



基于自适应变分模态分解与重构的全钒液流电池健康状态预测

毛恒山¹, 刘浩骥¹, 刘晓杰¹, 王杰¹, 李伟¹, 胡炜昊¹, 韩文杰¹, 邱杰², 王泉²,
熊斌宇²

(¹中电建新能源集团股份有限公司, 北京 100101; ²武汉理工大学自动化学院, 湖北 武汉 430000)

摘要: 全钒液流电池(vanadium flow batteries, VFBs)在长期运行过程中, 常因电解液体积失衡而引起异常容量衰减。因此对其健康状态(state of health, SOH)进行准确预测, 对维持系统稳定运行至关重要。本研究基于电池循环老化数据, 提出采用自适应变分模态分解与重构(adaptive variational mode decomposition and reconstruction, AVMDR)方法, 以处理电池老化过程中的容量再生现象, 并将其应用于SOH时间序列分析。基于相关性分析, 重构了表征容量再生特征的波动函数 $F(t)$ 与表征主体容量衰减趋势的主趋势函数 $M(t)$ 。进而结合两者特性, 分别采用长短期记忆网络(long short-term memory, LSTM)和Transformer模型, 构建融合神经网络(integrated neural network, INN)模型。此外, 通过概率分布计算以处理预测结果的不确定性问题。通过实验所得老化数据验证了所提融合模型的可行性与有效性。结果表明: 该模型在多时间尺度下的预测均方根误差(RMSE)可保持在0.45%以内, 在精度与稳定性方面均优于其他模型。

关键词: 全钒液流电池; 健康状态; 自适应变分模态分解与重构; 长短期记忆网络; Transformer模型

doi: 10.19799/j.cnki.2095-4239.2025.0962

中图分类号: TM 911

文献标志码: A

文章编号: 2095-4239 (2026) 04-1412-13

State of health prediction for vanadium flow batteries using adaptive variational mode decomposition and reconstruction

MAO Hengshan¹, LIU Haoji¹, LIU Xiaojie¹, WANG Jie¹, LI Wei¹, HU Weihao¹, HAN Wenjie¹,
QIU Jie², WANG Xiao², XIONG Binyu²

(¹Power China Renewable Energy Co.,Ltd, Beijing 100101, China; ²School of Automation, Wuhan University of Technology, Wuhan 430000, Hubei, China)

Abstract: Vanadium flow batteries (VFBs) are susceptible to abnormal capacity decay due to electrolyte volume imbalance during long-term operation. Therefore, accurate state of health (SOH) prediction is essential for maintaining system stability. In this study, a battery cycle aging data-based method based on adaptive variational mode decomposition and reconstruction (AVMDR) is proposed to address the capacity regeneration phenomenon observed during battery aging. The proposed method is applied to state-of-health time-series analysis. Correlation analysis is employed to reconstruct a fluctuation function $F(t)$ characterizing the capacity regeneration features and a main trend function $M(t)$ representing the dominant capacity decay trend. An integrated neural network (INN) model is then

收稿日期: 2025-10-27; 修改稿日期: 2025-11-22。

基金项目: 2024年度中国电建新型储能研究中心定向委托计划(DJ-PTZX-2024-01), 国家自然科学基金(52177221)。

第一作者: 毛恒山(1974—), 男, 硕士, 工程师, 研究方向为新型储能, E-mail: maohengshan@powerchina.cn; 通信作者: 熊斌宇, 教授, 研究方向为VFB系统建模, E-mail: bxiong2@whut.edu.cn。

引用本文: 毛恒山, 刘浩骥, 刘晓杰, 等. 基于自适应变分模态分解与重构的全钒液流电池健康状态预测[J]. 储能科学与技术, 2026, 15(4): 1412-1424.

Citation: MAO Hengshan, LIU Haoji, LIU Xiaojie, et al. State of health prediction for vanadium flow batteries using adaptive variational mode decomposition and reconstruction[J]. Energy Storage Science and Technology, 2026, 15(4): 1412-1424.

constructed by employing a long short-term memory (LSTM) network and a Transformer model to handle the distinct characteristics of functions $F(t)$ and $M(t)$, respectively. Furthermore, probability distribution calculations are performed to address the uncertainties in the prediction outcomes. The feasibility and effectiveness of the proposed hybrid model are validated using experimental aging data. Results demonstrate that the model maintains a root mean square error below 0.45% across multiple time scales, outperforming conventional models in both accuracy and stability.

Keywords: vanadium flow batteries; state of health; adaptive variational mode decomposition and reconstruction; long short-term memory; Transformer model

随着经济发展与工业化进程的不断加速, 能源需求持续增长。为减少化石能源开发利用所引发的一系列环境问题, 并保障经济可持续发展, 能源结构转型与可再生能源开发已受到广泛推动。全钒液流电池(vanadium flow batteries, VFBs)是目前大规模储能系统中最具应用前景的技术之一^[1]。近年来, VFB因其污染低、安全性高、循环寿命长、功率与容量解耦等显著优势而备受关注^[2]。

全钒液流电池的运行模式是 V^{2+}/V^{3+} 与 VO^{2+}/VO_2^+ 分别作为阳极电解液和阴极电解液溶解于硫酸溶液^[3]。与其他电池技术不同, 该电解液中的氧化还原反应无污染性(不含重金属), 避免了有害副产物的生成, 且系统可实现环境友好型管控^[4]。电解液与电堆相互隔离并分置于独立储罐, 从而确保其功率与容量特性不互耦^[5]。尽管具有上述优势, 目前仍存在若干问题制约着该行业的深度发展。

探究电解液迁移机制对于构建精确的健康状态(state of health, SOH)预测模型至关重要^[6]。质子交换膜虽可阻隔钒离子迁移, 但目前尚无能实现100%阻隔效果的隔膜。因此随着时间推移, 钒离子在正负极间持续进行跨膜传输, 不同价态钒离子在正负电解液中的自放电反应会导致容量衰减^[7]。Sun 等人^[8]通过渗流实验, 借助动态装置, 系统阐释了自放电反应过程中各价态钒离子穿越 Nafion 膜的迁移顺序, 证实浓度差是影响钒离子跨膜传输的主要因素。由于钒离子结合水分子数存在差异^[9], 长期运行过程中离子与水的交叉累积会逐渐形成浓度差。Song 等人^[10]指出电解液黏度是导致电解液失衡的主要原因, 并发现较高电解液流速会引发并加速电解液体积失衡。上述研究大多基于能量、动量、质量与电荷守恒定律构建的偏微分方程组, 从离子扩散/迁移、水分子迁移及电解液失衡等微观

角度探讨了容量失衡与衰减的机理, 形成了全面深入的研究体系, 这类模型因此被归类为微观机理模型^[11-12]。然而, 建模过程的复杂性、难度及成本使其难以实现大规模应用。

随着大数据与人工智能技术的广泛普及, 宏观机理模型应运而生。该类模型将整个电堆或储液罐视为单一质点, 通过建立电池参数与容量衰减的关联, 显著降低了计算复杂度。本团队 Xiong 等人^[13]开发了基于钒离子互串的容量衰减模型, 该模型在监测容量失衡状态方面被证明具有高度有效性。此外, 本团队^[14]还提出了一种数据驱动方法, 将流速变量集成至全钒液流电池建模中, 通过采用不同电流与流速的循环实验设计, 验证了模型的可行性、有效性与鲁棒性。结果表明: 该模型在宽泛运行区间内均表现良好, 电压预测误差始终保持在0.023 V 以下。

随时间推移, 正负电解液体积会因多重反应的叠加效应而出现失衡。若该失衡问题未获解决, 可能导致容量衰减甚至彻底耗尽^[15]。因此, 绝大多数全钒液流电池系统需进行定期维护, 主要通过电解液混合或再平衡手段恢复可用容量^[16]。由此可见, 全钒液流电池健康状态监测不仅对系统长期稳定运行至关重要, 更是保障储能系统稳定性与可靠性的关键所在。

本研究基于宏观机理, 提出了一种融合自适应变分模态分解与重构(adaptive variational mode decomposition and reconstruction, AVMDR)与集成神经网络的健康状态估计模型, 用于表征容量再生现象。通过 AVMDR 对 SOH 时间序列进行分解, 并依据相关性重构得到表征容量再生的波动函数 $F(t)$ 与表征容量衰减的主趋势函数 $M(t)$, 通过实验获取了多个循环老化数据。结果表明, 本集成模型在

多个时间尺度上均展现出卓越性能,表明本研究方法具有强稳定性,有效提升了模型的精度与鲁棒性。相较于其他方法,本模型始终保持最佳性能表现,能够有效应对长期运行中复杂多变的工作状况,有望为推动全钒液流电池储能领域的发展提供技术支持。

1 实验数据

1.1 实验数据简述

VFB的运行基于泵送系统驱动正负电解液通过管道传输至电堆,并在电堆内发生电化学反应,实现了电池的充放电功能。正极电解液主要包含四价与五价钒离子,负极电解液则由二价与三价钒离子构成。由于质子交换膜无法实现电解液的完全隔离,正负钒离子会相互穿透迁移,该现象称为自放电反应^[17-19]。通过实验获取的数据可精确表征电池自放电反应的外部行为特征。

本工作搭建了如图1所示的全钒液流电池实验平台,并设计开展了电池老化实验。该平台由电池测试系统、上位机及单电池系统构成。其中单电池系统包含单体电池、导流管路、蠕动泵和储液罐。电堆内部的端板、集流体、双极板与边框等组件均由湖北华夏智晟新能源科技有限公司提供。电解液初始容量为30 mL,蠕动泵流速设定为50 mL/min。容量衰减实验采用恒流恒压(CCCV)充电方式启动:先以1.8 A恒定电流充电至电压达1.7 V,随后维持该电压直至电流降至0.2 A;之后电池静置1 min。接着进行恒流恒压放电:以1.8 A恒定电流放电至电压降至0.5 V,随后转入恒压放电直至电流降至0.2 A;最后电池再次静置1 min。以上全部步骤构成一个完整循环,实验共计92次循环。

电池容量在每次充/放电结束时采用安时积分法(即库仑计数法)进行计算,如式(1)。

$$\text{SOH} = \frac{C_i}{C_0} = \frac{\int I_{\text{discharge}} dt_i}{\int I_{\text{discharge}} dt_0} \quad (1)$$

式中, C_i 和 C_0 分别为当前循环的实际容量和初始额定容量; t_i 和 t_0 分别为当前循环和初始循环在相同倍率下从满电状态放电至截止电压的放电时长。

如图2所示,随着循环次数的增加,SOH逐渐下降。这主要是由于不同价态钒离子在质子交换膜中的扩散系数存在差异,扩散系数越大代表离子迁移速率越高。按扩散系数从大到小排序,依次为:

V^{2+} 、 VO^{2+} 、 VO_2^+ 和 V^{3+} ^[8]。随着电池循环老化,正极电解液浓度逐渐升高,而负极电解液浓度逐渐降低。水分从含水量较高、溶质含量较低的负极向含水量较低、溶质含量较高的正极迁移,从而引发容量失衡现象,最终导致电池容量衰减和系统性能下降。为准确掌握正负极电解液的混合时间,需提前采取有效措施保障全钒液流电池系统的稳定性和可靠性。在此基础上,精准预测多时间尺度下的SOH变化趋势具有重要意义。

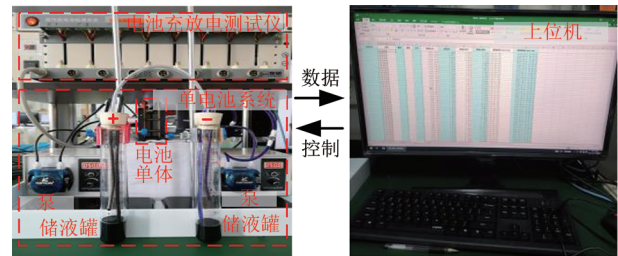


图1 VFB实验平台

Fig. 1 VFB experiment platform




图2 全钒液流电池SOH衰退曲线

Fig. 2 VFB SOH decay

1.2 容量再生机理及其信号表征

全钒液流电池在循环过程中出现的“容量再生”现象,通常表现为SOH在总体衰减趋势上的局部短暂回升,其物理成因主要来自以下几方面。

- ①电解液局部再平衡:泵送、流动不均匀或温度梯度导致的电解液局部混合,短时间内改善离子分布,引起容量暂时恢复。
- ②离子重分布与浓度弛豫:充放电后离子在膜/电极界面的非均匀分布会随静置或低电流运行逐渐弛豫,导致可用容量短暂提升。
- ③温度波动的影响:温度变化影响离子迁移速率与反应动力学,从而引起容量表现的短期波动。
- ④膜状态暂时恢复:某些运行条件下(如流速

调整、压力变化),膜内水合状态或离子通道可能发生可逆性改变,影响容量输出。

这些过程具有时间短、可逆(或准可逆)、与运行条件相关性强的特点,因此在SOH序列中表现为围绕长期衰减趋势的波动。模态分解后,这些短期波动被提取为高频或中频分量。而低频分量则对应由电解液整体体积失衡、钒离子跨膜净迁移、膜结构不可逆老化等长期机制主导的容量衰减趋势。

2 方法

2.1 VMD的原理

变分模态分解(variational mode decomposition, VMD)在模态混叠现象方面具有优异的应对能力,常被应用在不同领域。作为一种自适应信号处理方法,本部分选用VMD来应对电池容量衰减问题,通过式(2)对SOH衰减曲线进行分解。

$$\text{SOH}(t) = \{\text{IMF}_1(t) \cdots \text{IMF}_K(t), \text{RES}(t)\} \quad (2)$$

式中, $\text{IMF}_i(t)$ ($i = 1, 2 \cdots K$) 为分解后的 K 个具有适当带宽的本征模态函数分量。 $\text{RES}(t)$ 为残余分量。

VMD的工作原理是先建立变分约束模型,再通过希尔伯特变换将优化后的模型转化为SOH时间序列,如式(3)所示^[20]。

$$\min \left\{ \sum_{k=1}^K \left\| \partial(t) \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] * e^{-j\omega_k t} \right\|_2^2 \right\} \quad (3)$$

$$\text{s.t.} \sum_{k=1}^K u_k(t) = f(t)$$

式中, K 是模态分解的次数, $\alpha_k(t)$ 为分解后的本征模态函数, ω_k 是 IMF_i 的频率, j 为虚数单位, $*$ 为卷积函数, $\partial(t)$ 为一阶时间倒数, $\delta(t)$ 为狄拉克函数。

然后再引入拉格朗日算子 λ 和二次罚项 γ 求解变分约束模型,如式(4)所示。

$$L\{u_k, \omega_k, \lambda\} = \left\langle \lambda(t), x(t) - \sum_{k=1}^K u_k(t) \right\rangle + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2$$

$$+ \gamma \left\{ \sum_{k=1}^K \left\| \partial(t) \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] * e^{-j\omega_k t} \right\|_2^2 \right\} \quad (4)$$

式中, $\langle \rangle$ 为内积算法, u_k , ω_k , λ 的参数由拉格朗日函数更新。根据Parseval定理,通过更新初始化参数 $u_k^1(\omega)$, $\omega_k^1(\omega)$, $\lambda_k^1(\omega)$, 得到迭代参数如式(5)~(7)所示。

$$u_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i < k} \hat{a}_i^{n+1}(\omega) - \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\lambda(\omega - \omega_k^n)^2} \quad (5)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |u_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |u_k^{n+1}(\omega)|^2 d\omega} \quad (6)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \lambda \left[f(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right] \quad (7)$$

重复上述过程,直到满足迭代停止条件[式(8)]。

$$\sum_{k=1}^K \frac{\|\hat{u}_k^{n+1}(\omega) - \hat{u}_k^n(\omega)\|_2^2}{\|\hat{u}_k^{n+1}(\omega)\|_2^2} < \varepsilon \quad (8)$$

式中, ε 为结束迭代时确定的精度。

2.2 基于PSO的自适应VMD与重构

VMD的性能同时受到 K 和 α 的影响。 K 值不同,模态分解性能也有所差异:若 K 过小,则单个模态分量中包含多个信号分量;若 K 值过大,则会导致单个信号分量分布在多个模态分量中。过大的 α 严重限制带宽,这可能会消除有价值的频率信息;过小的 α 则会保留一些无用的频率分量。因此,选择合适的 K 和 α 值对模态分解的有效性至关重要。

在本工作中,采用粒子群优化算法(particle swarm optimization, PSO)作为优化参数的寻优框架。该算法简单易行,能够在不过多增加模型负荷和训练时间的前提下快速收敛并获得全局最优解。初始阶段随机分配 K 和 α 的所有粒子后,再对每个粒子进行PSO迭代,直到收敛。PSO算法以30个粒子为群大小,在可管理的计算成本下保证了充足的搜索多样性。在第 k 次迭代中的第 b 个粒子更新为

$$v_b^k = \omega v_b^{k-1} + c_1 r_1 (\alpha_g^{k-1} - \alpha_b^{k-1}) + c_2 r_2 (\alpha_l^{k-1} - \alpha_b^{k-1}) \quad (9)$$

$$\alpha_b^k = \alpha_b^{k-1} + v_b^k \quad (10)$$

式中, v 是迭代系数, ω 是惯性权重, c_1 和 c_2 分别代表粒子局部和全局最优位置的步长, r_1 和 r_2 是分别从区间 $[0, 1]$ 的均匀分布中采样得到的随机数,下标 g 和 l 分别表示“全局”和“局部”。惯性权重初始设为0.9,并随着迭代次数线性减少至0.4,以在探索与开发/利用之间取得平衡。随着迭代次数 k 的增加,损失函数逐步降低。如果迭代过程满足如式(11)的终止条件,则得到最优 K 和 α 。

$$\|\alpha_b^k - \alpha_b^{k-1}\| < \varepsilon' \quad (11)$$

式中,增量 ε' 是一个远小于1的正数。

本研究选择冲击复杂度指标(shock complexity index, SCI)作为PSO的适应度函数,该指数是峰度(kurtosis, KT)与能量谱熵(energy spectral entropy, ESE)融合构建的。峰度是一个量纲为1的指标,对信号中突发性或尖峰成分极为敏感,有助于检测电池信号中异常的尖刺;而能量谱熵反映信号能量在频谱内的分布情况,有助于识别曲线波动模式的改变,其定义如下。

$$SCI = KT \times ESE \quad (12)$$

$$KT = \frac{1}{N} \sum_{i=1}^N \left(\frac{X_i - \bar{X}}{s} \right)^4 \quad (13)$$

$$ESE = - \sum_{i=1}^M p_i \log_2 p_i \quad (14)$$

式中, X_i 表示第*i*个样本, \bar{X} 是样本均值, s 是样本标准差, N 是信号长度, p_i 是第*i*个频率分量的能量比。

通过采用PSO来确定VMD的最优参数,其目标函数如式(15)所示。优化空间中每一个粒子的位置都代表一个潜在解,即一组VMD参数(K, α)。为了使分解合理可靠,设定 K 和 α 的取值范围分别限定在[2,20]和[100,10000]。

$$\arg \min_{(K, \alpha)} \left\{ 1 / \left(\sum_{n=1}^N |C|_n / N \right) \right\} \quad (15)$$

自适应VMD的操作步骤如下。①初始化PSO的参数和VMD的参数组合(K, α)。②对信号进行VMD分解。③评估每个粒子的适应度。④更新每个粒子的位置。⑤验证迭代过程是否满足终止条件,若满足则保存最优参数并输出;若不满足,则返回第二步进一步迭代。

结果表明, VMD的3组参数被输出,分别为(2,2000)、(3,1000)和(4,500)。图3(a)、(c)和(e)分别给出了在这3组参数对应下的VMD分解后的分量,同时为了筛选出最优组合,还展示了各自的频谱图来展示不同频率下含有信息的成分,如图3(b)、(d)和(f)所示。从图3(a)~(b)可知,参数组合为(2,2000)时IMF₁和IMF₂都是一条较为平滑的曲线被认为是静态分量。由频谱图分析,只有低频分量缺少了部分特征。图3(e)~(f)展示了参数组合为(4,500)时的分解结果,尽管同时存在低频和中频动态分量。但是中频信号同时存在于多个模式分量中,同时过小的 α 导致了一些信息含量不高且重复的频率分量,这无疑会增加后续的工作负荷。因此, VMD参数组合被确定为(3,1000), ε 设置为

10^{-7} 。此类情况不仅有最低数量的代表容量再生现象的中低频动态(波动)分量(IMF₁),还有与SOH变化趋势高度相似的静态分量(IMF₂和IMF₃)。

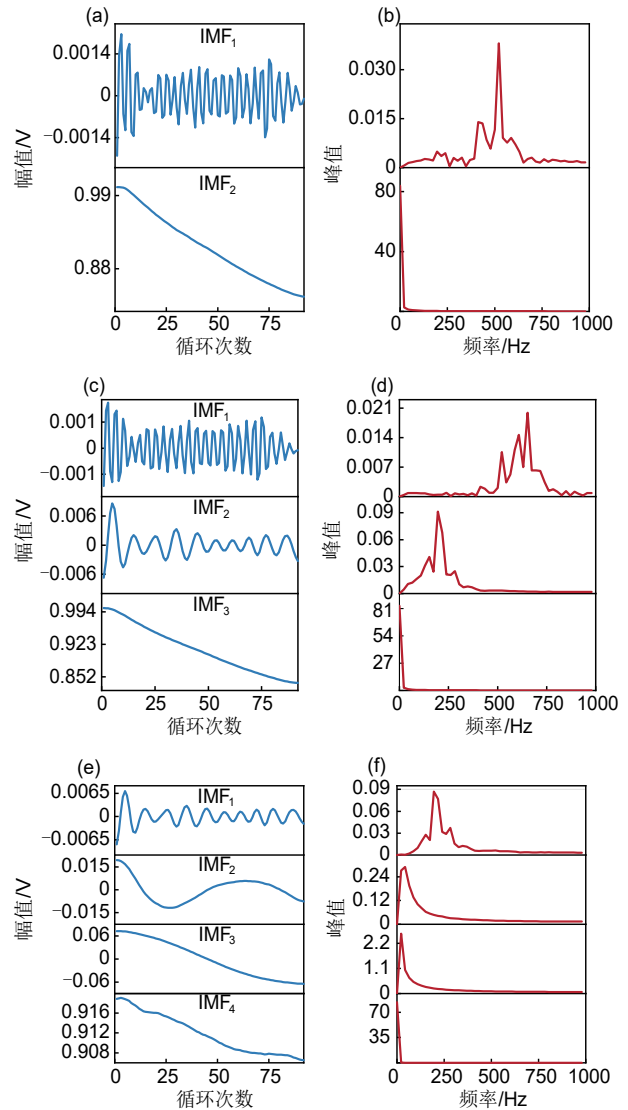


图3 曲线不同(K, α)参数组合下的模式分量及频谱图:
(a)~(b): (2,2000); (c)~(d): (3,1000); (e)~(f): (4,500)
Fig. 3 Component and spectrograms of VMD decomposition of battery at different parameter combinations (K, α): (a)~(b): (2,2000); (c)~(d): (3,1000); (e)~(f): (4,500)

为减少模型计算量,并减少预测次数过多带来的累积误差。通过相关性分析,3个IMF分量和余量RES被重构为主趋势函数 $M(t)$ 和波动函数 $F(t)$ 。与SOH相关性差的,即某个分量的相关性系数小于3个分量平均水平的被记为 $F(t)$ 。反之,将所有大于平均系数的IMF_i与RES累加,被记为 $M(t)$ 。

这样能够有效地将SOH时间序列中的主变化趋势和局部再生导致的波动信号分离开来，显著提高SOH预测模型的预测性能。

全钒液流电池在长期循环中，SOH序列呈现两种典型模式：一是由电解液离子迁移、水分输运、膜老化等不可逆过程引起的长期衰减趋势；二是由电解液局部再平衡、离子重分布、温度波动等可逆或准可逆过程引起的短期容量波动(即容量再生)。AVMDR本质上是一种自适应时频分解方法，其物理意义在于：通过优化变分模态分解的参数 (K, α) ，将SOH序列中不同时间尺度的物理过程分离为不同频带的模态分量(IMFs)。其中，高频或中频IMF通常对应快速波动的容量再生信号，而低频IMF及残余分量则对应缓慢演化的长期衰减趋势。这种分解方式与电池老化过程中多时间尺度物理机制的耦合特征一致，从而为后续分别建模提供了合理的信号基础。

2.3 基于Transformer的主趋势函数预测模型

Transformer擅长用来学习相隔较远数据点之间的相关性，基于此，本研究开发了一个基于Transformer的主趋势函数预测模型。当与多头注意力机制相结合时，该模型可以从特征数据中学习更复杂的退化模式。因此，自注意力机制能够有效捕获电池老化过程中复杂的长期依赖关系与非线性退化模式，在处理此类复杂动态过程时展现出卓越能力。

在Transformer框架中，重要的矩阵包括查询矩阵 Q 、键矩阵 K 和值矩阵 V ，其均在自注意力机制中起到关键作用，是模型的核心。若将输入数据记为 x ，查询矩阵、键矩阵和值矩阵对应的权重矩阵分别记为 W_Q 、 W_K 和 W_V ，那么它们之间的关系可以表示为：

$$Q = xW_Q \quad (16)$$

$$K = xW_K \quad (17)$$

$$V = xW_V \quad (18)$$

多头注意力机制的输出计算公式如式(19)。

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (19)$$

式中， d_k 是 K 矩阵的维度， QK^T 为查询矩阵和键矩阵的点积相似度。

超参数在Transformer中起到重要的作用，因此选择合适的值对确保预测结果的准确性至关重要。在本研究选用Adam优化器，它的收敛速度更

快；与其他优化器相比，其具有更加稳定的性能，并且易于调试。批量大小设置为256，注意力头数设置为5，初始学习率设置为0.01，丢弃率设置为0.2。

通过前馈网络(feed forward network, FFN)进一步提取特征，有效增强模型的表达能力。

$$\text{FFN}(\delta) = \text{ReLU}(\delta W_1 + b_1)W_2 + b_2 \quad (20)$$

式中， W_1 和 W_2 为权重矩阵， δ 为输入数据， b_1 和 b_2 为偏置项。

2.4 基于LSTM的波动函数预测模型

与传统神经网络相比，长短期记忆网络(long short-term memory network, LSTM)通过在隐层引入一个状态量 c ，解决了在应对长序列数据时容易出现的梯度消失或者爆炸问题^[21]。其主要是由输入、遗忘和输出3个门组成，3个门相互配合从而更加有效地处理长时间序列，预测过程如下。

首先，利用遗忘门，整体上电池通过激活函数 σ 来遗忘某些信息，表达式如下：

$$f_t = \sigma(W_f \cdot [y_{t-1}, x_t] + B_f) \quad (21)$$

式中， W_f 和 B_f 分别为遗忘门的权值矩阵和偏置项。 x_t 和 y_{t-1} 分别为 t 时刻输入和 $t-1$ 时刻的输出。

输入门和输出门的计算过程如下：

$$i_t = \sigma(W_i \cdot [y_{t-1}, x_t] + B_i) \quad (22)$$

$$o_t = \sigma(W_o \cdot [y_{t-1}, x_t] + B_o) \quad (23)$$

式中， W_i 和 B_i 分别为输入门的权值矩阵和偏置项； W_o 和 B_o 分别为输出门的权值矩阵和偏置项。

记忆状态 C_t 一般用来控制并监测电池长期的状态，计算过程如下：

$$\tilde{C}_t = \tanh(W_c \cdot [y_{t-1}, x_t] + B_c) \quad (24)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (25)$$

$$y_t = o_t \tanh(C_t) \quad (26)$$

式中， W_c 和 B_c 分别为全矩阵和偏置项； \tilde{C}_t 和 C_t 分别为当前时刻 t 的状态和长期状态。

LSTM多门协作，能够有效应对变化幅度较大的数据。波动函数 $F(t)$ 的预测如下所示：

$$F(t+b) = \text{LSTM}(F_{t-b+1} \cdots F_t) \quad (27)$$

2.5 基于AVMDR的VFB的SOH预测框架

如图4所示，本研究的模型建立主要分为3部分。

(1) 数据获取及预处理。通过1.1节所示实验得到92个循环下的电池容量和SOH衰减数据。

(2) 自适应变分模态分解和重构。通过PSO

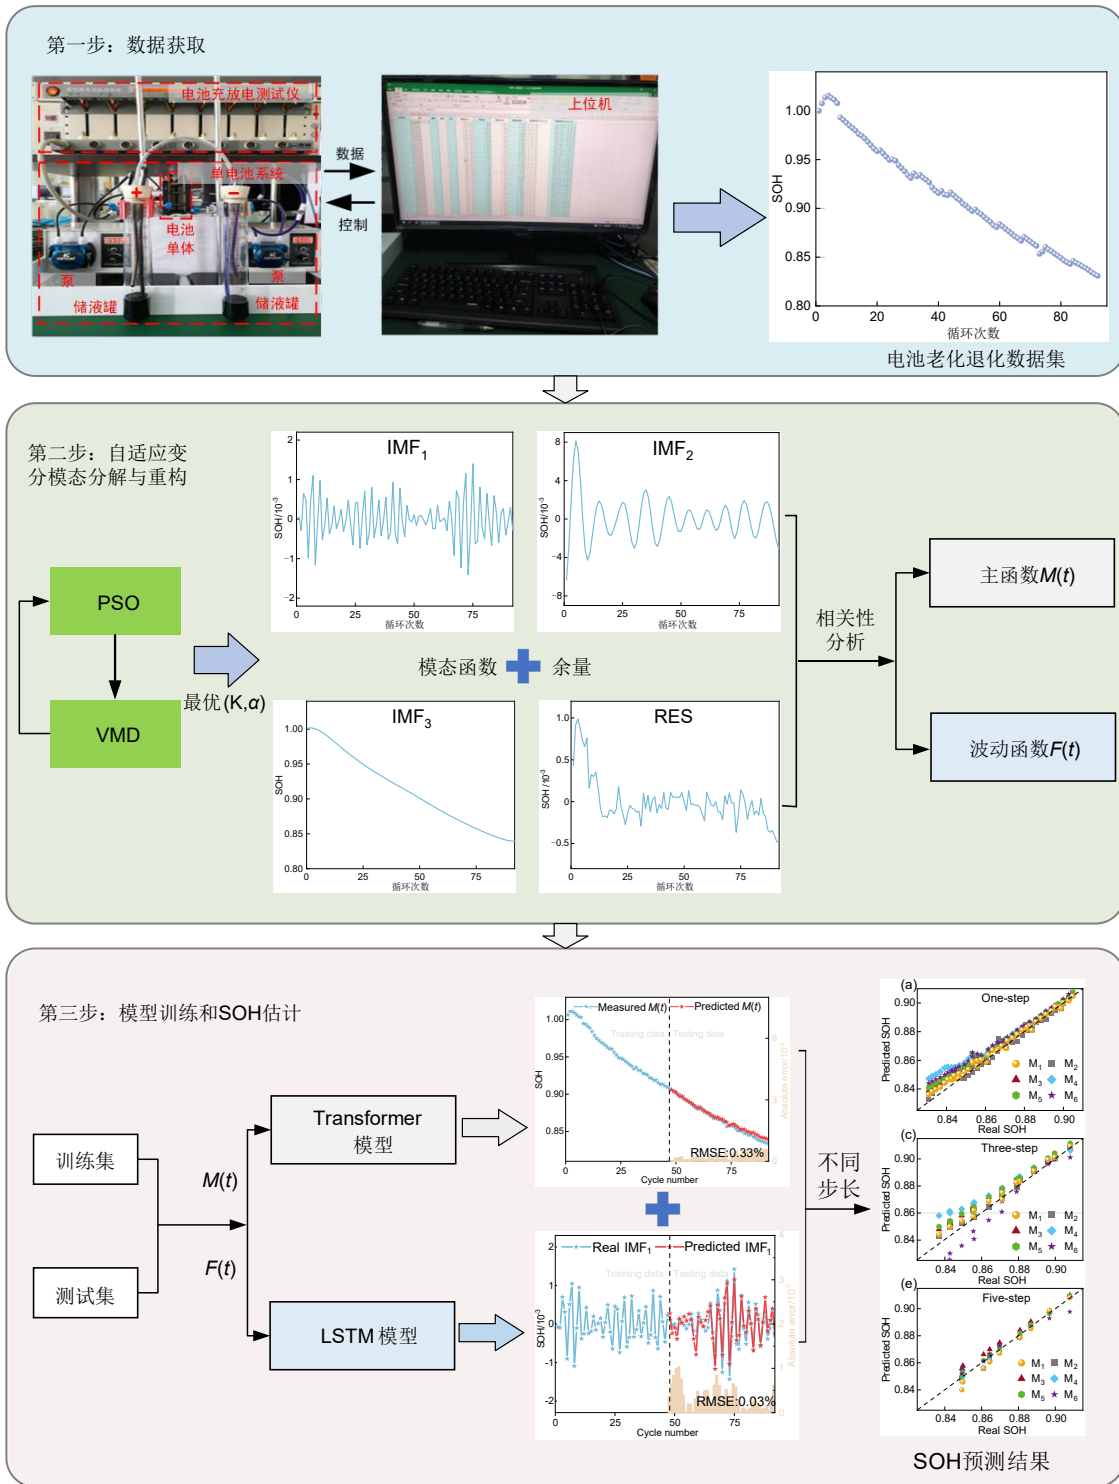


图4 基于AVMDR的VFB的SOH预测框架

Fig. 4 Framework of the SOH prediction model for VFB based on AVMDR

确定VMD的参数 K 和 α 的最优值组合。基于VMD将SOH变化趋势分解为3个本征模态函数IMFs和一个余量RES。根据相关性分析，对模态函数进行重构并得到波动函数 $F(t)$ 和主趋势函数 $M(t)$ 。

(3) 建立基于多时间尺度的VFB的SOH预测模型。将 $F(t)$ 和 $M(t)$ 的前50%数据划分为训练集，后50%数据划分为测试集。针对两种函数的特点，将各自的训练集分别置入LSTM和Transformer进

行学习，并利用测试集输出相加并验证结果，形成基于AVMDR的集成神经网络算法。通过改变神经网络内参数步长 b 建立基于多时间尺度的VFB的SOH预测模型。其中， $b=1$ 为短时间尺度， $b=3$ 为中时间尺度， $b=5$ 为长时间尺度。

3 结果与讨论

3.1 SOH时间序列分解

如图5所示，展示了当 K 取值为3时，分解得到的SOH时间序列各分量及主趋势函数 $M(t)$ 的构成。通过计算各本征模态函数与原始曲线之间的皮尔逊相关系数，并进一步求取平均相关系数，以判定是否将其归类为波动分量。表1列出了实验SOH各分量的皮尔逊相关系数及平均系数值。根据图5(b)所示， IMF_1 和 IMF_2 的相关系数低于平均系数，因此将 IMF_1 和 IMF_2 认定为表征容量再生的波动分量，并将其定义为波动函数 $F(t)$ 。所有剩余分量叠加后形成的组合分量，其变化趋势与原始函数极为接近，该分量被视为剔除容量再生影响后的SOH退化主趋势，定义为主趋势函数 $M(t)$ ，如图5(f)所示。

$$M(t) = IMF_2(t) + IMF_3(t) + RES(t) \quad (28)$$

研究发现， $M(t)$ 呈现出更为规则的单调递减趋势，这表明其几乎未受到容量再生效应的影响，从而验证了所提方法的合理性。最终推导出SOH的集成预测模型如下：

$$SOH(t) = \sum_{i=1}^N F_i(t) + M(t) \quad (29)$$

经分析确定，波动函数 $F(t)$ 包含两个项，因此将 N 的取值确定为2。

通过PSO-VMD自适应分解后，各IMF分量在频域上具有不同的中心频率与带宽。图3(c)~(d)显示，当 $K=3$ ， $\alpha=1000$ 时， IMF_1 为高频波动分量， IMF_2 与 IMF_3 为中低频缓变分量，这与容量再生(快速波动)和主体衰减(缓慢趋势)的物理时间尺度相符。进一步通过相关性重构，将相关系数低于平均水平的 IMF_1 与 IMF_2 归类为波动函数 $F(t)$ ，其余归类为主趋势函数 $M(t)$ 。该重构过程本质上是对信号物理意义的再识别： $F(t)$ 主要承载由电解液局部再平衡、离子重分布等引起的短期可逆波动； $M(t)$ 则承载由电解液整体失衡、膜老化等引起的长期不可逆衰减。因此，AVMDR不仅是一种数学分解工具，

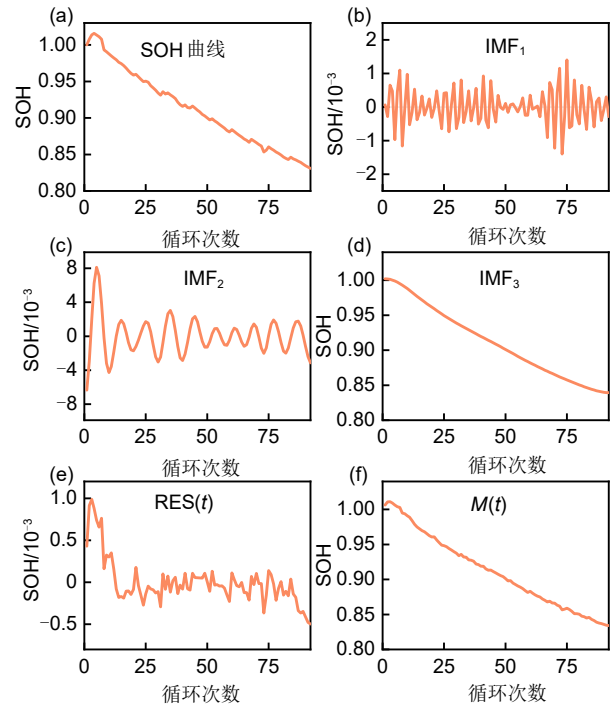


图5 基于AVMDR的健康状态时间序列：(a)原始SOH退化曲线，(b) IMF_1 ，(c) IMF_2 ，(d) IMF_3 ，(e) $RES(t)$ ，(f)重构的主函数 $M(t)$

Fig. 5 AVMDR-based on the SOH time series: (a) original SOH decay, (b) IMF_1 , (c) IMF_2 , (d) IMF_3 , (e) $RES(t)$, (f) main trend $M(t)$

表1 本征模态函数的相关性系数

Table 1 The correlation coefficient of the intrinsic mode function

模态分量	Pearson 相关性系数
IMF_1	0.0501
IMF_2	0.9976
IMF_3	0.9695
平均	0.6724

更是对电池老化多物理过程的一种时频解耦表示。

3.2 单步预测

考虑到深度学习存在结果不确定性，应避免由随机因素产生的误差。本研究采用预测值与真实值之间的均方根误差(root mean square error, RMSE)和决定系数(R^2)作为评估指标，用以分析指标的概率分布。根据概率分布划分若干区间或取值，并将出现概率最高的实验结果作为最终结果。基于蒙特卡洛采样得到的概率分布如图6所示。其中 $M(t)$ 、 IMF_1 和 IMF_2 的RMSE概率分布如图6所示。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_{pre})^2} \quad (30)$$

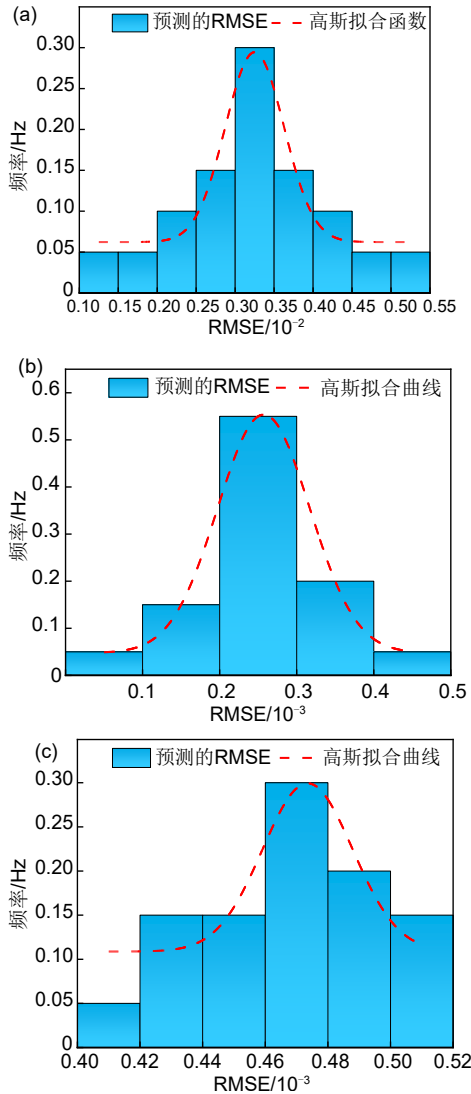


图6 不同成分的RMSE概率分布: (a) $M(t)$; (b) IMF_1 ; (c) IMF_2

Fig. 6 RMSE probability distribution: (a) $M(t)$; (b) IMF_1 ; (c) IMF_2

$$R^2 = 1 - \frac{\sum_{i=1}^N [y_{\text{real}}(i) - y_{\text{pre}}(i)]^2}{\sum_{i=1}^N [y_{\text{real}}(i) - \bar{y}_{\text{pre}}(i)]^2} \quad (31)$$

式中, $y_{\text{real}}(i)$ 表示SOH的实际测量值, $y_{\text{pre}}(i)$ 表示SOH的模型估计值, $\bar{y}_{\text{pre}}(i)$ 表示SOH模型估计值的均值, N 表示样本数量。

通过单步预测验证了所提模型的可行性,该方法利用当前时刻 t 的数据预测下一时刻 $t+1$ 的健康状态SOH($t+1$)。表2展示了LSTM模型的网络参数设置。将重构分量 $F(t)$ 和 $M(t)$ 的训练数据分别输入LSTM和Transformer网络进行训练,随后对测试数

据进行预测。最终整合两个模型的测试数据输出SOH预测值,并将其与SOH真实值进行对比分析。

表2 LSTM网络的超参数设置

Table 2 Parameters settings of the LSTM network

超参数	值
输入层	3
输出层	1
隐藏单元	100
学习率	0.01
最大迭代次数	500

图7展示了重构分量 $M(t)$ 、 $F(t)$ 及集成预测结果,包括真实值与预测SOH的误差及RMSE。研究表明,无论是重构分量还是集成分量均可实现精确预测,集成预测的RMSE始终控制在0.34%以内。结果表明:所提出的模型具有良好的性能与较高的预测精度,能有效处理电池老化过程中的容量再生现象。

为直观呈现所提模型的优越性,本研究采用5种对比模型:经验模态分解(empirical mode decomposition, EMD)+Transformer+LSTM^[22]、AVMDR+Transformer^[23]、AVMDR+LSTM^[24]、Transformer^[25]及LSTM^[25],依次命名为 $M_2 \sim M_6$,本研究提出的模型命名为 M_1 。各模型均遵循前述相同处理步骤,并考虑预测不确定性推导预测结果。图8(a)展示了 $M_1 \sim M_6$ 模型的单步预测结果。

为突显所提方法的优势,额外采用卷积神经网络(convolutional neural network, CNN)^[26]、极限学习机(extreme learning machine, ELM)^[27]和高斯过程回归(Gaussian process regression, GPR)^[28]作为SOH预测的对比实验,依次命名为 $M_7 \sim M_9$ 。图8(b)展示了上述3个模型的单步预测结果。

如图8(a)~(b)所示,在单步预测($b=1$)条件下,本研究所提模型(M_1)的预测曲线与实测SOH值高度吻合。从图9(a)定量评估来分析, M_1 的均方根误差RMSE仅为0.31%,决定系数 R^2 达到0.9791,显著优于其他对比模型($M_2 \sim M_9$)。这表明模型能够精准捕捉SOH的逐点变化规律,尤其对容量再生等非线性波动现象具有良好的跟踪能力。该结果验证了AVMDR分解重构策略与LSTM-Transformer混合架构在刻画电池短期退化行为方面的有效性。

3.3 多步预测

为验证模型的稳定性,本研究分别设置步长 $b=3$ 与 $b=5$,利用当前时刻 t 的SOH预测 $t+3$ 与 $t+5$

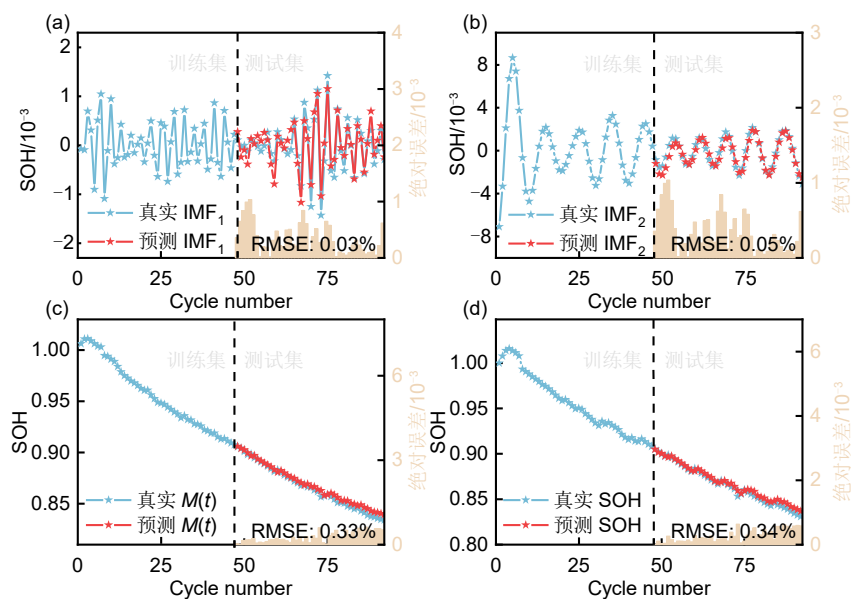


图 7 不同分量的预测结果：(a) 波动函数 IMF₁；(b) 波动函数 IMF₂；(c) 主函数 M(t)；(d) SOH 集成结果
 Fig. 7 Predicted results for different components: (a) Fluctuation signal IMF₁; (b) fluctuation signal IMF₂; (c) main trend M(t); (d) integrated predicted SOH results

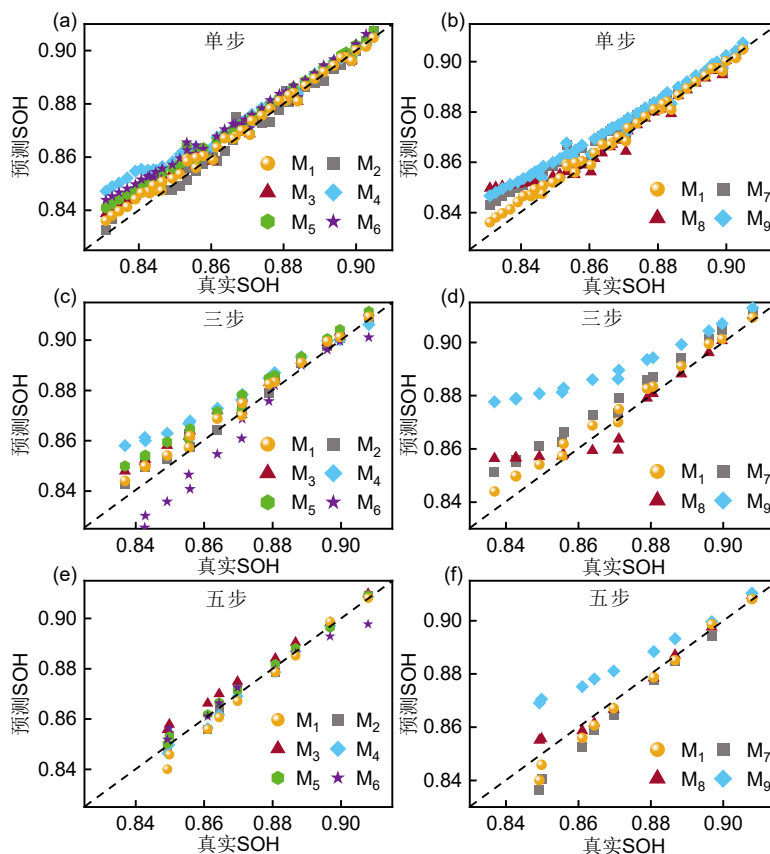


图 8 不同步长下 M₁~M₉ 模型预测结果对比：(a)~(b) 单步预测；(c)~(d) 三步预测；(e)~(f) 五步预测
 Fig. 8 Comparison of the prediction results of M₁—M₉ with different steps: (a)—(b) one-step prediction; (c)—(d) three-step prediction; (e)—(f) five-step prediction

时刻的SOH值。为保持预测一致性,采用相同的数据预处理方法。三步预测结果如图8(c)~(d)所示,预测指标见图9(b);五步预测结果如图8(e)~(f)所示,预测指标见图9(c)。

随着预测步长增加,模型的长期推理能力面临更大挑战。在三步预测和五步预测中,如图8(c)~(f)所示,多数对比模型(如 M_7 、 M_8)的预测误差显著增大,且轨迹偏离实际值。相比之下,所提模型 M_1

在不同步长下均保持稳定的预测性能:三步预测RMSE为0.38%,五步预测RMSE仍控制在0.45%以内, R^2 始终高于95.04%。这一现象说明了主趋势函数 $M(t)$ 的建模具有有效性,波动分量 $F(t)$ 的局部补偿作用合理,并且该算法架构具有协同优势。

综上所述,本研究所提集成模型具有通用性强、可行性高的特点,相比其他模型展现出更优异的长时间预测能力,并在不同时间尺度下均能保持良好性能。

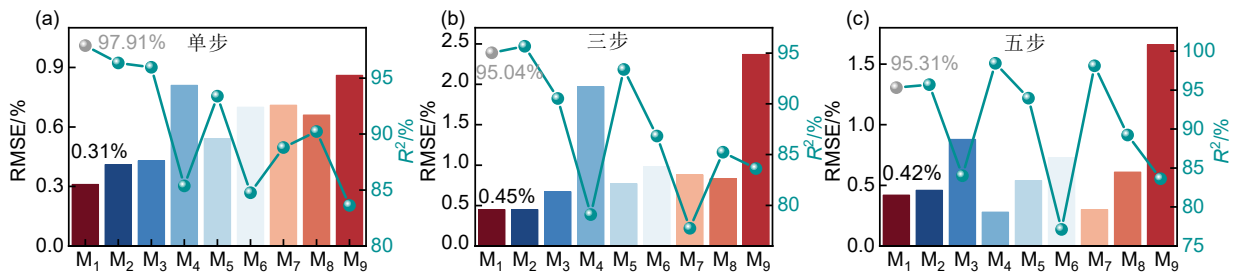


图9 M_1 ~ M_9 在不同步长下的RMSE和 R^2 : (a) 单步; (b) 三步; (c) 五步

Fig. 9 Prediction evaluation indexes for RMSE and R^2 of M_1 — M_9 for different step sizes: (a) one-step; (b) three-step; (c) five-step

3.4 增长率

为量化并比较在时间尺度增长时的模型稳定性差异,探寻多步指标与多步指标,多步指标与单步指标之间的关系。通过给出平均环比增长率和平均定基增长率来表示随着时间尺度的增大,模型性能的衰减情况。两种指标的值越小,代表模型从短时间尺度到中时间尺度,最后到长时间尺度的预测能力越强。计算公式如下:

$$\overline{RGR}(i) = \left[\frac{L_{TS}(i) - L_{OS}(i)}{L_{OS}(i)} + \frac{L_{FS}(i) - L_{TS}(i)}{L_{TS}(i)} \right] / 2 \times 100\% \quad (32)$$

$$\overline{FGR}(i) = \left[\frac{L_{TS}(i) - L_{OS}(i)}{L_{OS}(i)} + \frac{L_{FS}(i) - L_{OS}(i)}{L_{OS}(i)} \right] / 2 \times 100\% \quad (33)$$

式中, $L_{OS}(i)$ ($i=1,2,\dots,9$)为 M_1 ~ M_9 的单步预测RMSE, $L_{TS}(i)$ 为三步预测RMSE, $L_{FS}(i)$ 为五步预测RMSE。

图10展示了电池1#在九种模型多时间尺度预测的平均环比增长率和平均定基增长率大小比较。从单步到多步预测的过渡中, M_1 的RMSE增长率显著低于对比模型,进一步证明其在不同时间尺度下均具备优异的稳健性。这一特性对实际电池管理系统的运维决策具有重要价值:短期预测可支撑实时健康状态评估与故障预警,而中长期预测能力则

为系统维护周期规划与剩余寿命估算提供了可靠依据,从而全面提升全钒液流电池储能系统的经济运行水平与可靠性。

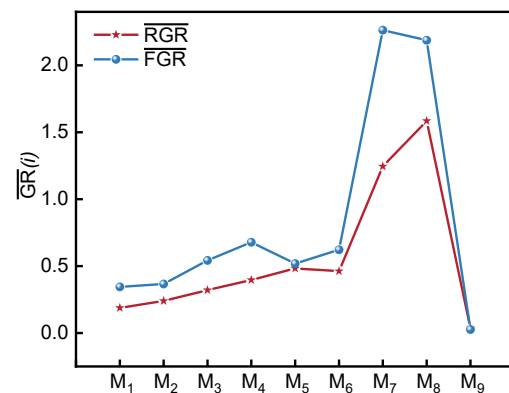


图10 M_1 ~ M_9 下的平均增长率比较

Fig. 10 Comparison of average growth rates for M_1 — M_9

3.5 工程应用分析

本研究所提出的SOH预测模型,其价值体现在对全钒液流电池储能系统实际运行与维护的指导上,具体而言,工程应用价值体现在以下3个方面。

(1) 本模型通过精准预测SOH的短期($b=1,3$)及中长期($b=5$)衰减趋势,能够为运维人员提供一个前瞻性的“维护时间窗口”,从而避免系统因容量骤

降而退出运行，保障储能系统的连续性与可靠性。

(2) 主趋势函数 $M(t)$ 有效地剥离了容量再生现象带来的随机波动，揭示了电池容量的整体衰减规律，这为准确评估电池的剩余使用寿命(RUL)奠定了坚实基础。其保证能够动态、高置信度地预估出电池达到该阈值的剩余循环次数，为储能项目的寿命评估、经济性分析及备品备件管理提供关键数据支持。

(3) 模型所输出的多时间尺度 SOH 信息，可以进一步与系统的运行控制策略相结合。在预知电池即将进入加速衰减阶段时，BMS 可自适应地调整充放电策略(如优化电流密度、控制电解液流速等)，以平缓衰减速率，延长电池的有效寿命。这种基于健康状态预测的闭环控制，能够最大化全钒液流电池在全生命周期内的利用效率与经济价值。

综上所述，本研究提出的 AVMDR-INN 模型不仅是一个高精度的预测工具，更是一个能够直接嵌入实际 BMS、提升系统智能化运维水平的关键技术，具有明确的工程应用前景和推广价值。

4 结论

为提升全钒液流电池系统性能并保障其长期可靠安全运行，本研究提出了一种基于自适应变分模态分解与重构与融合神经网络的 VFB 健康状态预测模型。该模型通过 AVMDR 将 SOH 时间序列信号分解重构为主趋势函数 $M(t)$ 与波动函数 $F(t)$ ，进而采用 Transformer 与 LSTM 融合的多尺度数据驱动方法，实现不同预测步长下的精确容量估计，本研究主要贡献如下。

(1) 利用 AVMDR 对 VFB 的 SOH 时间序列进行分解，获取最佳参数组合 (K, α) 下的本征模态函数，并基于相关性分析重构出表征 SOH 退化主趋势的 $M(t)$ 与刻画容量再生现象的 $F(t)$ 。

(2) 针对 $M(t)$ 与 $F(t)$ 的不同特性，分别构建基于 Transformer 与 LSTM 的融合预测模型，该方法具有良好的可靠性与可行性。

(3) 模型预测结果呈现概率分布特征，采用最高概率值作为输出结果，从而提升融合模型的鲁棒性与可靠性。

(4) 通过调整预测步长，实现多时间尺度下的 SOH 估计。实验结果表明：相较现有方法，本研究所提集成模型在多时间尺度下均表现出更高的预测精度与稳定性，其 RMSE 均低于 0.45%。

未来工作将集中于采用更大规模电池数据集，并考虑循环过程中温度因素的影响，以提升模型的泛化能力与工程适用性。

参考文献

- [1] 金阳. 新能源电力系统中的储能技术研究[J]. 低碳世界, 2023, 13(11): 49-51. DOI:10.3969/j.issn.2095-2066.2023.11.017.
JIN Y. Research on energy storage technology in new energy power system[J]. Low Carbon World, 2023, 13(11): 49-51. DOI: 10.3969/j.issn.2095-2066.2023.11.017.
- [2] 李建林, 梅岩竹, 王茜, 等. 全钒液流电池建模研究现状及展望[J]. 储能科学与技术, 2025, 14(12): 4618-4631.
LI J L, MEI Y Z, WANG Q, et al. Current status of vanadium redox flow battery modeling and research advances in data-driven approaches[J]. Energy Storage Science and Technology, 2025, 14(12): 4618-4631.
- [3] 严腾飞, 曾义凯, 许刚. 全钒液流电池电解液制备技术研究进展[J]. 制冷与空调(四川), 2025, 39(3): 381-387, 438. DOI: 10.3969/j.issn.1671-6612.2025.03.011.
YAN T F, ZENG Y K, XU G. Research progress on electrolyte preparation technologies for all-vanadium redox flow battery[J]. Refrigeration & Air Conditioning, 2025, 39(3): 381-387, 438. DOI: 10.3969/j.issn.1671-6612.2025.03.011.
- [4] 郑衍森, 苏黄盛, 梁业盈, 等. 风力发电用储能电池技术的发展现状及展望[J]. 电力电容器与无功补偿, 2025, 46(4): 1-12. DOI: 10.14044/j.1674-1757.pcrpc.2025.04.001.
ZHENG Y S, SU H S, LIANG Y Y, et al. Development status and prospects of energy storage batteries for wind power generation [J]. Power Capacitor & Reactive Power Compensation, 2025, 46(4): 1-12. DOI:10.14044/j.1674-1757.pcrpc.2025.04.001.
- [5] 王帅, 王远洋. 全钒氧化还原液流电池电解液的制备和性能优化研究进展[J]. 工业催化, 2025, 33(4): 26-33. DOI:10.3969/j.issn.1008-1143.2025.04.004.
WANG S, WANG Y Y. Research progress on preparation and performance optimization of all vanadium redox flow battery electrolyte[J]. Industrial Catalysis, 2025, 33(4): 26-33. DOI: 10.3969/j.issn.1008-1143.2025.04.004.
- [6] 岳孟, 郑琼, 阎景旺, 等. 液流电池流场结构设计与优化研究进展[J]. 化工进展, 2021, 40(9): 4853-4868. DOI: 10.16085/j.issn.1000-6613.2021-0558.
YUE M, ZHENG Q, YAN J W, et al. Progress in flow field structure design and optimization for flow battery[J]. Chemical Industry and Engineering Progress, 2021, 40(9): 4853-4868. DOI: 10.16085/j.issn.1000-6613.2021-0558.
- [7] 熊瑞. 考虑水分子迁移的全钒液流电池容量失衡机理与建模方法研究[D]. 武汉: 武汉理工大学, 2022.
XIONG R. Research on the vanadium redox flow battery capacity imbalance mechanism and its modeling considering water molecules migration[D]. Wuhan: Wuhan University of Technology, 2022.
- [8] SUN C X, CHEN J, ZHANG H M, et al. Investigations on transfer of water and vanadium ions across Nafion membrane in an operating

- vanadium redox flow battery[J]. *Journal of Power Sources*, 2010, 195(3): 890-897. DOI:10.1016/j.jpowsour.2009.08.041.
- [9] 杨皓凌, 徐昆誉, 张琪, 等. 钒液流电池中的改性Nafion膜[J]. *化学进展*, 2023, 35(11): 1595-1612.
YANG H L, XU K Y, ZHANG Q, et al. Modified Nafion membrane in vanadium redox flow battery[J]. *Progress in Chemistry*, 2023, 35(11): 1595-1612.
- [10] SONG Y X, LI X R, XIONG J, et al. Electrolyte transfer mechanism and optimization strategy for vanadium flow batteries adopting a Nafion membrane[J]. *Journal of Power Sources*, 2020, 449: 227503. DOI:10.1016/j.jpowsour.2019.227503.
- [11] 朱兆武, 张旭堃, 苏慧, 等. 全钒液流电池提高电解液浓度的研究与应用现状[J]. *储能科学与技术*, 2022, 11(11): 3439-3446. DOI: 10.19799/j.cnki.2095-4239.2022.0329.
ZHU Z W, ZHANG X K, SU H, et al. Research and application of increasing electrolyte concentration in all vanadium redox flow battery[J]. *Energy Storage Science and Technology*, 2022, 11(11): 3439-3446. DOI:10.19799/j.cnki.2095-4239.2022.0329.
- [12] 李先锋, 张华民, 张洪章. 全钒液流电池用多孔离子传导隔膜制备、结构调控及应用研究[C]//中国电子学会化学与物理电源技术分会, 中国化学与物理电源行业协会, 中国电工技术学会氢能发电装置专业委员会, 等. 第30届全国化学与物理电源学术年会论文集. 辽宁: 中科院大连化学物理研究所, 2013: 140.
- [13] XIONG B Y, ZHAO J Y, SU Y X, et al. State of charge estimation of vanadium redox flow battery based on sliding mode observer and dynamic model including capacity fading factor[J]. *IEEE Transactions on Sustainable Energy*, 2017, 8(4): 1658-1667. DOI: 10.1109/TSTE.2017.2699288.
- [14] XIONG B Y, TANG J R, LI Y, et al. A flow-rate-aware data-driven model of vanadium redox flow battery based on gated recurrent unit neural network[J]. *Journal of Energy Storage*, 2023, 74: 109537. DOI:10.1016/j.est.2023.109537.
- [15] KHAKI B, DAS P. Sensorless parameter estimation of vanadium redox flow batteries in charging mode considering capacity fading [J]. *Journal of Energy Storage*, 2021, 33: 102033. DOI:10.1016/j.est.2020.102033.
- [16] 杨斌. 全钒液流电池性能研究及SOC预测[D]. 西安: 西安理工大学, 2024.
YANG B. Performance research and SOC prediction of all-vanadium redox flow battery[D]. Xi'an: Xi'an University of Technology, 2024.
- [17] 曹鹏程, 吴和培, 刘浩, 等. 全钒液流电池电解液及隔膜研究进展[J]. *化工生产与技术*, 2024, 30(6): 13-17, 37. DOI:10.3969/j.issn.1006-6829.2024.06.004.
CAO P C, WU H P, LIU H, et al. Research progress in all vanadium flow batteries[J]. *Chemical Production and Technology*, 2024, 30(6): 13-17, 37. DOI:10.3969/j.issn.1006-6829.2024.06.004.
- [18] 李子鉴. 钒电池用双二氮杂萘酮聚芳醚磺离子交换膜[D]. 大连: 大连理工大学, 2024.
LI Z J. Ion exchange membrane of bis-phthalazinone poly(aryl ether sulfone) for vanadium battery[D]. Dalian: Dalian University of Technology, 2024.
- [19] 叶涛, 王怡君, 唐子龙, 等. 全钒液流电池电解液容量衰减及草酸恢复研究[J]. *储能科学与技术*, 2025, 14(3): 1177-1186.
YE T, WANG Y J, TANG Z L, et al. Investigation of capacity fading in vanadium flow battery electrolytes and recovery via oxalic acid[J]. *Energy Storage Science and Technology*, 2025, 14(3): 1177-1186.
- [20] 罗碧灵. 基于优化VMD和IWOA的MMC子模块故障诊断方法研究[D]. 阜新: 辽宁工程技术大学, 2023.
LUO B L. Research on fault diagnosis method for MMC submodules based on optimized VMD and IWOA[D]. Fuxin: Liaoning Technical University, 2023.
- [21] 王丽玲, 孙晓波, 宋树平, 等. 基于QPSO-LSTM模型的锂电池剩余容量预测[J]. *机械与电子*, 2024, 42(9): 52-56, 64. DOI:10.3969/j.issn.1001-2257.2024.09.008.
WANG L L, SUN X B, SONG S P, et al. Prediction of remaining capacity of lithium battery based on QPSO-LSTM model[J]. *Machinery & Electronics*, 2024, 42(9): 52-56, 64. DOI:10.3969/j.issn.1001-2257.2024.09.008.
- [22] 朱铮, 戴辰, 蒋超, 等. 改进型CNN-LSTM深度学习神经网络的台区户变拓扑关系识别[J]. *电气自动化*, 2024, 46(4): 93-95. DOI: 10.3969/j.issn.1000-3886.2024.04.028.
ZHU Z, DAI C, JIANG C, et al. Recognition of topological relationship between substation transformers and users based on improved CNN-LSTM deep learning neural network[J]. *Electrical Automation*, 2024, 46(4): 93-95. DOI: 10.3969/j.issn.1000-3886.2024.04.028.
- [23] WANG R H, LI C S, FU W L, et al. Deep learning method based on gated recurrent unit and variational mode decomposition for short-term wind power interval prediction[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 31(10): 3814-3827. DOI:10.1109/TNNLS.2019.2946414.
- [24] 陈逸嘉, 陶力, 李凯, 等. 基于IMIFS-VMD和ROA-LSTM的日前电价预测方法[J]. *自动化技术与应用*, 2025, 44(9): 23-28. DOI: 10.20033/j.1003-7241.(2025)09-0023-06.
CHEN Y J, TAO L, LI K, et al. Day-ahead electricity price forecasting method based on IMIFS-VMD and ROA-LSTM[J]. *Techniques of Automation and Applications*, 2025, 44(9): 23-28. DOI:10.20033/j.1003-7241.(2025)09-0023-06.
- [25] 刘富强, 刘为国, 朱洪波, 等. 基于KPCA与NRBO-Transformer的锂电池健康状态评估方法[J/OL]. *重庆理工大学学报(自然科学)*, 1-12 [2025-10-14]. <https://link.cnki.net/urlid/50.1205.T.20250904.1006.002>.
- [26] 池贝贝. 基于DEKF联合CNN-LSTM-Attention的锂电池SOC估计[J]. *软件*, 2024, 45(7): 134-137. DOI: 10.3969/j.issn.1003-6970.2024.07.041.
CHI B B. SOC estimation of lithium batteries based on DEKF combined with CNN-LSTM-attention[J]. *Computer Engineering & Software*, 2024, 45(7): 134-137. DOI:10.3969/j.issn.1003-6970.2024.07.041.
- [27] 于小芳, 陈苏声, 周怡. 基于ELM锂离子电池RUL预测优化方法研究[J]. *环境技术*, 2024, 42(6): 143-147. DOI:10.3969/j.issn.1004-7204.2024.06.032.
YU X F, CHEN S S, ZHOU Y. Research on RUL predictive optimization method based on ELM lithium-ion battery[J]. *Environmental Technology*, 2024, 42(6): 143-147. DOI:10.3969/j.issn.1004-7204.2024.06.032.
- [28] ZHANG Y W, TANG Q C, ZHANG Y, et al. Identifying degradation patterns of lithium ion batteries from impedance spectroscopy using machine learning[J]. *Nature Communications*, 2020, 11: 1706. DOI:10.1038/s41467-020-15235-7.