

融合 Kolmogorov-Arnold 表示理论的锂离子电池健康状态预测网络*

赵雪彤¹⁾²⁾³⁾ 董哲康¹⁾²⁾⁴⁾ 周豪杰¹⁾²⁾³⁾ 林辉品¹⁾²⁾⁴⁾ 纪晓悦^{5)†}

1) (杭州电子科技大学电子信息学院, 杭州 310018)

2) (全省智能汽车电子研究重点实验室, 杭州 310018)

3) (塞浦路斯科技大学电子工程、计算机工程与信息学系, 利马索尔 3036, 塞浦路斯共和国)

4) (浙江大学电气工程学院, 杭州 310027)

5) (清华大学精密仪器系, 北京 100084)

(2025 年 10 月 6 日收到; 2025 年 10 月 31 日收到修改稿)

电动汽车锂离子电池健康状态 (state of health, SOH) 的精准预测对行车安全与电池管理系统优化具有重要意义. 然而, 现有方法普遍面临两大挑战: 其一, 依赖大量健康特征导致信息冗余与计算复杂度过高; 其二, SOH 时间序列的强非线性与非平稳性使传统神经网络易出现预测漂移和趋势振荡. 基于此, 本文提出一种融合 KAN (Kolmogorov-Arnold) 表示理论的混合神经网络——KanFormer, 用于高精度 SOH 预测. 该网络由局部特征提取、全局特征提取与预测输出三大模块构成: 局部特征提取模块利用 KAN 的平滑插值能力有效捕捉细粒度信息, 全局特征提取模块结合 Transformer 的复杂关系建模能力实现跨时间尺度的信息整合, 预测输出模块借助 KAN 的非线性拟合优势生成精准预测结果. 该模型一方面有效缓解了数据非线性与非平稳性导致的漂移与振荡问题, 另一方面实现了平均 15.32% 的训练速度提升. 在 Michigan Formation, HNEI, NASA 三个公开电池老化数据集上的验证结果表明, KanFormer 在均方误差 (MSE)、平均绝对误差 (MAE) 和决定系数 (R^2) 上分别达到了 0.0045, 0.041, 0.978 (Michigan 数据集) 与 0.00055, 0.0175, 0.996 (HNEI 数据集), 显著优于现有主流方法, 充分说明其在 SOH 预测中的高准确性和强泛化能力.

关键词: 锂离子电池, 健康状态, 时间序列预测, Kolmogorov-Arnold 表示理论

DOI: 10.7498/aps.75.20251359

CSTR: 32037.14.aps.75.20251359

1 引言

电池管理系统的核心作用是确保电动汽车中电池的高效、长寿与安全运行^[1]. 《新能源汽车产业发展规划 (2021—2035 年)》明确提出要建立动力电池全生命周期管理和回收利用体系, 并推动高能量密度与高安全性电池技术的突破, 这一战略目标进一步凸显了电池管理系统在实现电池全生命周期安全与高效运行中的关键作用. 锂电池凭借其

高能量密度、较长寿命和较轻重量, 已成为电动汽车的主流选择. 然而, 随着充放电循环的进行, 电极材料会发生膨胀收缩, 固体电解质界面逐渐增厚, 导致结构破坏与材料脱落, 最终引起锂离子迁移受阻和内阻增加, 造成容量持续衰退^[2]. 电池老化不仅降低续航能力, 也会增加短路、漏液等故障风险, 威胁车内人员生命安全. 因此, 对电池健康状态 (state of health, SOH) 进行及时准确的预测, 不仅能够提前识别电池退化趋势, 防范潜在安全风险, 还能剩余寿命评估、预防性维护、梯次利用

* 国家重点研发计划 (批准号: 2023YFB2504100) 和浙江省优秀青年基金 (批准号: LZYQ25F020005) 资助的课题.

† 通信作者. E-mail: jixiaoyue@mail.tsinghua.edu.cn

与智能调度提供决策依据,是实现电池系统高效、安全、经济运行的关键支撑技术.

目前,根据推理范式,电池 SOH 预测的主要方法可以分为基于模型的方法和基于数据的方法^[3]. 基于模型的 SOH 预测方法根据电池内部的电化学反应原理,通过建立电池的数学或物理模型,考虑电池的电气、化学以及环境因素来进行 SOH 预测^[4-9]. Lai 等^[7]提出了一种基于三阶扩展卡尔曼滤波算法的离散阿伦纽斯老化模型,实现不同老化条件下电池健康状态预测. Xiong 等^[8]提出了一种基于电化学模型的电池老化状态识别方法,实现全生命周期健康状态预测. Amir 等^[9]提出了一种基于时间相关 2-RC 电气等效电路模型的方法,实现电池健康状态预测. 然而,受限于建模复杂性、参数难以获取及泛化能力有限,基于模型的方法在实现高精度 SOH 预测方面仍存在显著挑战.

随着机器学习和深度学习技术的快速发展,基于数据驱动的多种方法已被广泛应用于锂离子电池 SOH 预测领域. 这些工作通过引入特征选择、迁移学习、注意力机制、双相关分析、自编码器与平滑滤波、异常检测与修正、多源信息融合以及融合模型等方法^[10-23],不断丰富锂离子电池 SOH 预测的建模思路与技术手段. Li 和 Tao^[18]提出了一种基于卷积神经网络的锂离子电池 SOH 在线预测方法,并利用不同工况下的加速老化数据进行预训练,再通过迁移学习在少量正常速率老化数据上进行微调和测试. Zhang 等^[19]提出了一种基于逐渐减小电流、双相关分析与门控循环单元的锂离子电池 SOH 预测方法,并通过单体电池与电池包的实验进行了验证. Chen 等^[20]提出了一种基于双向长短期记忆网络的锂离子电池 SOH 预测方法,通过电池老化循环测试提取健康指标 (health indicators, HIs) 作为模型输入,最终建立数据驱动的 SOH 预测模型并进行了验证. Ren 等^[21]提出了一种基于改进卷积神经网络与长短期记忆网络的锂离子电池退化预测方法,利用自编码器扩展数据特征维度,并结合平滑滤波器对预测结果进行处理,在实际数据集上进行了验证. Gu 等^[22]提出了一种结合数据预处理方法与卷积神经网络和 Transformer 框架的锂离子电池 SOH 预测方法,利用相关性分析与主成分分析进行特征选择和降维,并完成了训练与验证. Li 等^[23]提出了一种基于双向长短期记忆网络与 Transformer 的锂离子

电池 SOH 预测方法,在不同充电倍率下进行了电池老化实验,并从恒流充电阶段电压曲线中提取特征作为输入,对模型进行了训练和验证. 同时研究者也在探索更有效的健康指标提取方法^[24-29]. 尽管基于数据驱动的 SOH 预测方法在预测精度上取得了显著提升,但仍存在以下问题: 1) 当电池退化规律呈现非线性、非平稳等高度复杂特征,且电池个体间存在显著异质性时,预测结果易产生系统性漂移和趋势振荡; 2) 许多现有方法依赖大量健康指标,不仅导致信息冗余和模型计算负担增加,还在实际部署中显著延长特征提取时间,从而降低整体预测效率.

针对上述问题,本文提出一种新型混合神经网络 KanFormer 用于 SOH 预测,本文的主要贡献如下:

1) 轻量化健康特征选择机制. 针对主流算法普遍依赖 10 个以上健康特征的问题,本文结合增量容量分析 (incremental capacity analysis, ICA) 与相关性分析,仅选取 4 个关键健康特征,在保持高精度 SOH 预测性能的同时,使模型训练速度平均提升 15.32%,有效降低对大规模特征数据的依赖.

2) 基于 KAN 表示理论的混合预测模型. 提出一种融合 KAN (Kolmogorov-Arnold) 表示理论的 SOH 预测模型,通过引入可学习的核基激活函数实现自适应非线性映射,并结合 Transformer 编码器捕获跨循环与跨时间尺度的长程依赖,从而形成局部与全局信息的一体化表征,提升模型对复杂退化机理的刻画能力.

3) 跨数据集验证与稳健性提升. 在 Michigan Formation 与 HNEI 两个公开电池老化数据集上的多组对比与消融实验表明,所提模型在预测精度上均取得最优表现,并显著抑制了 SOH 预测中常见的系统性漂移与趋势振荡,验证了模型的高准确性与强泛化性.

2 电池数据描述与特征选择

2.1 数据集描述

Michigan Formation 电池数据集包含 NMC 111(Ni:Mn:Co = 1:1:1) 石墨软包电池在不同成型协议下的循环老化数据^[30]. 该数据集涵盖两种成型工艺: 基线成型 (baseline formation, BLForm) 与快速成型 (modified formation, MCForm). 图 1(a)

展示了在 25 °C 与 45 °C 环境下, 两种成型工艺电池的放电容量衰减曲线. 整体来看, 电池在初始阶段容量下降较为平缓, 通常在经历约 200 个循环后, 各电池的衰退速率才开始显著分化. 成型工艺对电池寿命具有关键影响: 在 BLForm 条件下, 电池表现出更快的容量衰减, 而在 MCForm 条件下, 退化速率明显减缓, 因而能够维持更长的循环寿命.




图 1 电池放电容量衰减曲线 (a) Michigan Formation; (b) HNEI
Fig. 1. Battery discharge capacity fade curves: (a) Michigan Formation; (b) HNEI.

HNEI(Hawaii Natural Energy Institute) 电池数据集是由夏威夷自然能源研究所公开发布的圆柱电池老化数据集 [31]. 该数据集在恒温条件下进行测试, 采用标准的 CC—CV 充电和 CC 放电策略. 如图 1(b) 所示, 多数电池的容量衰减曲线整体呈近似线性下降趋势. 随着循环次数的增加, 部分电池在后期出现退化速率显著加快并伴随明显波动, 体现出非线性特征及电池间差异性.

图 2 展示了 Michigan Formation 数据集中锂离子电池 CC 充电阶段的电压-时间变化与 CV 阶段的电流-时间变化. 随着循环次数的增加, CC 阶段的电压上升曲线逐渐变陡, 内阻上升、容量下降, 达到截止电压所需时间缩短. CV 阶段, 电流从截止电压开始逐步衰减, 且老化电池的电流衰减速度

减缓、CV 时间延长, 说明其在高电压下的电流接受能力降低、电化学反应速率减慢, 体现了电池性能的退化趋势.




图 2 电池充电过程中的 (a) 电压曲线和 (b) 电流曲线
Fig. 2. (a) Voltage curves and (b) current curves during battery charging.

2.2 特征选择

增量容量 (IC) 曲线能够反映电池在不同电压下的活性物质利用情况及电化学反应动力学特征, 如内阻增大、容量衰减、极化效应增强、化学反应效率降低等 [29]. 其计算过程如下:

$$\frac{dQ_{\text{chg}}}{dV_{\text{cell}}} = \frac{I_{\text{chg}} dt}{dV_{\text{cell}}} = I_{\text{chg}} \frac{dt}{dV_{\text{cell}}}, \quad (1)$$

其中, I_{chg} , t 和 V_{cell} 分别是充电阶段的电流、时间和电压.

图 3 所示为 Michigan Formation 数据集中 BLForm1 电池和 HNEI 数据集中电池 d 在不同老化阶段的 IC 曲线. 可以观察到, 随着循环次数的增加, IC 曲线整体呈现右移趋势, 峰值逐渐降低.

为进一步识别能够更有效表征电池容量衰减特征的电压区间, 基于 IC 曲线在峰值附近的特征形态划分并提取了多个电压区间段. 具体而

言, 对于 Michigan Formation 数据集, 本研究在 3.5—4.0 V 电压范围内以 0.1 V 为步长划分子区间, 分别计算各区间的充电时间与电压-时间积分面积, 并与 SOH 进行相关性分析. 结果表明, 3.55—3.65 V 与 3.70—3.75 V 区间的相关性最高. 结合图 3 所示 IC 曲线可知, 这两段分别对应主要反应峰的上升段与峰顶过渡区, 反映了电极极化增强、界面电阻上升及 SEI 膜逐渐增厚等典型老化特征. 对于 HNEI 数据集, 在 3.7—4.1 V 电压范围内采用相同策略提取健康特征. 分析结果显示, 3.85—3.95 V 和 3.90—4.00 V 区间与 SOH 的相关性最强, 对应于主反应峰的峰顶及右肩区域. 随着循环次数增加, 该区域的 IC 峰形出现衰减与右移, 揭示了活性物质逐渐衰退、极化加剧及扩散阻抗上升的老化机理.

强、界面电阻上升及 SEI 膜逐渐增厚等典型老化特征. 对于 HNEI 数据集, 在 3.7—4.1 V 电压范围内采用相同策略提取健康特征. 分析结果显示, 3.85—3.95 V 和 3.90—4.00 V 区间与 SOH 的相关性最强, 对应于主反应峰的峰顶及右肩区域. 随着循环次数增加, 该区域的 IC 峰形出现衰减与右移, 揭示了活性物质逐渐衰退、极化加剧及扩散阻抗上升的老化机理.

Pearson 相关系数反映线性相关程度, 而 Spearman 相关性则能衡量单调关系, 因此两者结合可全面评估特征的有效性. 采用 Pearson 和 Spearman 相关性分析, 分别衡量这些特征与电池容量退化曲线之间的线性关系与单调关系. Pearson 和 Spearman 相关性分析如下:

$$r_p = \frac{\sum (X_i - X_{\text{mean}})(Y_i - Y_{\text{mean}})}{\sqrt{\sum (X_i - X_{\text{mean}})^2 \sum (Y_i - Y_{\text{mean}})^2}}, \quad (2)$$

$$r_s = 1 - \frac{6}{n(n^2 - 1)} \sum dr_i^2, \quad (3)$$

其中, r_p 表示 Pearson 相关系数, r_s 表示 Spearman 相关系数, X_i 和 Y_i 分别表示样本数据, X_{mean} 和 Y_{mean} 分别表示均值, dr 表示两个变量秩之间的差.

图 4 展示了两个数据集中候选特征的 Pearson 与 Spearman 相关矩阵热图, 其中每个圆圈的颜色代表相关性的强弱. 表 1 列出了每个 HIs 和电池容量之间的相关度数值. 基于相关性分析结果, 结合




图 3 电池不同老化程度 IC 曲线 (a) BLForm1; (b) 电池 d
Fig. 3. IC curves at different aging stages: (a) BLForm1; (b) battery d.

表 1 HIs 与电池容量的相关性分析结果

Table 1. Correlation analysis between HIs and battery capacity.

Michigan formation				HNEI			
健康特征	Pearson	Spearman	平均值	健康特征	Pearson	Spearman	平均值
HI 1	0.649	0.522	0.585	HI 1	0.956	0.993	0.974
HI 2	0.649	0.515	0.582	HI 2	0.957	0.992	0.974
HI 3	0.973	0.964	0.968	HI 3	0.991	0.997	0.994
HI 4	0.973	0.964	0.968	HI 4	0.990	0.996	0.993
HI 5	0.907	0.851	0.879	HI 5	0.951	0.968	0.959
HI 6	0.907	0.852	0.879	HI 6	0.963	0.980	0.971
HI 7	0.959	0.964	0.961	HI 7	0.957	0.991	0.974
HI 8	0.960	0.964	0.962	HI 8	0.964	0.994	0.979
HI 9	0.953	0.625	0.789	HI 9	0.992	0.998	0.995
HI 10	0.961	0.676	0.789	HI 10	0.992	0.998	0.995
HI 11	0.979	0.965	0.972	HI 11	0.987	0.996	0.991
HI 12	0.979	0.965	0.972	HI 12	0.986	0.994	0.990
HI 13	0.958	0.851	0.904	HI 13	0.921	0.960	0.940
HI 14	0.964	0.881	0.922	HI 14	0.917	0.943	0.930
HI 15	0.969	0.968	0.968	/	/	/	/
HI 16	0.969	0.968	0.968	/	/	/	/

注: 表中加粗数据列为与容量相关性排名前四的健康特征.




图 4 相关性分析 (a) Michigan Formation-Pearson; (b) Michigan Formation-Spearman; (c) HNEI-Pearson; (d) HNEI-Spearman
Fig. 4. Correlation Analysis: (a) Michigan Formation-Pearson; (b) Michigan Formation-Spearman; (c) HNEI-Pearson; (d) HNEI-Spearman.

验证集结果表明, 随着特征数量增加, 模型复杂度和计算开销显著上升, 而性能提升趋于饱和, 当特征继续增加时, 信息冗余反而导致预测性能下降. 综合考虑验证集性能与模型复杂度, 最终从特征集中筛选出 4 个与容量高度相关的关键特征, 作为 HIs 用于电池健康状态预测建模.

3 方 法

本文提出了一种融合 KAN 表示理论的锂离子电池 SOH 预测方法, 如图 5 所示. 该方法以 KAN 为核心, 通过将激活函数迁移至连接边并引入可学习的基函数, 实现多维函数的局部可加分解, 从而在保持模型连续可微特性的同时显著提升平滑插值与非线性拟合能力. 相比依赖全局激活函数的传统 MLP, KAN 能在局部空间中灵活调整函数形态, 更好地捕捉复杂特征的非线性变化. 与此同时, Transformer 模块通过自注意力机制有效建模长程依赖关系, 增强了模型在时序数据中的全局关联理解与并行建模能力. 两者的结合使模型能够在时间与特征双维度上实现协同建模, 兼顾电池退化过程中缓慢衰减与阶段性突变的特征表现, 从而在预测

曲线的平滑性与变化敏感性之间取得更优平衡.

3.1 局部特征提取模块

局部特征提取可捕捉容量衰减过程中短期容量变化模式, 从而增强模型对退化细节的感知. 该模块采用基于 KAN 改进的卷积结构. 与传统卷积仅依赖线性加权不同, KAN 卷积通过引入核插值模块作为非线性权重映射器, 实现对输入特征的自适应变换.

本文选择三阶 B 样条作为基函数, 并将输入区间划分为 10 个网格点, 主要基于拟合能力、平滑性与复杂度之间的科学平衡. 一阶或二阶样条过于简单, 难以刻画局部非线性变化; 而四阶及以上样条虽具有更强的拟合能力, 但易出现过拟合并增加计算负担. 相比之下, 三阶 B 样条能够在保持曲线光滑的同时准确拟合容量衰减曲线的缓变与局部突变特征. 另一方面, 实验表明当网格数大于 10 时拟合误差下降趋于饱和, 综合考虑拟合能力与参数复杂度后, 本研究选取 10 个网格点作为平衡方案. 不同网格数对实验的影响见 4.3 节. 具体的局部特征提取过程如下.




图 5 提出的 KanFormer 框架图

Fig. 5. Framework of the proposed KanFormer.

步骤 1 卷积核以设定步长在输入序列上滑动, 从每个位置提取对应的局部特征片段。

步骤 2 对局部特征片段中的每个元素 x_{conv} , 使用 B 样条, 生成一组固定的基函数 B_j . 其中, j 表示 B 样条基函数索引。

步骤 3 计算每条样条基函数响应 $B_j(x_{\text{conv}})$ 。

步骤 4 加权求和得到一个元素的 B 样条响应 $b_{\text{conv}}(x_{\text{conv}})$:

$$b_{\text{conv}}(x_{\text{conv}}) = \sum_{j=1}^J c_j B_j(x_{\text{conv}}), \quad (4)$$

其中, c_j 是对应的可学习系数, J 是样条基函数个数。

步骤 5 对 $b_{\text{conv}}(x_{\text{conv}})$ 加上基础激活, 得到一个元素的非线性响应输出 $f_{\text{conv}}(x_{\text{conv}})$ 。

$$f_{\text{conv}}(x_{\text{conv}}) = w(b_{\text{conv}}(x_{\text{conv}}) + \phi(x_{\text{conv}})), \quad (5)$$

其中, $\phi(x_{\text{conv}})$ 是基础激活函数, w 是对应的缩放参数。

步骤 6 对一个局部特征片段中每个元素的 $f_{\text{conv}}(x_{\text{conv}})$ 进行相加, 得到局部特征片段卷积 $F_{\text{conv}}(x_{\text{conv}})$ 。

$$F_{\text{conv}}(x_{\text{conv}}) = \sum_{l=1}^L f_{\text{conv},l}(x_{\text{conv},l}), \quad (6)$$

其中, L 表示局部特征片段中的元素数量, l 表示输

入元素索引。

步骤 7 将每个 $F_{\text{conv}}(x_{\text{conv}})$ 依次拼接, 形成完整的卷积输出序列。

为清晰呈现整体流程, 本文将局部特征提取过程整理如表 2 所列。

表 2 局部特征提取过程

Table 2. Local feature extraction process.

输入: 多维时间序列 $x \in \mathbb{R}^{D \times T}$

输出: KAN 卷积输出序列

开始

步骤 1 遍历输入序列, 并根据卷积核大小提取局部特征片段

步骤 2 对于局部特征片段中的每个元素, 生成一组固定的 B 样条基函数 B_j

步骤 3 对局部特征片段中每个元素, 计算其在各个 B 样条基函数上的响应 $B_j(x_{\text{conv}})$

步骤 4 根据对应的学习权重 c_j , 加权求和得到一个元素的 B 样条响应 $b_{\text{conv}}(x_{\text{conv}})$, 见(4)式

步骤 5 加上基础激活函数, 并引入可学习权重项 w , 得到一个元素的非线性响应输出 $f_{\text{conv}}(x_{\text{conv}})$, 见(5)式

步骤 6 对一个局部特征片段中每个元素的 $f_{\text{conv}}(x_{\text{conv}})$ 进行相加, 得到每个局部特征片段的卷积 $F_{\text{conv}}(x_{\text{conv}})$, 见(6)式

步骤 7 将每个 $F_{\text{conv}}(x_{\text{conv}})$ 拼接为最终 KAN 卷积输出序列

结束

3.2 全局特征提取模块

全局特征提取用于捕捉容量衰减过程中的整

体趋势与长程依赖关系,这一部分通过 Transformer 编码器结构实现. 主要由多头注意力层, 前馈神经网络层和残差连接, 层归一化组成. 与 RNN 及 LSTM 类模型天然具备的序列顺序感不同, Transformer 本身并不能直接感知序列顺序, 因此在输入 Transformer 层之前需引入位置编码以显式提供位置信息, 其公式为

$$\begin{cases} E_{p,2i} = \sin\left(\frac{p}{10000^{2i/d}}\right), \\ E_{p,2i+1} = \cos\left(\frac{p}{10000^{2i/d}}\right), \end{cases} \quad (7)$$

其中, p 是循环次数, i 是特征维度, d 是特征总维度. 经位置编码后得到带有位置信息的输入表示 z , 再经过线性映射生成注意力机制的输入 Q, K, V , 相关计算过程如下:

$$z = x_{\text{Atten}} + E, \quad (8)$$

$$Q = zW^Q, K = zW^K, V = zW^V, \quad (9)$$

其中, x_{Atten} 是输入值; E 是位置信息编码; z 是位置编码后的输入表示; Q, K, V 分别为 Query, Key, Value; W^Q, W^K, W^V 分别为 Query, Key, Value 的可训练投影矩阵.

多头注意力可以同时捕捉时间序列中的长期依赖和特征维度之间的交互关系, 是对注意力机制的一种并行拓展结构. 注意力机制的公式为

$$A(Q, K, V) = \sigma\left(\frac{QK^T}{\sqrt{d}}\right)V. \quad (10)$$

其中, $A(\cdot)$ 表示注意力映射, $\sigma(\cdot)$ 表示 softmax 函数.

多头注意力将 Query, Key, Value 分成多个头进行并行计算, 每个头输出不同的表示, 最后合并并经过一个线性层得到最终的注意力结果. 多头注意力通过以下方式定义:

$$M(Q, K, V) = [H_1 \| H_2 \| \cdots \| H_h] W^O, \quad (11)$$

其中, $M(\cdot)$ 表示多头注意力映射, H_i 表示第 i 个注意力头的输出, $[\cdot \| \cdot]$ 表示向量拼接算子. 每个头的计算方式为

$$H_i = A(QW_i^Q, KW_i^K, VW_i^V). \quad (12)$$

前馈神经网络是非线性变换模块, 用于增强模型的表示能. 在多头注意力和前馈神经网络之间都会加入残差连接和层归一化, 残差连接缓解深层网

络的梯度消失问题, 而层归一化保证每一层输出具有稳定分布.

3.3 预测输出模块

预测输出模块用于将高维特征表示转换为目标空间中的健康状态预测结果, 该部分由一个池化层、一个 Dropout 层和两个 KAN 全连接层组成. 池化层用于去除时间维度, 将时序特征压缩为固定长度的全局表示, 而 Dropout 层用于缓解过拟合问题并提升模型的泛化性能. KAN 全连接层作为输出层, 用于将前面提取到的全局特征映射为最终预测值, 其基于 B 样条的非线性表达能力能够更好地刻画电池退化规律. KAN 全连接层操作过程见表 3.

表 3 全连接层操作过程

Table 3. Operation process of the fully connected layer.

输入: 池化层输出的多维特征

输出: KAN 全连接层输出结果

开始

步骤1 对每个输入元素, 构造13个固定的B样条基函数

步骤2 对每个元素所有基函数响应进行加权求和, 计算 B 样条响应 $b_{fc}(x_{fc})$, 见(13)式

步骤3 加上基础激活函数 $\phi(x_{fc})$, 并引入可学习权重项 w , 得到一个元素的非线性响应 $f_{fc}(x_{fc})$, 见(15)式

步骤4 加权组合所有元素的 $f_{fc}(x_{fc})$, 得到最终输出 $F_{fc}(x_{fc})_m$, 见(16)式

结束

首先, 采用三阶 B 样条函数作为基函数, 其在各子区间内以三次多项式形式表示, 兼具光滑性与拟合能力; 将输入区间划分为 10 个网格点, 从而为每个输入元素构造 13 条基函数. 并通过加权求和得到每个输入元素 x_{fc} 的 B 样条响应 $b_{fc}(x_{fc})$:

$$b_{fc}(x_{fc}) = \sum_{j=1}^J c_j B_j(x_{fc}), \quad (13)$$

其中, c_j 为可学习系数, j 为基函数索引, J 为基函数总数, $B_j(x_{fc})$ 为每条基函数响应.

其次, 引入基础激活函数 $\phi(x_{fc})$, 再通过一个可学习的缩放因子 w 调节, 得到一个元素的非线性响应输出 $f_{fc}(x_{fc})$, 其公式如下:

$$\phi(x_{fc}) = \text{SiLU}(x_{fc}) = \frac{x_{fc}}{1 + e^{-x_{fc}}}, \quad (14)$$

$$f_{fc}(x_{fc}) = w(\phi(x_{fc}) + b_{fc}(x_{fc})). \quad (15)$$

最后, 所有输入元素的非线性响应通过权重矩阵 W_{mn} 组合, 得到最终预测结果 $F_{fc}(x_{fc})_m$, 即未

来循环中的最大容量:

$$F_{fc}(x_{fc})_m = \sum_{n=1}^N W_{mn} f_{fc}(x_{fc,n}), \quad m = 1, 2, \dots, M, \quad (16)$$

其中, N 为输入元素数, M 为输出元素数, n 为输入元素索引, m 为输出元素索引.

电池 SOH 预测定义为当前循环的最大容量 $C_{\max}$ 预测值与标称容量 C_{nominal} 的比值:

$$H_{\text{SOH}} = \frac{C_{\max}}{C_{\text{nominal}}}. \quad (17)$$

4 实验设置与结果分析

4.1 实验设置

为评估所提出模型 KanFormer 的性能, 不同电池数据集被划分为训练集和测试集. Michigan Formation 电池数据集中, 每种工况下, 8 个电池作为训练集, 2 个电池作为测试集. HNEI 电池数据集中, 12 个电池作为训练集, 2 个作为测试集. 实验的具体参数如表 4 所. 采用 4 项评价指标^[32]: 均方误差 (MSE)、平均绝对误差 (MAE)、决定系数 (R^2)、电池寿命终止循环预测误差 (EOL error). 这 4 项指标的定义如下:

$$E_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (18)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (19)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (20)$$

$$E_{\text{EOL}} = |\hat{N}_{\text{EOL}} - N_{\text{EOL}}|, \quad (21)$$

其中, $\hat{N}_{\text{EOL}}$ 为预测的终止循环次数, N_{EOL} 为真实的终止循环次数.

本文采用长期预测与逐步滚动更新相结合的策略对 SOH 退化轨迹进行建模. 具体而言, 模型在每轮预测中基于当前历史窗口生成一个固定长度的预测序列, 并将其中第 1 个预测值作为最新观测引入, 更新历史窗口, 从而迭代滚动构造完整的 SOH 退化曲线. 该完整曲线展示了模型长期滚动预测的稳定性和总体趋势拟合能力, 并用于对比实验和消融实验中对模型性能的量化评价.

本文实验均在如下环境下进行: 计算设备为华硕天选 2021, 搭载 Intel Core i9 处理器、16 GB 内存和 NVIDIA GeForce RTX 4060 Laptop GPU. 实验编程语言为 Python 3.10, 深度学习框架为 TensorFlow 2.0, 操作系统为 Windows 11.

4.2 对比实验

将所提出模型与文献^[18–23]中采用基于传统 MLP 的方法进行对比, 每个方法核心参数如表 5 所列.

SOH 预测结果如图 6 所示, 其中概率密度分布展示了不同方法在 SOH 预测中的误差分布情况, 而右侧两个子图进一步可视化了本方法在不同循环周期下的多步预测效果.

表 4 实验参数设置

Table 4. Experimental hyperparameter settings.

模型超参数	取值	模型结构参数	取值
样条网格大小	10	输入层	[64, 100, 8]
B样条阶数	3	卷积层1	[64, 100, 32]
编码器层数	4	卷积层2	[64, 100, 64]
每层注意力头数	4	编码器层	[64, 100, 64]
学习率	0.001	池化层	[64, 64]
Dropout	0.1	全连接层	[64, 512]
优化器	Adam	输出层	[64, 50]
Epoch	100	—	—

表 5 对比实验中各模型的核心参数设定

Table 5. Core parameter settings of each model in the comparative experiments.

方法	核心参数
Li et al. ^[18]	Conv_archs = [(2, 16), (2, 32), (2, 64)]
Zhang et al. ^[19]	Gated_archs = [(1, 64), (1, 128), (1, 256)]
Chen et al. ^[20]	Gated_archs = [(1, 32), (1, 64), (1, 128)]
Lei et al. ^[21]	Conv_archs = [(2, 16), (2, 32), (2, 64)], Gated_archs = [(1, 64), (1, 128)]
Gu et al. ^[22]	Conv_archs = [(2, 16), (2, 32), (2, 64)], Encoder_archs = [(1, 64)]
Li et al. ^[23]	Encoder_archs = [(1, 32)], Gated_archs = [(1, 64), (1, 128)]

注: 结构设定格式如 (L, D) , 表示该模块包含 L 层, 每层输出维度为 D .




图 6 不同电池预测结果对比 (a) BLForm8; (b) BLForm16; (c) MCForm25; (d) MCForm38; (e) 电池 c; (f) 电池 n

Fig. 6. Comparison of prediction results for different batteries: (a) BLForm8; (b) BLForm16; (c) MCForm25; (d) MCForm38; (e) battery c; (f) battery n.

在 Michigan Formation 数据集上, 如图 6(a)—(d) 所示, 所提方法在电池衰退前期始终紧密跟踪真实值. 在电池进入加速衰退阶段后, 由于电池间的异质性及多种复杂老化机制的叠加作用, 健康特征的稳定性下降, 数据间差异显著, 导致所有方法在后期预测误差普遍上升. 尽管如此, 所提方法仍能保持与真实退化趋势的一致, 未出现如对比方法中那样严重偏离真实轨迹的现象. 且概率密度分布结果显示所提方法在误差为 0 附近形成了尖锐且居中的主峰, 表明所提方法显著缓解了其他方法中普遍存在的系统性漂移问题 (预测值整体高于或低于真实值). 这说明所提出的 KAN 方法通过核激活机制实现了更灵活的非线性建模, 并具备局部响应性, 从而能够在不同退化阶段自动调节预测策略.

在 HNEI 数据集中, 如图 6(e)—(f) 所示, 由于原始数据存在明显噪声干扰, 且整体呈非平稳特征, 部分对比模型对输入扰动表现出较高敏感性, 预测结果随数据波动发生剧烈振荡, 甚至出现跳变, 从而难以准确刻画实际的退化过程. 相比之下, 本文所提出的方法具备更强的非线性表达与局部建模能力, 在面对非平稳噪声数据时仍能保持较好的输出平滑性, 且概率密度分布结果表明, 所提方法在误差为 0 附近形成了尖锐且居中的主峰, 不仅有效抑制了预测漂移, 还显著减弱了预测结果的振荡, 从而有效提升了模型的预测稳定性.

传统 MLP 难以捕获长程依赖且训练不稳, Transformer 虽具全局注意力, 却在局部拟合中易出现高频振荡. 其根源在于固定激活函数非线性不

足, 如 ReLU 响应刚性、缺乏平滑过渡, 易致梯度突变与预测波动. KanFormer 通过 B 样条的局部支撑与可训练控制点, 自适应调节非线性映射, 实现输入变化下的平滑响应, 兼顾长程依赖捕获与局部特征建模, 提升了模型的稳定性与预测精度. 为了更清晰地对比各方法的预测表现, 图 7 给出了相应的性能对比结果.

基于图 7, 所提出的 KanFormer 模型在 MSE, MAE 和 R^2 指标上均优于传统 MLP 模型. MSE 与 MAE 的显著降低表明该模型在各退化阶段具有更均衡的误差分布与更平滑的预测输出, 体现出较强的平滑插值能力; 同时, R^2 的提升说明模型能够更准确地刻画容量衰减过程中的非线性演化特征, 有效捕捉缓慢衰减与阶段性突变的动态变化, 展现出优于 MLP 的非线性拟合性能.

表 6 显示了提出模型与对比实验所用模型的复杂度对比. 由表 6 可得, 尽管 KAN 模型的参数量较多, 但其计算复杂度并未线性增长. 这是因为 KAN 的每条连接由一组具有局部支撑性的基函数组成, 在前向传播中仅有少数基函数在输入区间内

被激活, 从而显著减少了乘加运算次数. 与传统 MLP 的稠密矩阵乘法相比, KAN 的计算呈稀疏分布特征, 其参数更多地承担函数形态存储而非计算负担. 因此, KAN 保持较低的实际计算复杂度, 实现高表达性与高计算效率的平衡.

除此之外, 本文在保持网络结构与实验条件一致的前提下, 对比 HIs 数量分别为 4—16 时模型的训练与推理表现. 结果如图 8 所示, 采用 4 个 HIs 时训练速度实现 5.26%—25.38% 的提升, 且 MAE 与 MSE 分别降至 4.10% 与 0.45%, R^2 提升至 0.978. 此时模型能够在保持较低计算复杂度的同时实现最优预测精度. 这是由于适量的健康特征在保留关键信息的同时有效避免了信息冗余和噪声干扰, 这表明选取 4 个健康特征可在效率与性能之间取得最优平衡.

4.3 消融实验

为验证 KanFormer 各组成模块对整体性能的贡献, 本文设计了一系列消融实验: 1) 移除 KAN 卷积模块; 2) 将 KAN 全连接层替换为传统 MLP




图 7 不同电池预测性能对比

Fig. 7. Comparison of prediction performance across different batteries.

表 6 模型复杂度对比

Table 6. Model complexity comparison.

	Li et al. ^[18]	Zhang et al. ^[19]	Chen et al. ^[20]	Lei et al. ^[21]	Gu et al. ^[22]	Li et al. ^[23]	本文方法
Number of parameters	208850	305618	360178	368978	423566	486034	1005930
Computational complexity(MFLOPs)	16.54	18.83	19.92	23.76	34.53	35.37	33.21




图 8 健康指标数量对模型效率与性能的影响

Fig. 8. Impact of health indicator quantity on model efficiency and performance.

全连接层; 3) 仅使用 Transformer; 4) 仅使用 KAN, 以全面对比不同配置在电池容量退化预测中的表现差异.

以 Michigan Formation 电池数据集为例, 图 9 展示了各方法在不同电池上的具体预测情况. 实验表明, 完整模型在所有评价指标和 4 个电池数据上均取得最优性能. 相比之下, 当移除 KAN 卷积模块、采用传统 MLP 全连接层或仅保留单一 KAN 模块时, 模型的整体性能均出现显著下降, 其中仅使用 Transformer 的结构表现最差. 实验结果表明, 传统 MLP 在缺乏非线性自适应能力的情况下, 难以充分捕获容量变化的动态特征; 而仅使用 KAN 模块虽然在局部拟合上具备一定优势, 但由于缺乏全局依赖建模能力, 预测曲线存在较大偏差. 进一步从预测结果曲线观察可以发现, 在缺失 KAN 卷积模块或 KAN 全连接层的情况下, 模型输出表现出更为明显的系统性漂移与趋势振荡: 在退化初期阶段, 预测值持续高于或低于真实容量, 呈现明显的整体偏移; 进入退化后期, 预测结果对输入扰动的敏感性增强, 曲线波动频繁且稳定性显著下降, 反映出模型泛化能力不足. 相较之下, 完整的 KAN-Transformer 结构能够同时兼顾全局趋势捕获与局部平滑拟合, 使预测结果在时间序列上更具连续性与物理一致性. 误差曲线进一步验证了这一点: 所提出方法的误差分布始终保持在零均值附近, 波动

幅度最小, 即核心模块 KAN 卷积与 KAN 全连接层在建模复杂非线性退化过程、提升预测稳定性和泛化能力方面均发挥了关键作用.

为了更清晰地展示实验结果, 不同电池预测性能对比结果如图 10 所示. 不同网格数对预测性能及模型复杂度的影响如表 7 所列. 由表 7 可得, 当网格过少时, 样条分辨率不足, 产生欠拟合, 导致 MAE, MSE 偏高、 R^2 偏低; 而当网格过多时, 局部自由度过强, 易对噪声与短时扰动产生过拟合, MAE 不降反升、 R^2 回落, 整体预测效果并无明显提升, 且计算复杂度上升. 当网格数为 10 时, 既能刻画非线性阶段变化, 又避免过分细分带来的噪声放大, 因此在精度与复杂度之间取得最优平衡.

表 7 不同网格数预测性能和模型复杂度对比

Table 7. Comparison of prediction performance and model complexity under different grid numbers.

网格数	MSE/%	MAE/%	R^2	参数量	计算复杂度 (MFLOPs)
5	0.515	4.652	0.970	949970	31.46
10	0.195	2.690	0.989	1005930	33.21
15	0.185	2.702	0.986	1061890	35.05

4.4 讨论

本研究在 NASA 电池数据集上进行了跨场景验证, 其中, B0006, B0007, B0018 号电池用作训




图9 各方法在不同电池上预测结果 (a) BLForm7; (b) BLForm15; (c) MCForm24; (d) MCForm35

Fig. 9. Prediction results of various methods on different batteries: (a) BLForm7; (b) BLForm15; (c) MCForm24; (d) MCForm35.

练, B0005 号电池用作测试. 为模拟测量扰动, 对数据注入相对幅度约 0.5% 的高斯噪声, 其预测性能如表 8 所列.

基于表 8, 相较无噪声, MSE 上升约 14.29%, MAE 上升约 13.00%, 而 R^2 仅下降 0.003. 这表明噪声主要带来局部绝对误差与平方误差的温和增




图 10 不同电池预测性能对比

Fig. 10. Comparison of prediction performance across different batteries.

表 8 NASA 数据集预测性能

Table 8. Predictive performance on the NASA dataset.

	MSE/%	MAE/%	R^2
无噪声	0.056	1.684	0.984
加噪声	0.064	1.903	0.981

大,但对整体拟合趋势影响极小,模型保持较强的全局解释力与稳定性.结合电池退化的缓慢衰减和阶段性变化特征推断噪声影响主要集中在局部过渡段与测量扰动较敏感的区间;KAN的局部基函数表示与Transformer的时序建模在噪声影响下仍然发挥了平滑与鲁棒作用,使趋势基本不变、性能退化可控.

本研究基于Michigan Formation与HNEI两个公开数据集开展了模型验证,实验条件主要涵盖恒温环境和固定倍率的标准循环工况.在此范围内,模型能够稳定地识别关键健康特征,并在不同老化模式下保持较高预测精度,体现了良好的稳定性.不过,当前实验工况相对理想,尚未涉及更加复杂的实际应用场景,如环境温度的动态波动、随机充放电中断、电芯间一致性差异等.这些非理想因素可能导致电化学反应过程的短时扰动,从而影响健康特征的响应稳定性与模型的泛化表现.

因此,后续工作将面向多温度、多倍率及随机扰动等更复杂工况开展扩展实验,以系统验证模型在真实运行环境下的鲁棒性与适应性;同时引入跨批次与跨平台的多源数据,评估模型的跨域泛化能

力,并据此完善其工程化可用性.

5 结 论

本文提出了一种新型电池SOH预测模型KanFormer,利用KAN卷积提取复杂时序特征,并以KAN全连接层模块替代传统全连接层以增强非线性拟合能力.在不同电池数据集下开展的实验结果表明,所提出方法在容量预测精度和拟合方面均优于现有主流模型.消融实验进一步揭示了KAN卷积与KAN全连接层的协同作用,缺失任一模块均会导致预测性能下降.此外,本文还对比了不同数量健康特征对模型效率与性能的影响,当使用少量健康特征时,在训练速度和性能上同时达到最优.同时,误差结果进一步表明,所提出方法能够显著缓解预测漂移与振荡,提升模型在长期预测过程中的稳定性.综上,该模型在面向不同工况的退化预测中具有良好的泛化性能和工程应用潜力.未来工作可进一步拓展更复杂真实场景下的预测任务.

参考文献

- [1] Gao M Y, Cai L H, Sun C C 2022 *J. Electron. Inf. Technol.* **44** 3734 (in Chinese) [高明裕, 蔡林辉, 孙长城 2022 *电子与信息学报* **44** 3734]
- [2] Dong Z K, Ji X Y, Wang J Y, Gu Y T, Wang J F, Qi D L 2024 *IEEE Trans. Consum. Electron.* **70** 4311
- [3] Lucaferri V, Quercio M, Laudani A, Riganti Fulginei F 2023

- Energies* **16** 7807
- [4] Zhang Y L, Dong Z Q, Zheng L F, Wang K, Liang J F 2025 *Acta Phys. Sin.* **74** 148803 (in Chinese) [张艳岚, 董泽庆, 郑利锋, 王凯, 梁君飞 2025 物理学报 **74** 148803]
- [5] Li X J, Yu Y T, Zhang Z W, Dong X R 2021 *Acta Phys. Sin.* **71** 038803 (in Chinese) [李晓杰, 喻云泰, 张志文, 董小瑞 2021 物理学报 **71** 038803]
- [6] Fahmy H M, Hasanien H M, Alharbi M, Ji H 2025 *Sci. Rep.* **15** 14592
- [7] Lai X, Yi W, Cui Y F, et al. 2021 *Energy* **216** 119233
- [8] Xiong R, Li L L, Li Z R, et al. 2018 *Appl. Energy* **219** 264
- [9] Amir S, Gulzar M, Tarar M O, Naqvi I H, Zaffar N A, Pecht M G 2022 *IEEE Access* **10** 18279
- [10] Dong Z K, Gu S Y, Zhou S Q, Yang M J, Lai C S, Gao M Y 2025 *IEEE Trans. Transp. Electr.* **11** 3655
- [11] Dong Z K, Yang M J, Wang J F, Wang H, Lai C S, Ji X Y 2025 *IEEE Trans. Transp. Electr.* **11** 2696
- [12] Zhang M, Yang D F, Du J X, Sun H L, Li L W, Wang L C, Wang K 2023 *Energies* **16** 3167
- [13] Zhou D, Liang J L, Li F X, Cui Y X, Shan Y X, Zhang Y H, Chen M H, Li S 2024 *J. Energy Storage* **104** 114579
- [14] Huang J, He T, Zhu W L, Liao Y X, Zeng J H, Xu Q, Niu Y C 2025 *Comput. Electr. Eng.* **122** 109930
- [15] Zhang Y H, Li Z Y, Kong L Y, Xu H, Shen H W, Chen M 2025 *J. Energy Storage* **105** 114538
- [16] Qian C, Xu B H, Xia Q, Ren Y, Sun B, Wang Z L 2023 *Appl. Energy* **336** 120793
- [17] Zheng K, Meng J H, Yang Z P, Zhou F F, Yang K, Song Z X 2024 *Appl. Energy* **375** 124077
- [18] Li Y, Tao J 2020 *Proceedings of the Chinese Control and Decision Conference (CCDC)* Hefei, China, August 22–24, 2020 p5489
- [19] Zhang C L, Luo L J, Yang Z, Zhao S S, He Y G, Wang X, Wang H X 2023 *Green Energy Intell. Transp.* **2** 100108
- [20] Chen K Q, Pang H, Lin G Y, Wang F B, Nan W Z, Du J R 2024 *Proceedings of the IEEE Transportation Electrification Conference and Expo, Asia-Pacific (ITEC Asia-Pacific)* Chengdu, China, August 28–31, 2024 p423
- [21] Ren L, Dong J B, Wang X K, Meng Z H, Zhao L, Deen M J 2021 *IEEE Trans. Ind. Inf.* **17** 3478
- [22] Gu X Y, See K W, Li P H, et al. 2023 *Energy* **262** 125501
- [23] Li Z Y, Zhang X W, Gao W 2024 *Energy* **311** 133418
- [24] Liu W, Xu Y 2019 *Proceedings of the IEEE Conference on Energy Internet and Energy System Integration (EI2)* Beijing, China, November 8–10, 2019 p1203
- [25] Braco E, San Martin I, Sanchis P, Ursua A, Stroe D I 2022 *J. Energy Storage* **55** 105366
- [26] Ji X Y, Chen Y, Wang J F, Zhou G D, Lai C S, Dong Z K 2024 *IEEE Internet Things J.* **11** 41941
- [27] Chen X, Qin Y W, Zhao W D, Yang Q M, Cai N B, Wu K 2024 *J. Energy Storage* **86** 111197
- [28] Zhou W L, Lu Q, Zheng Y P 2022 *Machines* **10** 512
- [29] Krupp A, Ferg E, Schuldt F, et al. 2021 *Batteries* **7** 2
- [30] Weng A, Mohtat P, Attia P, Less G, Lee S, Stefanopoulou A 2021 *Battery Test Data–Fast Formation Study* University of Michigan–Deep Blue Data <https://doi.org/10.7302/pa3f-4w30>
- [31] Dubarry M, Beck D 2021 *HNEI Long-Term Degradation Dataset* Battery Archive <https://batteryarchive.org>
- [32] Tang Y M, Zhong S F, Wang P, Zhang Y, Wang Y 2024 *Sci. Rep.* **14** 23524

A lithium-ion battery state-of-health prediction network integrating Kolmogorov-Arnold representation theory*

ZHAO Xuotong¹⁾²⁾³⁾ DONG Zhekang¹⁾²⁾⁴⁾ ZHOU Haojie¹⁾²⁾³⁾

LIN Huipin¹⁾²⁾⁴⁾ JI Xiaoyue^{5)†}

1) (School of Electronics and Information, Hangzhou Dianzi University, Hangzhou 310018, China)

2) (Key Laboratory of Automotive Electronics Research of Zhejiang Province, Hangzhou 310018, China)

3) (Department of Electronic Engineering, Computer Engineering and Informatics, Cyprus University of Technology, Limassol 3036, Cyprus)

4) (College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China)

5) (Department of Precision Instrument, Tsinghua University, Beijing 100084, China)

(Received 6 October 2025; revised manuscript received 31 October 2025)

Abstract

Accurate prediction of the state of health (SOH) of lithium-ion batteries in electric vehicles is crucial for ensuring the safety of drivers and passengers, optimizing battery management systems (BMS), and extending battery life. Reliable SOH prediction is the foundation of BMS basic functions, including charge and discharge control, remaining useful life (RUL) prediction, and fault diagnosis. However, existing data-driven methods still

* Project supported by the National Key Research and Development Program of China (Grant No. 2023YFB2504100) and the Outstanding Youth Fund Project of Zhejiang Province, China (Grant No. LZYQ25F020005).

† Corresponding author. E-mail: jixiaoyue@mail.tsinghua.edu.cn

face two long-standing challenges. First, most models rely excessively on a large number of handcrafted health features derived from voltage, current, and capacity data, resulting in feature redundancy and low computational efficiency. Second, SOH-related time series exhibits strong nonlinearity and non-stationarity, leading traditional neural networks to experience prediction drift, instability, and performance degradation under varying conditions. To address the first challenge, we propose a lightweight health feature selection mechanism that combines incremental capacity analysis (ICA) with correlation analysis to automatically identify compact and physically meaningful degradation features. Only four key health features that are highly correlated with capacity fading are selected, which effectively reduces model complexity and computational cost while maintaining high SOH prediction accuracy. To tackle the second challenge, we develop a hybrid neural network model called KanFormer, which integrates the Kolmogorov-Arnold (KAN) representation theory with a Transformer-based temporal modeling framework to enable accurate and robust SOH prediction. Specifically, the proposed KanFormer framework consists of three hierarchical modules: 1) the local feature extraction module, which leverages the smooth interpolation capability of KAN to capture fine-grained degradation characteristics from voltage-capacity and incremental capacity (IC) curves, modeling local nonlinear behaviors in the degradation process; 2) the global feature extraction module, which employs a multi-head Transformer encoder to learn long-range dependencies and cross-scale temporal relationships, enabling the joint modeling of short-term dynamics and long-term aging evolution; 3) the prediction output module, which uses nonlinear KAN layers to adaptively fuse local and global representations, producing numerically stable and highly accurate SOH prediction results. By combining the mathematical expressiveness of KAN with the temporal reasoning capability of the Transformer, KanFormer effectively mitigates prediction drift and oscillations induced by data nonlinearity and non-stationarity. Compared with traditional deep-learning models, the proposed method improves training efficiency by 15.32%. Experimental validation on three publicly available battery-aging datasets (Michigan Formation, HNEI, and NASA) demonstrates its superior performance, achieving $\text{MSE} = 0.0045$, $\text{MAE} = 0.041$, and $R^2 = 0.978$ on the Michigan dataset, $\text{MSE} = 0.00055$, $\text{MAE} = 0.0175$, $R^2 = 0.996$ on the HNEI dataset, and $\text{MSE} = 0.0056$, $\text{MAE} = 0.017$, $R^2 = 0.984$ on the NASA dataset. These results substantially outperform mainstream baselines, confirming the high accuracy and robustness of KanFormer. In summary, KanFormer combines lightweight feature selection, nonlinear functional representation, and cross-scale temporal modeling, providing a scalable and interpretable solution for predicting high-accuracy and high-efficiency SOH.

Keywords: lithium-ion battery, state of health, time series prediction, Kolmogorov-Arnold representation theory

DOI: [10.7498/aps.75.20251359](https://doi.org/10.7498/aps.75.20251359)

CSTR: [32037.14.aps.75.20251359](https://cstr.net.cn/resultDetail.do?id=cstr&val=32037.14.aps.75.20251359)

融合Kolmogorov–Arnold表示理论的锂离子电池健康状态预测网络

赵雪彤 董哲康 周豪杰 林辉品 纪晓悦

A lithium-ion battery state-of-health prediction network integrating Kolmogorov–Arnold representation theory

ZHAO Xuetong DONG Zhekang ZHOU Haojie LIN Huipin JI Xiaoyue

引用信息 Citation: *Acta Physica Sinica*, 75, 030809 (2026) DOI: 10.7498/aps.75.20251359

CSTR: 32037.14.aps.75.20251359

在线阅读 View online: <https://doi.org/10.7498/aps.75.20251359>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn>

您可能感兴趣的其他文章

Articles you may be interested in

锂离子电池电化学降阶模型性能对比

Comparative study of reduced-order electrochemical models of the lithium-ion battery

物理学报. 2021, 70(13): 138801 <https://doi.org/10.7498/aps.70.20201894>

VS₂作为锂离子电池负极材料的第一性原理研究

First-principles study of VS₂ as anode material for Li-ion batteries

物理学报. 2024, 73(11): 113101 <https://doi.org/10.7498/aps.73.20231681>

力学约束对锂离子电池双层电极中锂扩散和应力的影响

Influence of mechanical constraints on Li diffusion and stress in bilayer electrode of lithium-ion batteries

物理学报. 2025, 74(2): 020201 <https://doi.org/10.7498/aps.74.20241275>

一种求解锂离子电池单粒子模型液相扩散方程的新方法

A new method to solve electrolyte diffusion equations for single particle model of lithium-ion batteries

物理学报. 2022, 71(4): 048201 <https://doi.org/10.7498/aps.71.20211619>

基于电化学–应力耦合模型的锂离子电池硅/碳核壳结构的模拟与优化

Simulation and optimization of silicon/carbon core-shell structures in lithium-ion batteries based on electrochemical-mechanical coupling model

物理学报. 2021, 70(17): 178201 <https://doi.org/10.7498/aps.70.20210455>

基于电化学老化衰退模型的锂离子电池动力电池外特性

External characteristics of lithium-ion power battery based on electrochemical aging decay model

物理学报. 2022, 71(3): 038803 <https://doi.org/10.7498/aps.71.20211401>