

基于N-BEATS和相关向量机的锂电池健康状态混合预测方法

李泽龙, 乔钢柱, 崔方舒, 蔡江辉

(中北大学 计算机科学与技术学院, 山西 太原 030051)

摘要: 锂离子电池是众多领域的能源核心部件, 准确预测其生命周期内的健康状态至关重要, 因此本文提出了一种基于神经基扩展分析(N-BEATS)和相关向量机的锂电池健康状态混合预测方法。首先, 为了提高预测的准确性, 利用变分模态分解方法对原始时间序列进行分解; 其次, 将分解后的子序列根据中心频率划分为高频和低频子序列, 利用具有残差原理的深层神经网络N-BEATS模型和相关向量机模型分别对其进行建模预测; 最后, 通过对各个子序列的预测结果进行叠加重构得到最终的预测结果。为了验证所提方法的有效性, 本文使用NASA和CALCE提供的锂离子电池数据进行了仿真实验。实验结果表明, 与单一的N-BEATS模型和相关向量机模型相比, 所提混合方法能够有效地结合两种模型的优势, 展现出较高的预测精度。进一步地, 与长短期记忆网络、高斯过程回归、支持向量回归模型进行对比, 所提方法的均方根误差分别降低了96.5%, 74.5%和62.5%, 均方误差分别降低了97.3%, 76.7%和58.8%。

关键词: 锂离子电池; 健康状态; N-BEATS模型; 变分模态分解; 相关向量机

中图分类号: TM912 **文献标识码:** A **doi:** 10.62756/jnuc.issn.1673-3193.2024.05.0016

引用格式: 李泽龙, 乔钢柱, 崔方舒, 等. 基于N-BEATS和相关向量机的锂电池健康状态混合预测方法[J]. 中北大学学报(自然科学版), 2025, 46(3): 316-325.

LI Zelong, QIAO Gangzhu, CUI Fangshu, et al. A hybrid method based on N-BEATS and relevance vector machine for predicting state of health of lithium-ion batteries [J]. Journal of North University of China (Natural Science Edition), 2025, 46(3): 316-325.

A Hybrid Method Based on N-BEATS and Relevance Vector Machine for Predicting State of Health of Lithium-Ion Batteries

LI Zelong, QIAO Gangzhu, CUI Fangshu, CAI Jianghui

(School of Computer Science and Technology, North University of China, Taiyuan 030051, China)

Abstract: As a core energy component in many fields, accurate prediction of state of health (SOH) is crucial for lithium-ion battery during their lifecycle. A hybrid prediction method based on Neural Basis Expansion Analysis (N-BEATS) and relevance vector machine (RVM) was proposed. Firstly, variational mode decomposition was used to decompose the original time series to improve the accuracy of prediction; Secondly, the decomposed subsequence was divided into high-frequency and low-frequency subsequences based on the center frequency, and the deep neural network N-BEATS model with residual principle and RVM model were used to model and predict them respectively; Finally, the prediction results of each subsequence were overlaid and reconstructed to obtain the final prediction results. To verify the effectiveness of the proposed method,

收稿日期: 2024-05-20

基金项目: 山西省基础研究计划资助项目(202303021222084); 山西省研究生教育创新项目(2024KY613)

作者简介: 李泽龙(2001-), 男, 硕士生, 主要从事储能电池健康管理的研究。

通信作者: 乔钢柱(1975-), 男, 教授, 博士, 主要从事物联网技术及应用, 大数据处理及区块链技术研究。E-mail: qiaogz@nuc.edu.cn.

this paper conducted simulation experiments using lithium-ion battery data provided by NASA and CALCE. The experimental results show that compared with the single N-BEATS model and the RVM model, the proposed hybrid method can effectively combine the advantages of the two models and demonstrate higher prediction accuracy. Furthermore, compared with the long short-term memory network, Gaussian process regression, and support vector regression models, the root mean square error of the proposed method is reduced by about 96.5%, 74.5%, and 62.5%, and the mean square error is reduced by 97.3%, 76.7%, and 58.8%, respectively.

Key words: lithium-ion battery; state of health; N-BEATS model; variational mode decomposition; relevance vector machine

0 引言

锂离子电池因其循环寿命长、无记忆效应、能量密度高和功率密度高等优点,在交通、能源汽车、移动设备等领域得到了广泛的应用,但锂离子电池的安全性和可靠性问题亟待解决^[1]。因此,研究锂离子电池的容量退化状态,进而预测其健康状态(State of Health, SOH)以及剩余使用寿命(Remaining Useful Life, RUL)对电池系统的安全性具有重要意义^[2]。一般认为,当锂离子电池当前容量小于出厂容量的70%~80%时则判定电池报废^[3]。目前,预测锂电池SOH的方法主要有三种:基于模型的方法、数据驱动的方法和混合的方法^[4]。

基于模型的方法根据电池内部工作原理、材料性质和电化学反应进行监测和分析,通过构建电化学模型、等效电路模型等方法来分析锂离子电池的内部参数来完成SOH预测^[5-7]。尽管基于模型的方法在预测性能上表现良好,但此类模型通常结构复杂且适用性较差。相对而言,数据驱动方法是利用电池历史退化数据来了解电池的行为模式和特征,并推导出预测模型而不依赖于复杂的物理模型^[8]。杨彦茹等^[9]通过结合完备集经验模态分解和支持向量回归算法(Support Vector Regression, SVR)建立锂离子电池RUL预测模型,克服了局部最优值问题,并增强了模型预测结果的准确性。与SVR相比,相关向量机(Relevance Vector Machine, RVM)具有更高的稀疏性,且能够提供概率性预测,Wang等^[10]提出了一种基于RVM算法的容量退化模型,用于电池退化建模,其在RUL预测方面取得了不错的预测结果。随着深度学习的发展,神经网络也被广泛应用到锂离子电池的SOH和RUL研究中。Heinrich等^[11]使用长短期记忆网络(Long Short-Term Memory, LSTM)模型来捕捉电池退化的长期趋势,

该模型因在处理时间序列数据的长期依赖性方面表现突出而取得了不错的预测效果。然而,数据驱动方法严重依赖历史数据,当电池在实际应用中出现历史数据数量有限或质量差的情况时,将严重影响SOH的预测精度,导致评估结果不可靠。

单独采用模型预测或数据驱动预测方法存在一定的局限性,而混合模型可以通过结合不同算法的优势显著提升预测的精度和鲁棒性,因此,越来越多的锂离子电池SOH研究倾向于采用多模型混合的方法^[12]。在这些混合方法中,通过建立混合神经网络模型进行锂离子电池SOH预测,预测结果优于单一神经网络模型,并且预测拟合度和准确性更高^[13-15]。

经过上述分析,本文提出了一种基于神经基扩展分析(Neural Basis Expansion Analysis, N-BEATS)和RVM的锂电池健康状态混合预测方法。首先,通过变分模态分解(Variational Mode Decomposition, VMD)方法,将锂离子电池容量退化数据分解成多个子序列。然后,采用RVM对低频分量进行处理,利用其稀疏解的特性和较低的计算成本有效捕捉了电池的长期退化趋势。N-BEATS作为一种简单的全连接层神经网络架构,在捕捉高频细节和快速变动信息时具有优势,因此其被用来对高频分量进行建模预测。最后,通过将N-BEATS和RVM的预测结果进行叠加重构,成功地整合了两种模型的优势,以获得更为精确的电池健康状态预测。此外,通过与几种主流的预测方法进行比较检验了所提混合方法的预测性能。

1 算法设计

1.1 实验数据集

本文所用到的锂离子电池相关数据来自NASA和CALCE的公开锂电池寿命测试数据集^[16-17]。选取了NASA提供的B05、B06、B07和B18号电池以

及CALCE提供的CS2_35和CS2_36共6组锂电池数据进行仿真实验。NASA和CALCE的电池容量衰退曲线如图1和图2所示,同类型电池的容量衰减特征有着相似之处,都是在前期退化比较缓慢,后期退化加速,并出现多个局部自恢复现象。




图1 NASA电池容量衰退曲线

Fig. 1 Battery capacity degradation curves of NASA




图2 CALCE电池容量衰退曲线

Fig. 2 Battery capacity degradation curves of CALCE

1.2 变分模态分解

由于锂离子电池原始数据具有复杂的非线性特征,直接进行预测难以获得预期效果。经验模态分解是一种有效的非线性信号处理方法,然而面对复杂的电池老化过程可能会遇到模态混叠等挑战,为了克服这一问题,VMD作为一种改进的信号分解方法,通过其自适应、非递归信号分解的特性能够有效地将原始信号分解成多个模态分量^[18]。这种分解策略有助于减少非线性对预测结果的不利影响,从而提高锂电池健康状态预测的准确性。

VMD实质为变分问题,得到的约束变分问题可以表达为

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta_t + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (1)$$

式中: $u_k = \{u_1, u_2, \dots, u_n\}$ 和 $\omega_k = \{\omega_1, \omega_2, \dots, \omega_n\}$ 表示VMD分解的 k 个模态分量和对应的中心频率; *表示卷积运算; δ_t 为狄克拉函数; ∂_t 为梯度运算。式(1)满足 $\sum_k u_k = f$ 约束。

求解上述方程,引入二次惩罚项 α 和拉格朗日乘数 λ ,得到模态 u_k 的求解公式为

$$\hat{u}_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)}{1 + 2\alpha(\omega - \omega_k)^2} \quad (2)$$

中心频率的求解公式为

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (3)$$

最终VMD分解算法的具体过程如下:

1) 初始化 $\{\hat{u}_k^1\}, \{\omega_k^1\}, \hat{\lambda}^1, 0 \rightarrow n$

2) 重复

$$n \leftarrow n + 1,$$

更新所有 $\omega \geq 0$ 的 $\hat{u}_k, k \in [1, K]$,

$$\hat{u}_k^{n+1}(\omega) =$$

$$\frac{\hat{f}(\omega) - \sum_{i < k} \hat{u}_i^{n+1}(\omega) + \sum_{i > k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (4)$$

更新 ω_k ,

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (5)$$

使用对偶上升法, $\omega \geq 0$, 得

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau \left(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (6)$$

3) 直到收敛: $\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \epsilon$ 。

1.3 相关向量机

相关向量机算法是一种基于贝叶斯推断原理的机器学习技术,其核心优势在于通过剔除不相关样本点实现模型的稀疏表示^[19]。这种稀疏性不仅优化了模型结构,而且通过减少不必要的参数,增强了模型的泛化能力。与非稀疏模型相比,RVM的应用降低了模型的复杂度,同时提高了预测性能。在锂

电池数据的分析领域, RVM 算法特别适用于处理具有线性特征的低频分量。

RVM 算法给定训练数据集 $\{X_i, Y_i\}$ 、 N , 其中, X_i 是输入向量, Y_i 是目标值, N 是训练数据的长度, RVM 算法的回归表达式为

$$y(x, \boldsymbol{w}) = \sum_{i=1}^N w_i K(x, x_i) + w_0, \quad (7)$$

$$t_n = y(x_n, \boldsymbol{w}) + \epsilon_n, \quad n = 1, 2, \dots, N, \quad (8)$$

式中: ϵ_n 为噪声误差, 其服从高斯分布, 其中, 均值为 0, 方差为 σ ; $\boldsymbol{w} = [w_0, \dots, w_n]^T$ 为权重向量; t_n 为 $y(x_n, \boldsymbol{w})$ 的回归值; $K(x, x_i)$ 为核函数。

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|}{\eta^2}\right), \quad (9)$$

式中: η 为核函数。

如果利用 \boldsymbol{w} 和 ϵ 直接预测, 容易导致过拟合, 同时模型也较难实现稀疏。因此, 引入超参数 α_i , 并假设 w_i 服从零均值且方差为 α_i^{-1} 的高斯分布, 其表达式为

$$p(w_i | \alpha_i) \sim N(w_i | 0, \alpha_i^{-1}), \quad (10)$$

$$p(\boldsymbol{w} | \boldsymbol{\alpha}) \sim \prod_{i=0}^N N(w_i | 0, \alpha_i^{-1}), \quad (11)$$

式中: $\boldsymbol{\alpha} = [\alpha_0, \alpha_1, \dots, \alpha_N]$ 。

使用迭代预测法进行计算, 得到新的超参数 α 和噪声方差 σ^2 , 其更新过程为

$$(\alpha)^{\text{new}} = \frac{\lambda_i}{\mu_i^2}, \quad (12)$$

$$(\sigma^2)^{\text{new}} = \frac{\|y - \phi\boldsymbol{\mu}\|}{N - \sum_{i=0}^N \gamma_i}. \quad (13)$$

在更新过程中, 大部分 α_i 趋于无穷, 其余的 α_i 对应的 (x_i, y_i) 就是相关向量, 这些相关向量揭示了数据集最本质的特征。

1.4 N-BEATS 网络

N-BEATS 神经网络是一种用于时间序列预测的模型, 它与传统的循环神经网络不同, 后者通常包含记忆门和遗忘门。该方法凭借其简单的全连接网络架构, 实现了在处理时间序列数据的非线性和复杂动态时的高灵活性和效率^[20]。利用其结构优势, 能够有效捕捉时间序列数据中的短期波动和低频变化, 即便在小样本数据集上也能提供准确的预测结果。

N-BEATS 的网络模型结构如图 3 所示, 主要思想是将时间序列分解为多个自回归组件, 并使用堆叠式的全连接层进行预测。

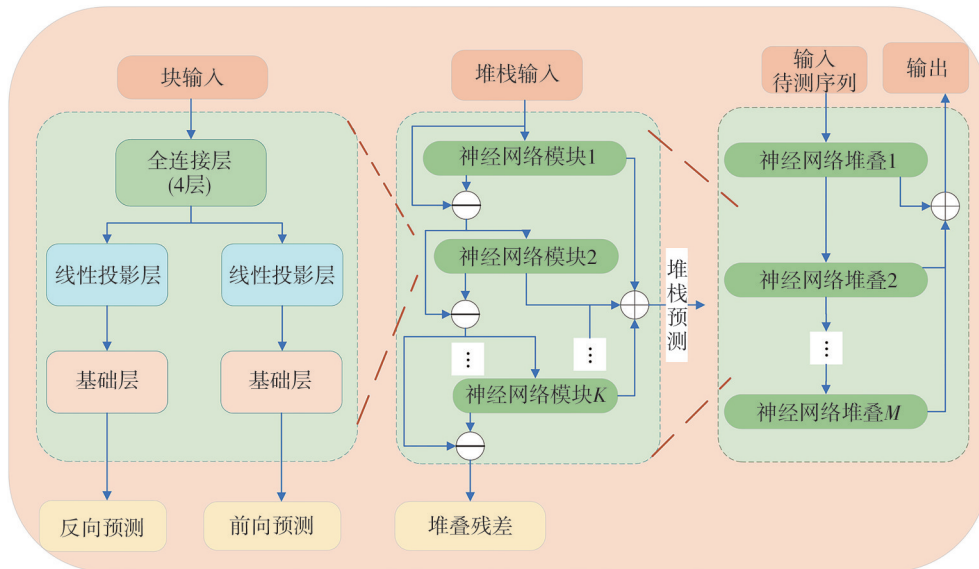


图 3 N-BEATS 神经网络结构图

Fig. 3 The neural network structure of the N-BEATS

N-BEATS 模型的核心在于其灵活性, 其中“N”代表模型可配置的层数, 允许模型适应不同的数据集和预测任务。N-BEATS 模型的基本构成包括两种类型的基础模块: 堆叠式全连接层模块和逆残差模块。其中, 堆叠式全连接层模块由

多个全连接层组成, 负责对输入数据执行线性变换。每个全连接层的输出是输入的线性组合, 为模型提供了捕捉时间序列数据中的复杂关系的能力。逆残差块模块由两个堆叠的全连接层和一个跳跃连接组成。跳跃连接允许模型绕过某些层直

接传递信息。此外,逆残差块中包含的门控单元可以调节信息流,增强模型的可解释性。在N-BEATS中,这两种基础模块交替堆叠,形成完整的神经网络结构,这种设计允许模型在保持简洁的同时,通过不同模块的组合来适应不同的预测需求。模型的每个块接收来自前一个块的残差序列和当前时间窗口的时间序列数据。通过前向传递,每个块计算前向和后向的缩放系数,这些系数随后用于基础层,以计算前向和后向序列的预测。N-BEATS模型能够通过其独特的结构设计有效地捕捉时间序列数据的非线性和非平稳特征,从而提供准确的预测结果。

1.5 锂电池健康状态预测框架

为了进一步提高电池健康状态预测的精度,本文提出了一种基于N-BEATS和相关向量机的锂电池健康状态的混合预测方法,具体流程如图4所示。首先,通过提取锂离子电池的历史衰退容量来分析容量衰退趋势;然后,采用VMD方法将容量衰退数据分解为高、低频模态分量,并基于N-BEATS和RVM方法分别对高频、低频分量进行模型训练预测;最后,将各个模态分量数据的预测值相加得到重构后的容量衰退预测值,通过计算相关评价指标MAE、RMSE和 R^2 验证了所提模型的有效性。

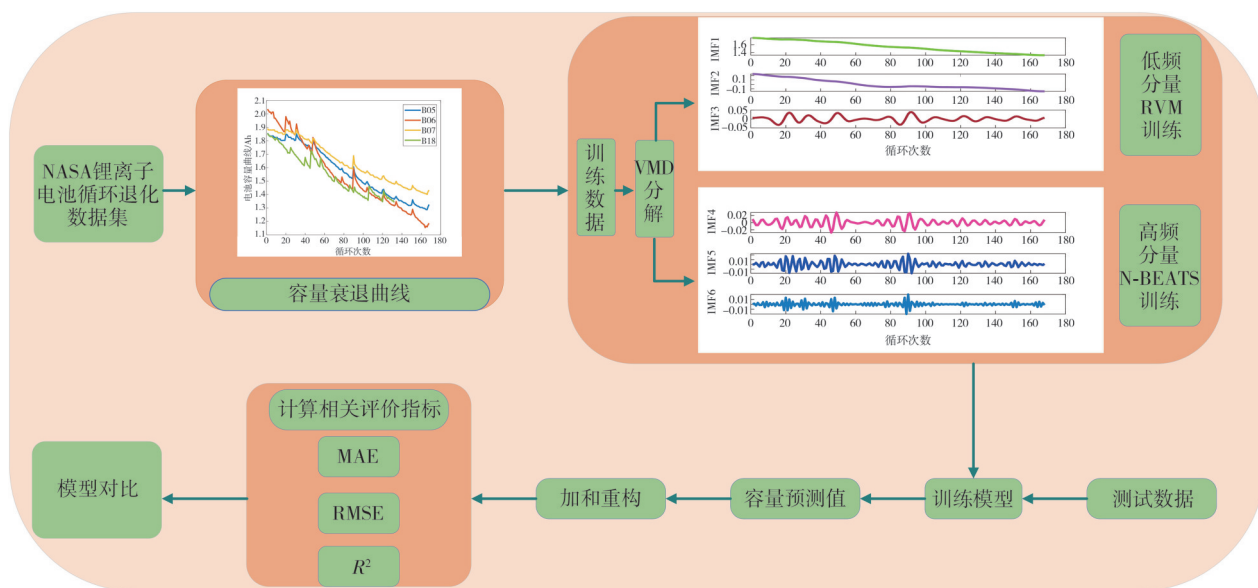


图4 本文预测方法框架图

Fig. 4 The framework of the proposed prediction method

2 实验结果与分析

2.1 基于VMD的健康因子分解

本文应用VMD方法对锂离子电池的历史容量序列进行分解。模态分量(IMFs)的个数 K 对分解结果影响较大, K 值太小,初始信号中的某些重要信息可能会丢失, K 值太大,可能会导致频率混叠,因此选择适当的 K 值至关重要。本文通过考察不同的分解模态数下中心频率的排列来预先确定合适的 K 值。表1展示了不同 K 值下B06电池的中心频率的分布情况,可以看出,当 $K > 6$ 时,各个模态分量的中心频率变化不明显,若继续增大 K 的取值,容易产生额外噪声分量,因此,本文确定分解模态个数 K 的最优值为6。

表1 不同 K 值下B06电池的中心频率

Tab. 1 Center frequency of B06 battery under different K values

K	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7
2	-6.27×10^{-5}	0.082	—	—	—	—	—
3	-5.06×10^{-5}	0.065	0.175	—	—	—	—
4	-4.59×10^{-5}	0.062	0.164	0.303	—	—	—
5	-4.24×10^{-5}	0.058	0.152	0.246	0.407	—	—
6	-2.28×10^{-5}	0.005	0.069	0.163	0.269	0.414	—
7	-2.30×10^{-5}	0.005	0.068	0.149	0.224	0.306	0.43

以B06锂离子电池为例,根据表1和图5所展示的VMD结果,对各个模态分量对应的中心频率及其对应的曲线进行分析。分析结果表明:IMF1的中心频率低,较好地反映了电池容量的退化趋势;IMF2和IMF3分量的中心频率相对较低,主要与电池的不规律容量再生行为相关;其余IMFs中心频率大,主要代表了高频分量。VMD分解方法通过对非线性信号的有效处理,为锂电池健康状态的后续预

测分析提供了基础。




图5 B06锂电池容量的VMD曲线

Fig. 5 VMD curves of B06 Lithium-ion battery

2.2 实验评判标准

本文采用平均绝对误差 E_{MA} (Mean Absolute Error, MAE)、均方根误差 E_{RMS} (Root Mean Square Error, RMSE)和决定系数(R^2)作为预测模型的性能指标。其计算公式分别为

$$E_{MA} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (14)$$

$$E_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2}, \quad (15)$$


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

式中： \hat{y}_i 为模型的预测值； y_i 为实际测量值； \bar{y}_i 为测量的平均值， $i \in [1, n]$ ， n 为实验循环次数。通常情况下， E_{MA} 和 E_{RMS} 值越小，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。与 E_{MA} 和 E_{RMS} 不同的是， R^2 值越接近1，表明模型越能很好地解释数据中的变异，能够帮助判断模型的拟合程度。


2.3 基于VMD和N-BEATS+RVM的模型的预测结果与分析

为了验证该模型在捕捉电池容量变化趋势方面的准确性，本文采用了NASA的4种锂电池的前80个循环周期数据以及CALCE的2种锂电池的前50%的循环周期数据作为训练集，使用基于N-BEATS和RVM的混合预测方法预测锂离子电池的容量退化数据。


图6展示了N-BEATS、RVM以及混合方法对6种锂离子电池进行容量衰退预测的结果。可以看出，与单独使用N-BEATS或RVM模型相比，本文所提出的混合方法的预测曲线更贴近实际测量的电池容量衰退曲线，因此能够较好地描述锂电池容量衰退趋势。




(a) B05(T=80)




(b) B06(T=80)



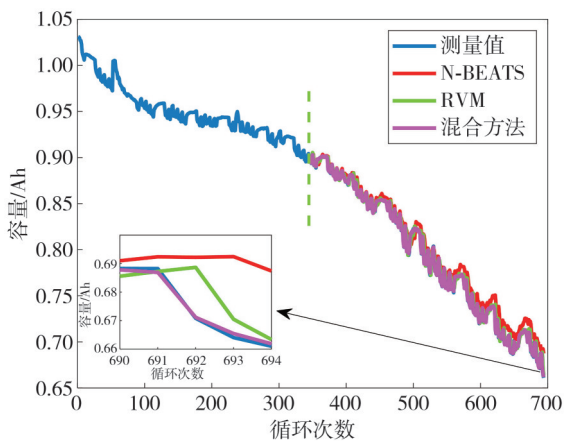
(c) B07(T=80)



(d) B18(T=80)



(e) CS2_35(T=358)



(f) CS2_36(T=347)

图6 6种电池的容量衰退预测结果

Fig. 6 Prediction results of capacity decline for 6 types of batteries

此外,表2给出了不同方法对6种电池预测的性能结果,其中CS2_35锂电池的混合方法的预测性能最为突出, E_{MA} 、 E_{RMS} 和 R^2 分别为0.07%,0.09%和99.98%,具有较好的准确度。尽管B18的预测性能略逊一筹,但其 E_{MA} 和 E_{RMS} 值也低至0.32%和0.40%, R^2 高达98.53%,表现也十分出

色。这些结果表明,本文所提方法不仅具有较好的泛化能力,而且在锂电池的容量衰退预测任务中展现了较高的预测精度。


表2 不同方法对6种电池预测的性能

Tab. 2 The prediction performance of different methods for 6 types of batteries

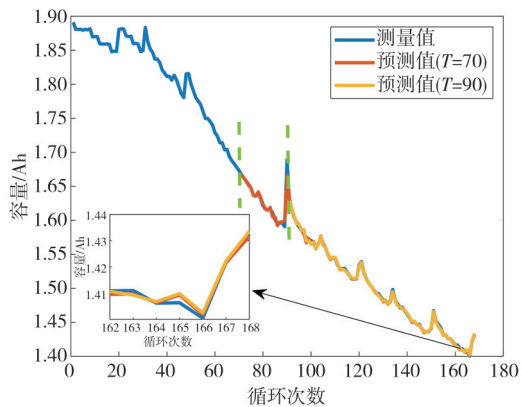
电池型号	预测方法	$E_{MA}/\%$	$E_{RMS}/\%$	$R^2/\%$
B05	N-BEATS	1.25	1.85	95.17
	RVM	1.79	2.30	92.62
	混合方法	0.21	0.31	99.87
B06	N-BEATS	2.87	3.39	88.68
	RVM	0.96	2.08	95.75
	混合方法	0.28	0.42	99.82
B07	N-BEATS	1.06	1.81	92.80
	RVM	1.38	1.91	91.93
	混合方法	0.18	0.32	99.78
B18	N-BEATS	1.96	2.74	31.83
	RVM	1.13	2.11	59.75
	混合方法	0.32	0.40	98.53
CS2_35	RVM	0.36	0.52	99.61
	混合方法	0.07	0.09	99.98
CS2_36	N-BEATS	0.94	1.20	97.01
	RVM	0.44	0.63	99.18
	混合方法	0.07	0.10	99.97

为了进一步验证所提出模型在不同预测起点的预测精度,本研究选取了NASA锂电池的70/90循环周期数据以及CS2_35的286/430和CS2_36的278/416循环周期数据作为训练集。图7展示了以不同循环周期为预测起点时,采用N-BEATS和RVM的混合预测方法的锂离子电池的容量衰退预测曲线。


由图7和表3可以看出,随着训练集规模的减小,预测精度呈现下降趋势。这一现象表明,预测从早期开始,由于模型训练过程中提供的有效信息减少,导致预测结果的误差增加。




(a) B05(T=70/90)




(b) B06(T=70/90)




(c) B07(T=70/90)



(d) B18(T=70/90)



(e) CS2_35(T=286/430)



(f) CS2_36(T=278/416)

图 7 不同循环次数为预测起点的 6 种电池的容量衰退预测结果
Fig. 7 Prediction results of capacity degradation for 6 types of batteries in different charge and discharge cycles

表 3 以不同循环次数为预测起点的混合模型的预测结果
Tab. 3 Prediction results of a hybrid model in different charge and discharge cycles

电池型号	预测起点	$E_{MA}/\%$	$E_{RMS}/\%$	$R^2/\%$
B05	70	0.239 4	0.338 9	99.87
	90	0.165 0	0.220 0	99.91
B06	70	0.430 4	0.538 3	99.75
	90	0.229 8	0.303 2	99.90
B07	70	0.175 4	0.319 7	99.82
	90	0.130 0	0.183 8	99.90
B18	70	0.279 3	0.376 1	99.30
	90	0.340 2	0.418 9	97.99
CS2_35	286	0.067 2	0.089 5	99.98
	430	0.072 0	0.095 7	99.98
CS2_36	278	0.078 0	0.098 8	99.98
	416	0.083 7	0.106 6	99.96

然而, 尽管预测起点的降低对预测精度有一定影响, 但并未引起评价指标出现显著变化, 即使是预测精度最差的电池 B06, 其 70 个循环周期的 E_{MA} 、 E_{RMS} 和 R^2 值分别为 0.430 4%、0.538 3% 和 99.75%, 仍然具有较好的表现。与以 90 个循环周期为预测起点的性能评价指标相比, E_{MA} 和 E_{RMS} 都仅相差大约 0.20 百分点, R^2 也仅相差 0.15 百分点, 表明所提出的预测模型有较高的稳定性, 在少量训练样本的情况下仍然具有较高的预测精度。

2.4 基于 VMD 和 N-BEATS+RVM 的模型与其他模型的比较分析

为了进一步证明所提出的 N-BEATS 和 RVM 的混合预测方法的优越性, 以电池 B06 为例, 在相同的初始条件和训练集下, 将混合预测方法的预测结果分别与 LSTM、GPR、SVR 模型的预测结

果进行比较。

由图8及表4可以看出,本文所提出的混合方法以0.42%的 E_{RMS} 和0.28%的 E_{MA} 显著优于其他模型。同时,相较于LSTM、GPR和SVR预测模型,混合方法的 E_{RMS} 分别降低了96.5%,74.5%和62.5%, E_{MA} 分别降低了97.3%,76.7%和58.8%。综合分析表明,本文所提出的混合方法具有更高的预测精度,其 E_{RMS} 和 E_{MA} 均远低于其他单一算法。该结果证明了在锂离子电池健康状态预测模型中采用多模型混合策略的重要性。

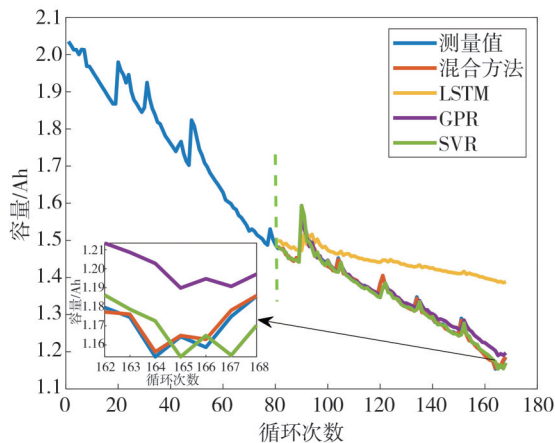


图8 对比实验的容量预测结果

Fig. 8 Capacity prediction results for comparative experiments

表4 不同模型的性能评估

Tab. 4 Performance evaluation for different models

算法	$E_{MA}/\%$	$E_{RMS}/\%$
本文方法	0.28	0.42
LSTM	10.21	12.02
GPR	1.20	1.65
SVR	0.68	1.12

3 结论

本文提出了一种基于N-BEATS和RVM的锂电池健康状态混合预测方法。首先,为了减少非线性对预测结果的不利影响,采用VMD方法将提取的锂离子电池容量衰退数据分解成不同子序列。然后,将这些子序列定义为高频和低频模态分量,并分别使用N-BEAT和RVM模型进行预测。最后,使用NASA和CALCE提供的锂离子电池数据集进行了仿真实验验证,证明所提出的方法具有良好的预测精度和稳定性,预测误差均保持在0.5%以内, R^2 也基本维持在99%以上。此外,与现有的其他预测方法进行对比,验证了所提方法的优越性。然而在实际的锂离子电池健

康状态预测中,有时很难直接测量电池的可用容量,这对本文所提出的方法提出了挑战。因此,后续可以利用易于测量的特征因子来预测电池的健康状态,以提高模型的实用性和适用范围。

参考文献:

- [1] 胡晓亚,郭永芳,张若可. 锂离子电池健康状态估计方法研究综述[J]. 电源学报, 2022, 20(1): 126-133. HU Xiaoya, GUO Yongfang, ZHANG Ruoke. Review of state-of-health estimation methods for lithium-ion battery [J]. Journal of Power Supply, 2022, 20(1): 126-133. (in Chinese)
- [2] 刘大同,宋宇晨,武巍,等. 锂离子电池组健康状态估计综述[J]. 仪器仪表学报, 2020, 41(11): 1-18. LIU Datong, SONG Yuchen, WU Wei, et al. Review of state of health estimation for lithium-ion battery pack [J]. Chinese Journal of Scientific Instrument, 2020, 41(11): 1-18. (in Chinese)
- [3] DING G R, WANG W B, ZHU T. Remaining useful life prediction for lithium-ion batteries based on CS-VMD and GRU[J]. IEEE Access, 2022, 10: 89402-89413.
- [4] WU C L, FU J C, HUANG X R, et al. Lithium-ion battery health state prediction based on VMD and DBO-SVR[J]. Energies, 2023, 16(10): 3993.
- [5] LIU C, WANG Y J, CHEN Z H. Degradation model and cycle life prediction for lithium-ion battery used in hybrid energy storage system[J]. Energy, 2019, 166: 796-806.
- [6] SADABADI K K, JIN X, RIZZONI G. Prediction of remaining useful life for a composite electrode lithium-ion battery cell using an electrochemical model to estimate the state of health[J]. Journal of Power Sources, 2021, 481: 228861.
- [7] WASSILIADIS N, ANK M, BACH A, et al. A systematic approach for the parameter identification of electrochemical battery models enabling health-aware fast charging control of battery electric vehicles [J]. Journal of Energy Storage, 2022, 56: 105951.
- [8] XIONG R, ZHANG Y Z, WANG J, et al. Lithium-ion battery health prognosis based on a real battery management system used in electric vehicles [J]. IEEE Transactions on Vehicular Technology, 2019, 68(5): 4110-4121.
- [9] 杨彦茹,温杰,史元浩,等. 基于CEEMDAN和SVR的锂离子电池剩余使用寿命预测[J]. 电子测量与仪器学报, 2020, 34(12): 197-205.

- YANG Yanru, WEN Jie, SHI Yuanhao, et al. Remaining useful life prediction for lithium-ion battery based on CEEMDAN and SVR[J]. *Journal of Electronic Measurement and Instrumentation*, 2020, 34(12): 197-205. (in Chinese)
- [10] WANG D, MIAO Q, PECHT M. Prognostics of lithium-ion batteries based on relevance vectors and a conditional three-parameter capacity degradation model [J]. *Journal of Power Sources*, 2013, 239(1): 253-264.
- [11] HEINRICH F, PRUCKNER M. Virtual experiments for battery state of health estimation based on neural networks and in-vehicle data [J]. *Journal of Energy Storage*, 2022, 48: 103856.
- [12] 金建新, 虞儒新, 刘刚, 等. 锂离子电池健康状态估算方法研究进展[J]. *电气工程学报*, 2024, 19(1): 33-48.
- JIN Jianxin, YU Ruxin, LIU Gang, et al. Research progress on state-of-health estimating method for lithium-ion batteries[J]. *Journal of Electrical Engineering*, 2024, 19(1): 33-48. (in Chinese)
- [13] LIU M X, MO C M, WANG H L. Short-term power load forecasting model based on CNN-GRU and dual attention mechanism hybrid neural network model [C]//2023 8th Asia Conference on Power and Electrical Engineering (ACPEE), 2023: 1769-1773.
- [14] 王英楷, 张红, 王星辉. 基于1DCNN-LSTM的锂离子电池 SOH 预测[J]. *储能科学与技术*, 2022, 11(1): 240-245.
- WANG Yingkai, ZHANG Hong, WANG Xinghui. Hybrid 1DCNN-LSTM model for predicting lithium-ion battery state of health[J]. *Energy Storage Science and Technology*, 2022, 11(1): 240-245. (in Chinese)
- [15] ZRAIBI B, OKAR C, CHAOUI H, et al. Remaining useful life assessment for lithium-ion batteries using CNN-LSTM-DNN hybrid method [J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(5): 4252-4261.
- [16] SAHA B, GOEBEL K. Battery data set [DB/OL]. (2024-01-04) [2024-05-16]. <https://www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository/>
- [17] Universtiy of Maryland. Battery data [EB/OL]. [2024-05-16]. <https://calce.umd.edu/battery-data>.
- [18] 唐贵基, 王晓龙. 变分模态分解方法及其在滚动轴承早期故障诊断中的应用[J]. *振动工程学报*, 2016, 29(4): 638-648.
- TANG Guiji, WANG Xiaolong. Variational mode decomposition method and its application on incipient fault diagnosis of rolling bearing [J]. *Journal of Vibration Engineering*, 2016, 29(4): 638-648. (in Chinese)
- [19] 范兴明, 王超, 张鑫, 等. 基于增量学习相关向量机的锂离子电池 SOC 预测方法 [J]. *电工技术学报*, 2019, 34(13): 2700-2708.
- FAN Xingming, WANG Chao, ZHANG Xin, et al. A prediction method of Li-ion batteries SOC based on incremental learning relevance vector machine [J]. *Transactions of China Electrotechnical Society*, 2019, 34(13): 2700-2708. (in Chinese)
- [20] ORESHKIN B N, CARPOV D, CHAPADOS N, et al. N-BEATS: Neural basis expansion analysis for interpretable time series forecasting [DB/OL]. (2020-02-20) [2024-05-16]. <https://arxiv.org/abs/1905.10437v4>.