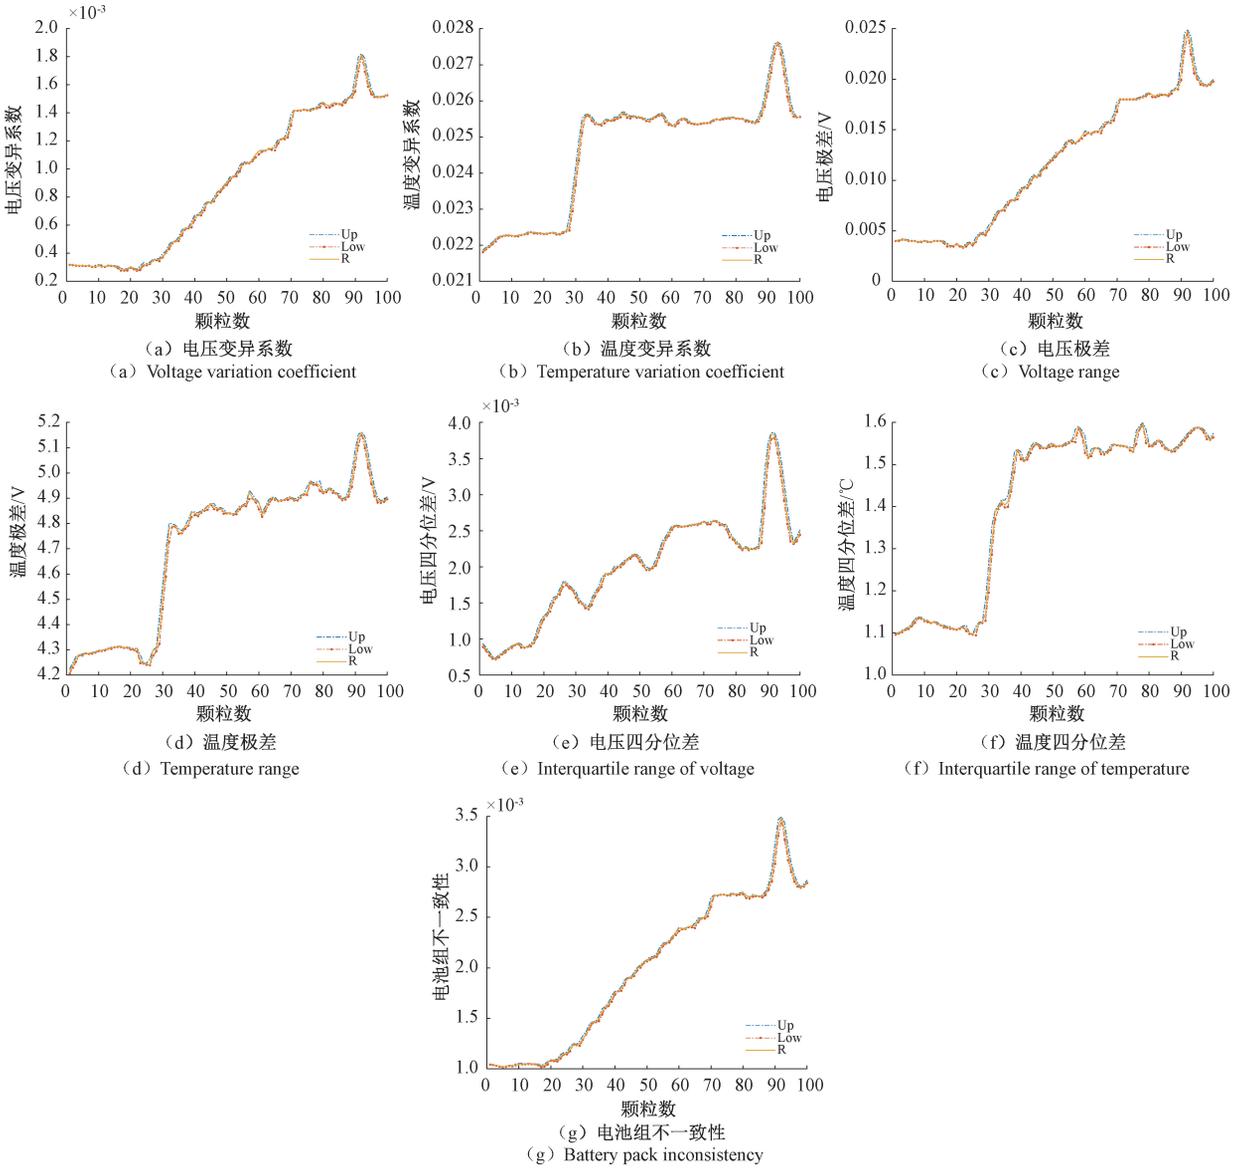


图 3 提取的 HI 被 FIG 处理后的结果

Fig. 3 The results of extracted HIs processed by FIG

2.2 LSTM 神经网络

LSTM 神经网络是传统的循环神经网络 (recurrent neural network, RNN) 的一种变体。包含 3 个门控机制 (遗忘门, 输入门和输出门) 及一个单元状态, 解决了 RNN 中梯度消失和爆炸的问题^[27]。鉴于 LSTM 在处理时间序列数据方面的优势, 本文采用 LSTM 建立 RUL 预测模型, 以获得更准确和可靠的预测结果。

LSTM 网络的第 1 层为遗忘门, 用于选择哪些信息被丢弃, 其输出范围是从 0~1 的数值, 值为 0 说明所有信息都应该被丢弃。遗忘门可以表示为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (13)$$

式中: f_t 为遗忘门的输出; σ 表示 sigmoid 激活函数; h_{t-1} 和 x_t 分别表示在 $t-1$ 时刻的隐藏状态向量和遗忘门的输入向量; W_f 和 b_f 分别表示权重矩阵和偏置项。

第 2 层为输入门, 用来决定上一个单元状态的哪些信息要添加到下一个单元状态。输入门可表示为:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (14)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (15)$$

式中: i_t 表示输入门的输出; \tilde{c}_t 表示候选单元状态; W_i

表示权重矩阵; \mathbf{b}_i 和 \mathbf{b}_c 是偏置项。通过遗忘门和输入门,可以将单元状态更新为 \mathbf{c}_i :

$$\mathbf{c}_i = \mathbf{f}_i \cdot \mathbf{c}_{i-1} + \mathbf{i}_i \cdot \tilde{\mathbf{c}}_i \quad (16)$$

最后一层为输出门,通过 sigmoid 函数决定单元状态的哪些部分将输出,过程可以表示为:

$$\mathbf{o}_i = \sigma(\mathbf{W}_o \cdot [\mathbf{h}_{i-1}, \mathbf{x}_i] + \mathbf{b}_o) \quad (17)$$

式中: \mathbf{o}_i 表示输出门的输出; \mathbf{W}_o 和 \mathbf{b}_o 分别表示输出门的权重矩阵和偏置项。

最终单元状态的输出可以表示为:

$$\mathbf{h}_i = \mathbf{o}_i \cdot \tanh(\mathbf{c}_i) \quad (18)$$

2.3 联合不一致性评估与 RUL 预测的综合框架

基于样本熵的不一致性评估方法,将其与 FIG 和 LSTM 技术相结合,提出一种联合不一致性评估与 RUL 预测的框架,如图 4 所示。

步骤 1) 特征提取。首先从电池组测量数据中提取温度和电压的变异系数、极差和四分位差作为初始的 6 个 HI,这些指标能够提供电池组内部不一致性的重要信息。

步骤 2) 不一致性评估。采用样本熵对步骤 1 中提取的 HI 进行客观赋权,通过加权融合各指标信息,最终获得一个不一致性评估结果。

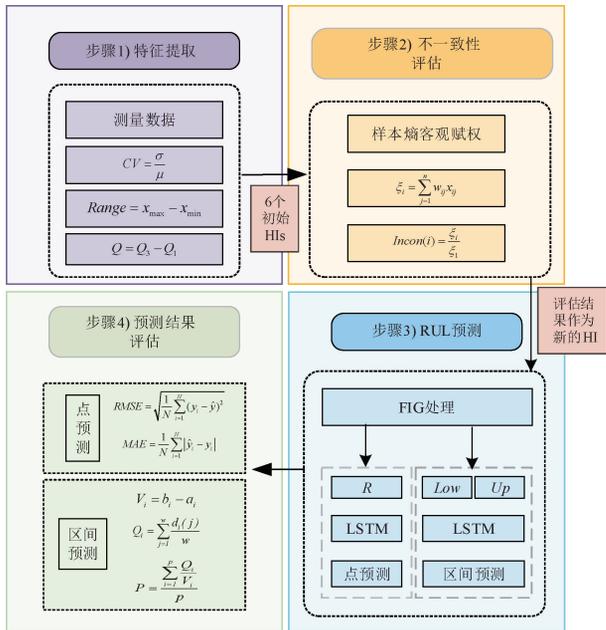


图 4 联合不一致性评估与 RUL 预测框架

Fig. 4 Joint inconsistency evaluation and RUL prediction framework

步骤 3) RUL 预测。将步骤 2) 中得到的不一致性评估结果作为一个新的 HI,与其他 HI 一起进行 FIG 处理。通过 FIG,原始时间序列数据被处理为 3 个序列, R 、 Low 和 Up 。接下来,将这 3 个序列作为 LSTM 的输入进行建

模。其中 R 序列用于 RUL 点预测, Low 和 Up 序列用于 RUL 区间预测。

步骤 4) 预测结果评估。引入两类评估指标分别对点预测和区间预测的结果进行评估。其中均方根误差 (RMSE) 和平均绝对误差 (MAE) 用来评估点预测的精度, V_i 、 Q_i 和 P 用来评估区间预测的质量。

3 实验结果和分析

3.1 电池组 RUL 预测结果

为了评估模型在不同训练数据规模下的适应性和鲁棒性,本文设计了不同起始点的 RUL 预测实验。实验中分别选取前 30%、50% 和 70% 个颗粒的 R 、 Low 和 Up 序列作为输入,同时将容量的 R 、 Low 和 Up 序列作为输出,用于训练 LSTM 模型。随后,利用训练好的模型对容量的真实值及其上下界进行预测。

将 FIG 处理后的结果从颗粒级扩展到整个电池组周期,分别对应于 150、250 和 350 的预测起始点。3 种训练策略下的点预测结果如图 5 所示。其中蓝色曲线表示预测值,红色曲线表示容量真实值,灰色虚线为失效阈值,对应于电池组初始容量的 80%。从图 5 可以看出,使用所提策略得到的预测曲线与真实的容量退化曲线比较接近,并且随着起始点的后移,预测曲线更加接近实际值。这一结果表明,在不同训练数据的情况下,所提模型能够实现有效的点预测。

进一步地,不同起始点下的电池组区间预测结果如图 6 所示,其中,灰色阴影区域表示预测区间,红色曲线表示区间预测的上界,蓝色曲线则代表区间的下界,而黄色曲线则表示容量的真实值。从图 6 可以清晰观察出,在大多数情况下,上下界成功覆盖了真实值。并且随着预测起始点的后移,预测区间的范围逐渐变窄。以上结果表明,本文模型能够提供有效的电池组区间预测结果。

表 2 为电池组在不同起始点的 RUL 点预测和区间预测结果。从表 2 可以看出,3 种不同起始点的情况下,RUL 点预测值与真实值之间的误差均在 15 个周期以内;同时,RUL 区间预测结果均覆盖真实 RUL 值。此外,随着训练数据量的增加,RUL 点预测结果越来越趋近于实际值,且 RUL 预测区间越来越窄。综上所述,本文所提策略可以实现准确且鲁棒的电池组 RUL 点预测和区间预测。

表 2 不同起始点的 RUL 预测结果

Table 2 The RUL prediction results at different starting points

预测起始点	真实 RUL	RUL 点预测	RUL 预测区间
150	455	470	[440,460]
250	455	465	[445,460]
350	455	450	[450,455]

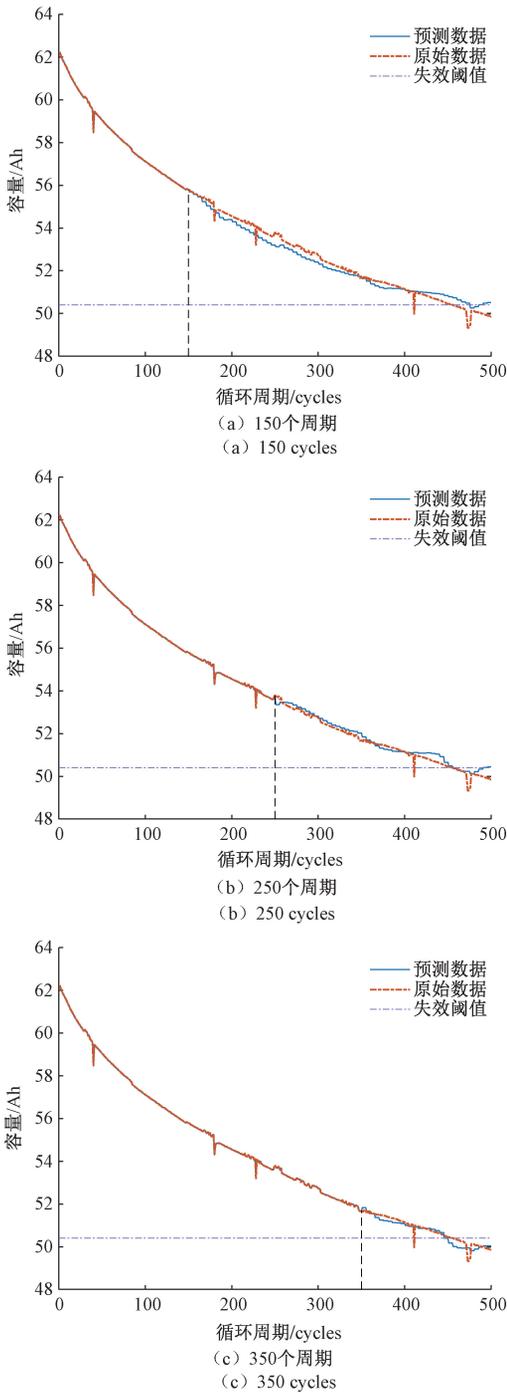


图 5 不同起始点的点预测结果

Fig. 5 Point prediction results at different starting points

3.2 实验结果分析

为了更全面地评估所提策略的 RUL 预测结果,引入两类评价指标。一类是通用指标 RMSE 和 MAE,用来评估点预测的精度。计算公式如式(19)、(20)所示。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2} \quad (19)$$

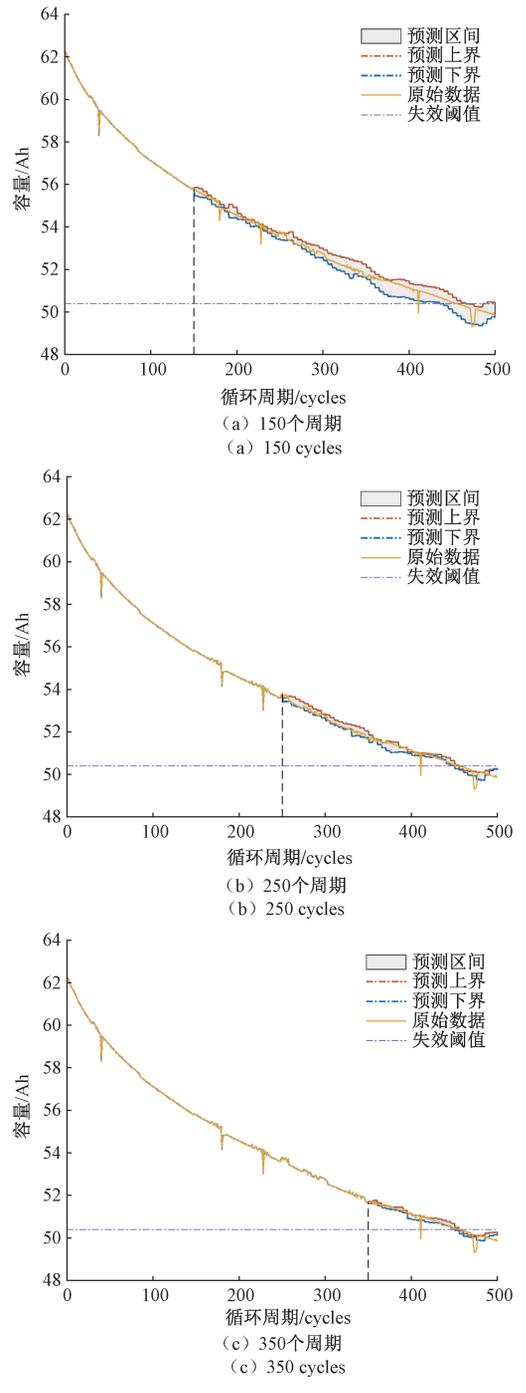


图 6 不同起始点的区间预测结果

Fig. 6 Interval prediction results at different starting points

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (20)$$

式中: N 为样本数目; y_i 表示真实值; \hat{y}_i 表示预测值。

另一类是评价生成区间预测质量的指标,分别是用于衡量区间上下界宽度的特异性准则 V ,以及评估区间包含真实值程度的覆盖率准则 Q 。对于第 i 个时间窗口 T_i ,这些指标可以表示如下:

$$V_i = b_i - a_i \quad (21)$$

$$Q_i = \sum_{j=1}^w \frac{d_i(j)}{w} \quad (22)$$

$$d_i(j) = \begin{cases} 0 & x_j^i \notin [a_i, b_i] \\ 1 & x_j^i \in [a_i, b_i] \end{cases} j = 1, 2, \dots, w \quad (23)$$

式中: $[a_i, b_i]$ 为预测区间; w 为时间窗口的宽度。通常, 在区间宽度 V_i 保持不变的情况下, 覆盖率 Q_i 的值越大, 表明预测结果越准确。同样, 对于固定的 Q_i, V_i 的值越小, 表明预测结果精度越高。为全面反映预测区间的宽度和覆盖率, 引入综合评价指标 P 用于平衡覆盖率指标 Q_i 和特异性指标 V_i, Q_i 值越大、 V_i 越小, P 值越大, 区间预测的结果越理想。 P 的定义如下:

$$P = \frac{\sum_{i=1}^p \frac{Q_i}{V_i}}{p} \quad (24)$$

式中: p 表示时间窗口的个数。

不同起始点的点预测和区间预测评价结果如表 3 所示, 其中 \bar{V} 和 \bar{Q} 分别表示 V_i 和 $Q_i (i = 1, \dots, p)$ 的平均值。从表 3 可以看出, 不同起始点的点预测误差 RMSE 和 MAE 均小于 0.32 Ah, 这表明模型预测精度较高; 此外, 随着起始点的后移, 预测误差逐渐减小。对于区间预测的评估结果, 区间预测的宽度 \bar{V} 都小于 0.48, 覆盖率 \bar{Q} 均大于 0.58, 表明区间预测效果较好。此外, 随着训练数据的增加, 区间宽度 \bar{V} 越来越窄, 区间覆盖率 \bar{Q} 也越来越小, 这是由于区间宽度变窄导致区间范围包含更少的实际值; 对于综合评价指标 P , 其值也在不断增大, 这表明了区间预测性能的提升。

表 3 不同起始点的点预测和区间预测评价结果

Table 3 The evaluation results of point prediction and interval prediction at different starting points

起始点	点预测		区间预测		
	RMSE/Ah	MAE/Ah	\bar{V}	\bar{Q}	P
150	0.316 6	0.265 9	0.476 6	0.847 1	1.979 1
250	0.241 9	0.180 3	0.243 4	0.602 0	2.271 1
350	0.208 6	0.160 6	0.161 8	0.580 2	3.619 8

3.3 对比试验分析

为进一步验证所提模型在预测性能上的优势, 在保持 HI 选择、融合和 FIG 处理方式一致的前提下, 将本文采用的 LSTM 与多层感知机 (multilayer perceptron, MLP)、RNN 和 LSSVM 的预测结果进行对比。表 4 为各模型在不同预测起始点下点预测和区间预测的评价结果。点预测精度方面, FIG-LSTM 模型的 RMSE 和 MAE 均低于其他 3 个模型; 区间预测质量方面, FIG-LSTM 模型的综合评价指标 P 值均高于其他模型。综上所述, 无

论是在点预测精度还是区间预测质量方面, 本文所提模型都具有明显优势。

表 4 不同模型的点预测和区间预测的评价结果

Table 4 Point prediction and interval prediction results evaluation for different models

起始点	模型	点预测		区间预测
		RMSE/Ah	MAE/Ah	P
150	FIG-LSTM	0.316 6	0.265 9	1.979 1
	FIG-MLP	0.462 6	0.354 9	1.272 0
	FIG-RNN	0.477 9	0.378 8	1.168 2
	FIG-LSSVM	0.517 7	0.382 9	0.933 8
250	FIG-LSTM	0.241 9	0.180 3	2.271 1
	FIG-MLP	0.361 5	0.266 0	1.724 1
	FIG-RNN	0.385 6	0.284 2	1.633 0
	FIG-LSSVM	0.304 8	0.230 2	1.943 0
350	FIG-LSTM	0.208 6	0.160 6	3.619 8
	FIG-MLP	0.308 0	0.247 5	2.470 4
	FIG-RNN	0.341 1	0.291 8	2.239 5
	FIG-LSSVM	0.249 2	0.198 8	2.708 9

4 结 论

电池组退化过程中, 准确评估其不一致性和 RUL 对于保障系统运行的安全性和稳定性至关重要。本文提出一种综合策略, 旨在同时进行电池组不一致性评估和 RUL 区间预测。首先, 从电压和温度两个维度出发, 提取多个反映不一致性的 HI, 这些指标为后续不一致性评估和 RUL 预测提供了基础。其次, 采用样本熵对提取的 HI 进行了客观赋权, 从而进行不一致性评估。评估结果表明, 不一致性对电池组的退化有显著影响。接着, 将不一致性评估结果作为一个补充的 HI, 并运用 FIG 将所有序列转化为包含主要信息的模糊颗粒, 用于电池组的 RUL 预测。这种方法在提供点预测的基础上, 能够根据不同应用场景的需求, 提供灵活的预测范围。最后, 通过电池组老化数据, 验证了所提出策略的可行性和有效性。通过引入两类评价指标分别对 RUL 点预测和区间预测结果进行量化评价, 实验结果表明, 该策略能够有效实现不一致性评估和 RUL 区间预测。在未来工作中, 将进一步利用真实电动汽车的数据集对所提出的策略进行进一步的验证和优化, 以确保其在实际应用中的有效性和适用性。

参考文献

[1] ARSHAD F, LIN J, MANURKAR N, et al. Life cycle assessment of lithium-ion batteries: A critical review[J]. Resources, Conservation and Recycling, 2022, 180: 106164.

[2] HU X, FENG F, LIU K, et al. State estimation for advanced battery management: Key challenges and future

- trends[J]. *Renewable and Sustainable Energy Reviews*, 2019, 114: 109334.
- [3] 刘彤宇, 陆起涌, 李旦, 等. 随机工况下基于改进 ANFIS 的锂电池容量衰减实时估计[J]. *仪器仪表学报*, 2024, 45(5): 218-226.
- LIU T Y, LU Q Y, LI D, et al. Real-time estimation of lithium battery capacity degradation based on an improved neural fuzzy inference system under random operating conditions[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(5): 218-226.
- [4] 李春喜, 乔涵哲, 姚刚, 等. 基于 RBF-BLS 面向电动汽车低碳安全出行的 SOH 估计方法[J]. *上海交通大学学报*, 2024, 58(9): 1454-1464.
- LI CH X, QIAO H ZH, YAO G, et al. SOH estimation method based on RBF-BLS for low-carbon and safe travel of electric vehicle [J]. *Journal of Shanghai Jiaotong University*, 2024, 58(9): 1454-1464.
- [5] 赵珍, 庞晓琼, 董渊昌. 多健康指标的锂电池剩余使用寿命区间预测[J]. *中北大学学报(自然科学版)*, 2023, 44(3): 263-271.
- ZHAO ZH, PANG X Q, DONG Y CH. A Remaining useful life interval prediction for lithium-ion batteries considering multiple health indicators [J]. *Journal of North University of China (Natural Science Edition)*, 2023, 44(3): 263-271.
- [6] WENG C, FENG X, SUN J, et al. State-of-health monitoring of lithium-ion battery modules and packs via incremental capacity peak tracking[J]. *Applied Energy*, 2016, 180: 360-368.
- [7] SONG L, ZHANG K, LIANG T, et al. Intelligent state of health estimation for lithium-ion battery pack based on big data analysis[J]. *Journal of Energy Storage*, 2020, 32: 101836.
- [8] LYU Z, WANG G, GAO R. Synchronous state of health estimation and remaining useful lifetime prediction of Li-Ion battery through optimized relevance vector machine framework[J]. *Energy*, 2022, 251: 123852.
- [9] OUYANG Q, HAN W, ZOU C, et al. Cell balancing control for lithium-ion battery packs: A hierarchical optimal approach [J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(8): 5065-5075.
- [10] CHE Y, FOLEY A, EL-GINDY M, et al. Joint estimation of inconsistency and state of health for series battery packs[J]. *Automotive Innovation*, 2021, 4(1): 103-116.
- [11] CHANG C, WU Y, JIANG J, et al. Prognostics of the state of health for lithium-ion battery packs in energy storage applications[J]. *Energy*, 2022, 239: 122189.
- [12] ZHANG X, WANG Y, LIU C, et al. A novel approach of battery pack state of health estimation using artificial intelligence optimization algorithm[J]. *Journal of Power Sources*, 2018, 376: 191-199.
- [13] SONG Y, PENG Y, LIU D. Model-based health diagnosis for lithium-ion battery pack in space applications [J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(12): 12375-12384.
- [14] ZHOU Z, DUAN B, KANG Y, et al. Online state of health estimation for series-connected LiFePO₄ battery pack based on differential voltage and inconsistency analysis [J]. *IEEE Transactions on Transportation Electrification*, 2024, 10(1): 989-998.
- [15] HU X, CHE Y, LIN X, et al. Health prognosis for electric vehicle battery packs: A data-driven approach[J]. *IEEE/ASME Transactions on Mechatronics*, 2020, 25(6): 2622-2632.
- [16] KWON S, HAN D, PARK J, et al. Joint state-of-health and remaining-useful-life prediction based on multi-level long short-term memory model prognostic framework considering cell voltage inconsistency reflected health indicators [J]. *Journal of Energy Storage*, 2022, 55: 105731.
- [17] ZHANG J, ZHANG W, SUN B, et al. A novel method of battery pack energy health estimation based on visual feature learning[J]. *Energy*, 2024, 293: 130656.
- [18] PAN W, CHEN Q, ZHU M, et al. A data-driven fuzzy information granulation approach for battery state of health forecasting [J]. *Journal of Power Sources*, 2020, 475: 228716.
- [19] PANG X, ZHAO Z, WEN J, et al. An interval prediction approach based on fuzzy information granulation and linguistic description for remaining useful life of lithium-ion batteries [J]. *Journal of Power Sources*, 2022, 542: 231750.
- [20] PANG X, ZHAO Z, WEN J, et al. Considering the self-adaptive segmentation of time series in interval prediction of remaining useful life for lithium-ion battery [J]. *Journal of Energy Storage*, 2023, 70: 107862.
- [21] XIA G, JIA C, SHI Y, et al. Remaining useful life prediction of lithium-ion batteries by considering trend filtering segmentation under fuzzy information granulation [J]. *Energy*, 2025, 318: 134810.
- [22] 吴文进, 吴晶, 郭海婷, 等. 基于变论域模糊 PID 算法的锂电池组级联式均衡控制[J]. *电子测量与仪器学报*, 2024, 38(8): 137-144.
- WU W J, WU J, GUO H T, et al. Cascaded equalization control of lithium batteries based on variable discourse

domain fuzzy PID algorithm [J]. Chinese Journal of Electronic Measurement and Instrumentation, 2024, 38(8): 137-144.

- [23] TIAN J, FAN Y, PAN T, et al. A critical review on inconsistency mechanism, evaluation methods and improvement measures for lithium-ion battery energy storage systems [J]. Renewable and Sustainable Energy Reviews, 2024, 189: 113978.
- [24] HE Y, BAI W, WANG L, et al. SOH estimation for lithium-ion batteries: An improved GPR optimization method based on the developed feature extraction [J]. Journal of Energy Storage, 2024, 83: 110678.
- [25] DUAN B, LI Z, GU P, et al. Evaluation of battery inconsistency based on information entropy [J]. Journal of Energy Storage, 2018, 16: 160-166.
- [26] DELGADO-BONAL A, MARSHAK A. Approximate entropy and sample entropy: A comprehensive tutorial [J]. Entropy, 2019, 21(6): 541.
- [27] WANG Z, LIU N, CHEN C, et al. Adaptive self-attention LSTM for RUL prediction of lithium-ion batteries [J]. Information Sciences, 2023, 635: 398-413.

作者简介



庞晓琼 (通信作者), 2003 年于山西师范大学获得学士学位, 2006 年于中北大学获得硕士学位, 2013 年于华南农业大学获得博士学位, 现为中北大学副教授, 主要研究方向为复杂系统的预测和健康管理、信息安全和密码学。

E-mail: xqpang@nuc.edu.cn

Pang Xiaoqiong (Corresponding author) received her B. Sc. degree from Shanxi Normal University in 2003, M. Sc. degree from North University of China in 2006, and Ph. D. degree from South China Agricultural University in 2013, respectively. Now she is an associate professor at North

University of China. Her main research interests include prognostics and health management of complex systems, information security and cryptography.



李笑, 2022 年于山西大同大学获得学士学位, 现为中北大学硕士研究生, 主要研究方向为复杂系统的故障预测与健康管理。

E-mail: liix122@163.com

Li Xiao received her B. Sc. degree from Shanxi Datong University in 2022. Now she is a M. Sc. candidate at North University of China. Her main research interests include prognostics and health management of complex systems.



李晓杰, 2003 年于华北工学院获得学士学位, 2009 年于中北大学获得硕士学位, 2016 年于中北大学获得博士学位, 现就职于中北大学能源与动力工程学院, 主要研究方向为新能源汽车动力系统和智能车。

E-mail: lixiaojie16@nuc.edu.cn

Li Xiaojie received his B. Sc. degree from North China Institute of Technology in 2003, M. Sc. degree from North University of China in 2009, and Ph. D. degree from North University of China in 2016, respectively. Now he is working with the School of Energy and Power Engineering, North University of China. His main research interests include the power system of new energy vehicles and Intelligent vehicle.



张鑫, 2022 年于中北大学获得学士学位, 现为中北大学硕士研究生, 主要研究方向为复杂系统的故障预测与健康管理。

E-mail: 2418506191@qq.com

Zhang Xin received his B. Sc. degree from North University of China in 2022. Now he is a M. Sc. candidate at North University of China. His main research interests include prognostics and health management of complex systems.