

DOI:10.19651/j.cnki.emt.2415967

基于混合尺度健康因子的 LSTM-Transformer 锂电池寿命预测^{*}

赵昱坡¹ 黄伟¹ 张剑飞²

(1. 上海电力大学自动化工程学院 上海 200090; 2. 华能玉环电厂 台州 317699)

摘要: 为提高锂电池剩余使用寿命(RUL)预测的精度,提出基于混合尺度健康因子的集成模型进行 RUL 预测。针对电池退化数据噪声大,数据量少和非线性特点捕捉不全的问题,首先提出奇异值分解(SVD)对电容信号处理,通过奇异值的能量分布优化变分模态分解(VMD)的最佳模态数,降噪重构出直接健康因子 SR。提出一种幅度、相位双扰动(APP)的数据增强方法,依据 SR 数据分布变化,生成人工标记数据 ESR,此 ESR 与电容相关系数均高于 0.97。将 SR、ESR 结合 GRA 算法择取的 3 个间接健康因子,建立了更全面的混合尺度寿命特征信息;此外,为了避免单一模型预测的局限性,采用 LSTM 模型改进了 Transformer 结构中的解码器,引入新兴 Optuna 框架分析了影响模型预测精度的关键超参数并对它们进行了优化。最后通过 NASA 数据进行实验,并与 RNN、LSTM、Transformer 以及现有模型方法进行比较,结果证明 RMSE 控制在 2.39% 以内,MAE 在 1.59% 以内,且预测性能受预测起点的影响小,稳定性更高,95% 置信区间更窄。

关键词: 锂离子电池;混合尺度特征提取;LSTM-Transformer 模型;APP 数据增强;Optuna 框架

中图分类号: TM912;TN911 **文献标识码:** A **国家标准学科分类代码:** 520

Lithium-ion battery life prediction based on hybrid scale health factors with LSTM-Transformer model

Zhao Yupo¹ Huang Wei¹ Zhang Jianfei²

(1. School of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. Huaneng Yuhuan Power Plant, Taizhou 317699, China)

Abstract: To enhance lithium-ion battery remaining useful life (RUL) prediction accuracy, we propose an integrated model using hybrid scale health factors. We address challenges of noisy data, limited quantity, and incomplete capture of nonlinear characteristics. Firstly, we use singular value decomposition (SVD) to process capacitance signals, optimizing variational mode decomposition (VMD) for denoising and reconstructing the direct health factor, SR. We introduce an amplitude-phase perturbation (APP) data augmentation method to generate artificially labeled data, ESR, based on changes in SR data distribution. Combined with three indirect health factors, selected using GRA algorithm, we establish a comprehensive mixed-scale life characteristic information. Additionally, we improve Transformer model's decoder structure with LSTM and optimize key hyperparameters using Optuna framework. Experimental results on NASA data show RMSE within 2.39% and MAE within 1.59%, with improved stability and narrower 95% confidence intervals compared to RNN, LSTM, Transformer, and existing models.

Keywords: lithium-ion battery; hybrid scale feature extraction; LSTM-Transformer model; APP data augmentation; Optuna framework

0 引言

双碳政策的推进,国家大力发展新能源的背景之下,新

型储能市场需求快速释放,对于锂电企业来说,储能电池业务正是规模迅速扩张的关键期^[1],而锂离子电池相比较传统的电池有着一系列的优点,比如底能耗,高容量,能量高,

收稿日期:2024-05-01

^{*} 基金项目:国家电网公司华东分部科技项目(H2021-111)资助

工作电压高,循环寿命长等,已经大量运用于医疗、交通运输,国防军事等领域,所以准确预测锂电池的剩余使用寿命(remaining useful life, RUL)的研究是至关重要的。

常用的锂电池 RUL 预测方法可分为机理建模法和数据驱动方法,二者相比,后者不需要考虑电池内部复杂的电化学反应,直接通过电池容量衰减数据来搭建电池衰退模型进行 RUL 预测。神经网络^[2]、支持向量机^[3]、深度神经网络模型^[4]、自回归积分滑动平均模型^[5]、高斯过程回归模型^[6]等单一的模型,会由于长期依赖问题而降低电池 RUL 预测的精度。叶鑫等^[7]利用变分模态分解(variational mode decomposition, VMD)对电池容量进行分解,再结合优化后的长短期记忆神经网络(long short-term memory network, LSTM)模型进行预测,该方法在 VMD 分解过程中,模态分量个数的选择上,存在分析效率低、数据分析可靠性不足等问题。尹杰等^[8]采用结合变分自编码器和生成对抗网络模型生成多组数据进行数据扩充,来解决电池退化数据稀少的问题,再结合降噪自编码器(denoising autoencoder, DAE)和 LSTM 模型进行预测。但是该方法结合了两个复杂的生成模型,平衡二者所需要的计算量较大,且生成的样本数据与原数据的相似度有低于 0.95。刘琼等^[9]以平均电压、电流和温度为特征预测电池 RUL,但特征提取尺度仅考虑了电容退化的间接影响因素。上述问题可概括为以下 3 点:

1) 预测模型的局限性:大多电池 RUL 预测方法将局部的容量退化数据作为特征输入供模型训练,导致模型无法学习到电池退化全过程的特点,此类方法的建模数据具有一定局限性,其次是模型单一的局限性,难以捕捉特征输入中复杂的非线性关系。

2) 特征提取尺度的单一性:现有特征提取工作大多局限于对电池容量这一直接因素进行各种的信号分解工作;或是局限于从反映电池性能退化的间接因素即电压、电流等方面提取时间尺度上的特征。两种方法都忽略了锂电池的健康程度是由直接和间接健康因子所共同反应的现实问题,导致模型难以全面捕捉电容的变化特征。

3) 电池数据稀缺性:数据驱动是需要充足的数据作为支撑,而现有的单一型号电池数据十分有限,对电池 RUL 预测模型的训练有一定的影响。

为解决上述问题,本文提出一种基于 SVD-VMD-APP 混合特征提取的 LSTM-Transformer 锂电池寿命预测方法研究(简称为 SVAL-Transformer)。该方法的优势如下:

1) 弥补单一模型的局限性。王冉等^[10]采用集成深度模型对电池 RUL 预测,本文是对近年来关注度高的 Transformer 模型进行改进,运用 LSTM 模型替换其解码器,最终实验证明集成模型的预测精度更高。

2) 特征提取更为全面。考虑到电池退化程度是由直接和间接因素所共同反映的,提出联合奇异值分解(singular value decomposition, SVD)、VMD 和幅度、相位双扰动

(amplitude and phase perturbations, APP)的方法对电容信息进行解析、重构与增强处理,从中提取直接健康因子,再与择取的间接健康因子组成混合尺度的健康因子,全面反映了电池退化情况。

3) 考虑到美国航空航天局(national aeronautics and space administration, NASA)数据库中单一型号电池数据较少,本文采用迁移学习的思想,运用标准化欧式距离(standardized euclidean distance, SED)测量方法寻找相似电池,使模型学习到电池退化的全过程特点,并结合待预测电池的部分数据进行迁移学习,提高模型的预测精度。

4) 通过 Optuna 对集成网络模型结构内的超参数进行寻优,该新兴框架采用了修剪器和采样器,可以快速的找到特定时间内的最佳超参数值,提升模型的预测能力。

综上,本文对不同类型的电池,在不同的预测起点下进行 RUL 预测实验:先采用 SED 算法扩充模型训练的数据集,再根据 SVD-VMD-APP 方法提取出直接健康因子,结合灰色关联度分析(grey relation analysis, GRA)算法所择取的间接健康因子,组成了更为全面的特征输入,使得 Optuna-LSTM-Transformer 集成模型能够充分挖掘退化数据的特点。此外,本文增设了不同模型方法的对比实验,验证了本方法在电池 RUL 预测上的有效性。

1 相关理论基础

1.1 基于 SED 的迁移性测量

本文采用的是 SED 方式,评估不同电池容量之间的相似度,与陈锐等^[11]提出的平均欧几里得距离(average euclidean distance, AED)的不同之处是,SED 方法可以评估电容数据长度不一样的电池。若 B07、B05 型号电池的容量退化序列分别为 $X=[x_1, x_2 \cdots x_n]$ 、 $Y=[y_1, y_2 \cdots y_n]$,由于数据特征尺度不同会导致距离计算不准确,所以在欧几里得距离的特征尺度方面进行改进,改进后的公式为:

$$\text{dis}(x, y) = \sqrt{\sum_{i=1}^n \left(\frac{x_i - \mu_i}{\sigma_i} - \frac{y_i - \mu_i}{\sigma_i} \right)^2} \quad (1)$$

其中, μ_i 是维度 i 的均值, σ_i 是 i 维度的标准差。通过取标准差的倒数提供一个更加平等的权重,使得距离计算更加准确可靠。

1.2 基于 APP 数据增强

本文引入 APP 数据增强方法,充分利用输入序列的变化特性添加扰动,生成更多符合该输入序列的人工标记数据,以此来提高模型对于真实世界中复杂条件的适应能力。

对于输入的特征序列 $X_1 \cdots X_n$,进行离散傅里叶变换得到其频谱 $F(\omega_k)$,计算公式为:

$$F(\omega_k) = \frac{1}{N} \sum_{t=0}^{N-1} x_t e^{-j\omega_k t} = \text{Re}[F(\omega_k)] + j \text{Im}[F(\omega_k)] \quad (2)$$

其中, $\text{Re}[F(\omega_k)]$ 和 $\text{Im}[F(\omega_k)]$ 是表示输入序列频谱的实部和虚部, $\omega_k = \frac{2\pi k}{N}$ 为角频率。

因为 $F(\omega_k)$ 是复数,故可用振幅和相位来表示为:

$$F(\omega_k) = A(\omega_k)e^{[j\theta(\omega_k)]} \quad (3)$$

$A(\omega_k)$ 是振幅,代表 $F(\omega_k)$ 的大小; $\theta(\omega_k)$ 是相位,代表 $F(\omega_k)$ 的角度。

为了在频域的特定片段中进行幅度和相位的扰动,可通过比率系数 r 来定义所选片段的长度 L ,如式(4)所示:

$$L = rN \quad (4)$$

其中, N 是特征输入的频谱长度; L 是在频域中选择用于添加扰动的片段长度,其长度大小由比率系数 r 来决定。

定义截取片段的数目和截取区间为:

$$[k_i, k_i + L], k_i \sim U(0, N - L), i = 1, 2, \dots, m_k \quad (5)$$

m_k 表示在频域中选择了 m_k 个需要添加扰动的片段,每个片段的区间可以表示为 $[k_i, k_i + L)$ 。其中, k_i 是从均匀分布 $U(0, N - L)$ 中随机选取的,规定相邻扰动区间重叠部分不超过长度 L 的一半,如式(6)所示。

$$|k_i - k_{i+1}| \geq \frac{L}{2}, i = 1, 2, \dots, m_{k-1} \quad (6)$$

进行输入信号增强处理时,首先将所选幅度片段中的数值替换成 x , x 服从高斯分布 $x \sim N(\mu_A, q_A \delta_A^2)$, μ_A, δ_A^2 为所选幅度片段内所有点的均值和方差; q_A 是控制扰动程度的参数。接着是从相位的角度进行扰动处理,将所选相位片段中所有点的值增加一个扰动 θ ,该扰动服从高斯分布即 $\theta \sim N(0, \delta_\theta^2)$, δ_θ^2 为所选相位片段中所有点的方差;最后通过傅里叶逆变换返回到时域状态。

1.3 变分模态分解

VMD 的分解过程本质上是解决一个变分问题,其约束变分模型如式(7)、(8)所示。 $\delta(t)$ 是每个分量的中心频率, u_k 是信号分解后的分量, k 为模态分解的个数。 ∂_t 是梯度运算。 $*$ 表示卷积运算。通过引入拉格朗日乘子项和二次惩罚,得到增广拉格朗日表达式(9),进而可求得 $u_k^{\wedge_{n+1}}(\omega)$ 、 ω_k^{n+1} 和 $\lambda_k^{n+1}(\omega)$ 。

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (7)$$

$$s.t. \sum_k u_k(t) = f(t) \quad (8)$$

$$L = a \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \quad (9)$$

1.4 LSTM-Transformer 模型

Transformer 模型是近年来受到广泛关注的模型,它是由编码器和解码器组成,采用了一种自注意力机制的序列建模模型,每个部分都是由多个编码层或者解码层组成^[12]。编码器将输入的序列转换为一个固定长度的向量,解码器则使用该向量生成输出序列。编码器和解码器通常

采用循环神经网络(recurrent neural network, RNN)或者其变体,比如运用较多的 LSTM 模型。

目前 Transformer 模型可应用于负荷预测^[13]中,为了更好的挖掘电池容量中变化的规律,对 Transformer 模型进行改进,用全连接层和 LSTM 模块作为模型的解码器,搭建如图 1 的 LSTM-Transformer 模型,其工作流程如下。

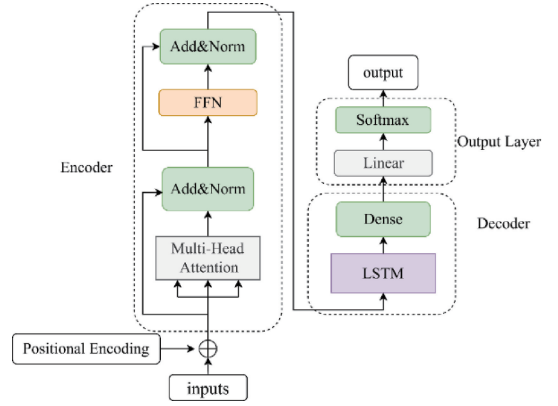


图 1 LSTM-Transformer 模型结构图

Fig. 1 LSTM-Transformer model architecture diagram

1) 将输入的时序数据 X_m 分解成不同的时间序列片段 X'_m 送入到编码器 encoder 的多头注意力机制中得到局部的特征表示 Q_m , 其表达式为:

$$Q_m = \text{MultiHeadAttention}(X'_m) \quad (10)$$

2) 根据上式计算出不同时序序列的特征权重 C_m , 并以此计算出每个时序片段之间的自注意力权重 $S^{(m)}$, 如式(11)、(12)所示, 式中 W_q, W_k, W_v 为可训练的权重矩阵。

$$C_m = \text{Softmax}(\text{ReLU}((W_q Q_m)^T W_k Q_m)) \quad (11)$$

$$S^{(m)} = \sum_{m=1}^n C_m W_v Q_m \quad (12)$$

3) 输入的时序片段经 Transformer 模型中的编码器处理后, 输出特征向量, 对其进行拼接, 组成了不同尺度的特征向量表示为 W 。

4) 将输出的 W 送入 LSTM 模块中, 进一步特征抽取, 如式(13)所示, Y'_m 是在 t 时刻的输出隐藏状态; U_m 是 LSTM 模块中训练学习的参数矩阵; E_m 是 LSTM 模型结构中的超参数。

$$Y'_m = \text{LSTM}(W, U_m, Y_m^{t-1}, E_m) \quad (13)$$

5) 最终将解码器所输出的特征矩阵送入输出层, 进行降维激活处理, 得到预测结果。

2 基于 SVD-VMD-APP 数据处理的 Optuna-LSTM-Transformer 预测方法

2.1 锂离子电池 RUL 预测数据集选择

本文所用数据集为 NASA 数据库中 B05、B06、B07、B18 型号电池的退化数据, 运用式(1) SED 方法, 测量待预测电池与其余电池的容量退化曲线之间的距离, 评估相似

度,实验数据如表 1 所示。最终去除距离最远的电池型号,剩余的电池数据作为模型的训练集。

表 1 待测电池与其余电池容量曲线之间距离
Table 1 Distance between the capacity curves of the test battery and other batteries

待预测电池	电池型号	距离
B05	B06	2.571 8
	B07	0.830 1
	B18	3.659 6
B06	B05	2.571 8
	B07	1.928 9
	B18	2.668 6
B07	B05	0.830 1
	B06	1.928 9
	B18	3.210 9
B18	B05	3.659 6
	B06	2.668 6
	B07	3.210 9

2.2 多尺度健康因子提取

1) 电池直接健康因子的特征提取

首先考虑的是电池容量,它是表征电池健康程度的直接因素。通过 VMD 对电池容量序列进行分解,而选取合适的模态分量个数 K 是至关重要的, K 值过小会过滤掉序列中重要的信息, K 值过大会导致模态重叠。

本文采用 SVD 分解时间序列数据得到 Hankel 矩阵来确定数据的主要成分,再依据奇异值的能量百分比来确定时间序列的最佳模态数。

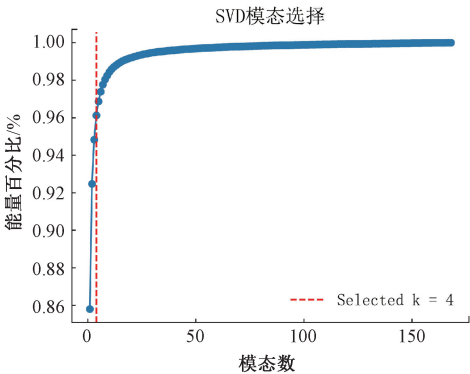
以 B05 电池为例,首先超过 95% 能量百分比时, K 为 4,如图 2(a)所示。模态数确定后,采用 VMD 算法对 B05 的电池容量进行分解,其结果如图 2(b)所示。

表 2 为每个模态分量的中心频率和与容量的相关系数,根据中心频率和相关系数高低的判别方法,得知 IMF1 反映容量的退化趋势,IMF2 与 IMF3 反映容量的再生情况,IMF4 为噪声分量。将 IMF1、IMF2 和 IMF3 进行拼接重构,得到一个新的分量 SR5,它只保留反映电池容量总体退化趋势和容量再生的特点,可用它来提升特征数据的质量。


表 2 B05 各模态分量的中心频率和相关系数

Table 2 Central frequencies and correlation coefficients of each modal component for B05

模态分量	IMF1	IMF2	IMF3	IMF4
中心频率	2.15×10^{-5}	0.068 2	0.174 5	0.359 2
Pearson	0.997 8	0.106 2	0.052 3	0.033 1
Spearman	0.993 3	0.141 1	0.048 4	-0.000 4



(a) B05最佳模态选择
(a) Best mode selection for B05



(b) B05电池容量分解曲线
(b) B05 battery capacity decomposition curve

图 2 VMD 分解过程

Fig. 2 VMD decomposition process

按照上述 SVD-VMD 算法对各型号电池电容进行分解重构,得到直接健康因子 SR5、SR6、SR7、SR18,并对它们与各自的电容信号进行相关系数分析,如表 3 所示。可看出所有分量的相关系数都超过了 0.99,表明重构后的分量保留了原始电容信号的重要特征。

表 3 直接健康因子的相关系数

Table 3 Correlation coefficients of direct health indicators

电池型号	Pearson	Spearman
SR5	0.999 6	0.999 2
SR6	0.998 7	0.998 4
SR7	0.997 5	0.998 7
SR18	0.998 5	0.996 8

由于直接健康因子较间接健康因子相比,数据量偏少,需要进行数据扩充处理,所以根据式(2)~(6),采用 APP 数据增强方法,对重构所得到的各 SR 分量进行数据增强。为了添加适合原数据的噪声,依据各 SR 分量的幅度和相位的分布变化情况,在选取的随机片段中添加符合该片段数据分布的扰动点。

以 B05 型号电池为例,SR5 信号处理的过程如图 3、图 4 所示,图 3 为频谱的正频率部分,将添加扰动后的幅度和相位进行还原得到了数据增强后的分量 ESR5,如图 4 所示,从前后信号对比图可看出与原信号较为相似。

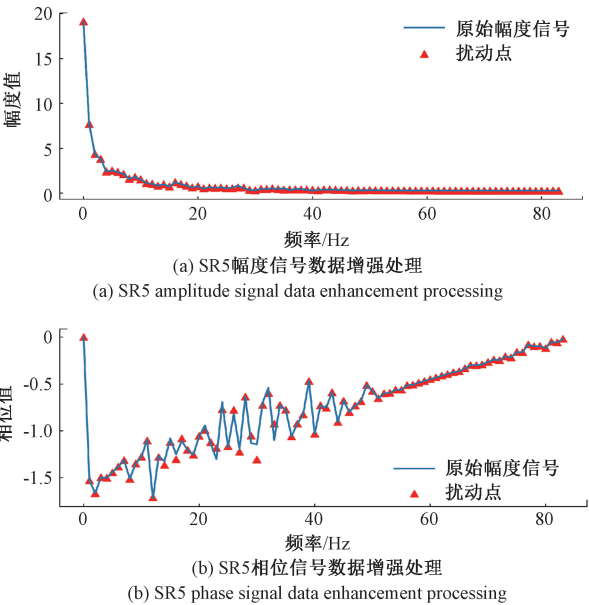


图 3 SR5 分量幅度相位双增强后的结果

Fig. 3 Results after dual enhancement of amplitude and phase for SR5 component

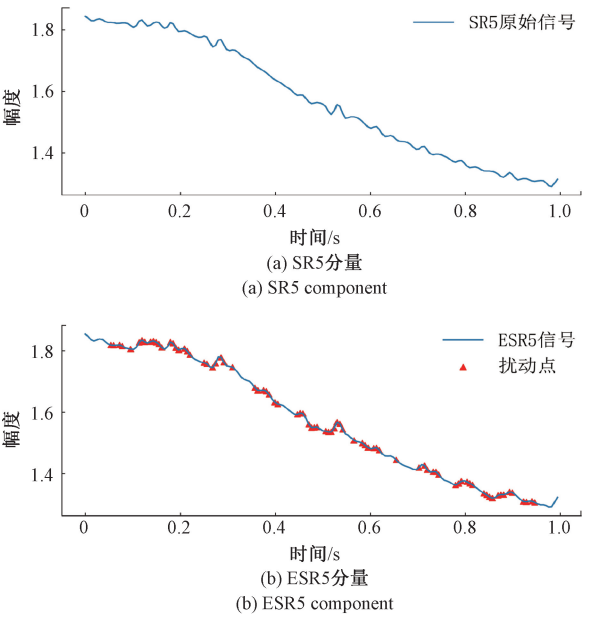


图 4 SR5 分量增强前后对比

Fig. 4 Comparison of SR5 component before and after enhancement

按照同样的方法对其余 3 个 SR 分量进行处理,依次得到 ESR6、ESR7 和 ESR18,并对它们进行容量相关系数的分析如表 4 所示,可看出数据增强后的分量虽然相关系数略有降低,但其值仍高于 0.97,证明该方法充分利用了

数据分布的特点来添加合适的扰动噪声,生成了更多的人工标记数据。增强后的 ESR 分量与原有的 SR 分量共同作为直接健康因子供模型训练,有助于提高最终模型的鲁棒性,提高模型的预测精度。

表 4 数据增强处理后的各 ESR 分量与各电池电容的相关系数

Table 4 Correlation coefficients between enhanced ESR components and battery capacities

电池型号	Pearson	Spearman
ESR5	0.976 2	0.987 8
ESR6	0.995 9	0.995 4
ESR7	0.993 2	0.994 5
ESR18	0.979 2	0.982 4

2) 电池间接健康因子的特征提取

其次考虑的是表征电池健康程度的间接因素,由于参考的权威文献^[14]并未对 B07 型号电池进行间接健康因子提取,所以参照对应的方法对 B07 电池进行操作,并经 GRA 分析得到表 5。

表 5 GRA 方法的相关系数

Table 5 Correlation coefficients using the GRA method

序号	特征	B0005	B0006	B0018	B0007
1	充电电压与时间关系	0.679 5	0.722 9	0.592 5	0.971 6
2	充电电流与时间关系	0.721 2	0.948 6	0.622 6	0.787 3
3	充电电池温度与时间关系	0.627 0	0.629 2	0.624 4	0.813 3
4	充电器电流与时间关系	0.967 7	0.928 6	0.621 8	0.769 1
5	充电器电压与时间关系	0.721 8	0.797 0	0.623 4	0.974 8
6	放电电压与时间关系	0.992 8	0.990 8	0.987 7	0.993 6
7	放电电流与时间关系	0.986 5	0.993 0	0.987 4	0.982 1
8	放电电池温度与时间关系	0.988 6	0.992 0	0.980 3	0.997 2
9	放电负载电流与时间关系	0.671 3	0.675 8	0.546 4	0.731 4
10	放电负载电压与时间关系	0.992 8	0.990 8	0.987 7	0.988 5

通过 GRA 方法对 10 个间接健康因子进行降维,由表 5 可知,不同型号的电池中,第 6、8、10 这 3 个不同尺度的间接健康因子,其 GRA 系数都较高,所以本文选取这

3 个间接健康因子作为间接因素的特征输入,由此减少了计算量。

上述就是特征提取的所有工作,最终提取到了混合尺度健康因子的特征数据,该数据由两个直接健康因子和三个间接健康因子混合组成,充分考虑了电池的健康程度是由直接和间接两种因素所共同反应的现实问题,更加贴切电池退化的实际情况。

2.3 模型超参数设置

LSTM-Transformer 模型内部结构的关键超参数包括

解码器优化器学习率 lr2、编码器优化器学习率 lr1、丢失概率参数 dropout、编码器层数 numlayers 和模型隐藏层参数 hidden_size 进行寻优,本文采用新兴的优化工具 Optuna^[15] 和贝叶斯优化方法对上述超参数进行寻优。

以预测 B05 电池实验为示例,利用 Optuna 框架寻优试验 20 次后得到 hidden_size、lr2、num_layers、lr1 和 num_layers 对模型的影响程度占比分别为 42%、27%、20%、5% 和 6%。图 5 所示为 5 个超参数分别对模型的损失影响程度。




图 5 超参数对损失值的影响

Fig. 5 The impact of hyperparameters on loss values

由图观察可得,lr2 和 num_layers 的值取得越小损失值越低,而 hidden_size 对模型影响最大,值越小模型的损失值越低,当其接近 5 的时候,模型损失降到最低。lr1 和 dropout 对损失影响较低。最终经过优化确定超参数 dropout 为 0.3,hidden_size 为 5,num_layer 为 1,lr1 为 0.028,lr2 为 0.001 08。

2.4 预测流程

本文提出的电池 RUL 预测方法的流程如图 6 所示,具体步骤如下:1) 准备阶段:在 NASA 数据库中,利用 SED 方法评估待预测电池与其他型号电池的容量数据之间的相似度,去除电池库中相似度最低的电池型号,剩下的电池数据作为训练集。2) 特征提取阶段:将电池的相关数据按照直接与间接尺度进行健康因子的提取。3) 训练阶段:将数据集归一化处理后,按照一定的比例分配训练集和测试集,送入 LSTM-Transformer 模型训练,同时通过 Optuna 框架进行超参数寻优,获取最终模型。4) 预测阶段:将测试集送入最终模型,得到测试集的电容预测值。5) 评价阶段:将预测的 RUL 值与真实值进行指标评估。

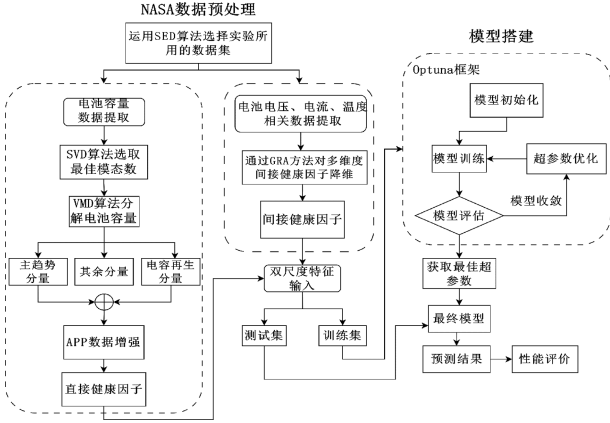



图 6 锂离子电池 RUL 预测流程


Fig. 6 Workflow for predicting the RUL of lithium-ion batteries

3 实验结果分析


为了验证本文所提方法的稳定性与可靠性,对 B05、B06、B07、B18 电池从 60 起点开始的不同情况进行预测,如图 7 所示。




(a) B05 S=60




(b) B05 S=70




(c) B05 S=80




(d) B05 S=90




(e) B05 S=100




(f) B06 S=60




(g) B06 S=70




(h) B06 S=80




(i) B06 S=90




(j) B06 S=100




(k) B07 S=60




(l) B07 S=70



(m) B07 S=80



(n) B07 S=90



(o) B07 S=100




图 7 各类型电池不同预测起点的预测情况

Fig. 7 Prediction performance for various battery types at different prediction starting points

图中蓝色曲线表示电池容量退化的真实值,红色曲线表示电池容量的预测值,淡蓝色区域表示模型预测值 95% 的置信区间,水平绿线代表各电池归一化处理后的失效阈值。横轴为循环充放次数,纵轴为电池容量归一化后的结果。观察图像可得以下几种结论:

1)图 7 中模型对电池容量的退化趋势有较好的跟踪作用,证明了本方法受预测起点的影响小,稳定性与可靠性较高。

由图 7 中置信区间的覆盖情况可知,所有型号的电池在不同预测起点的情况下,无论是全局的退化趋势、局部的容量再生情况和终止阈值所在的大部分循环周期以内,模型预测值的 95% 置信区间基本覆盖了容量的真实值。

2)各电池预测结果的精度指标如图 8 所示,其中红色柱状图是模型预测结果的均方根误差,蓝色柱状图是平均绝对误差。由图可见:随着预测起点的递增,预测的误差指标递减,预测精度越高。







图 8 不同预测起点下 RUL 预测结果评估指标

Fig. 8 Evaluation metrics for RUL prediction results at different prediction starting points

B05、B07 号电池 RMSE、MAE 双指标均在 1.2% 以下;B06 号电池的 MAE 指标都低于 1.6%,起点 90、100 的 RMSE 指标低于 1.5%,而 60、70、80 情况下的 RMSE 均超

过 2%,这是因为 B06 电池的测试集中出现的大幅度容量回升情况,让模型适应度下降导致预测略有偏差,但 95% 的置信区间还是基本覆盖真实值,且 RMSE 仅是略有提

高,证明此模型较为稳定。

B18 电池因为在终止阈值后的循环周期中,对容量大幅度回升的预测略有偏差,其 RMSE 略高于 2%,但 MAE 指标均低于 1.34%,且终止阈值后的预测结果无需讨论。

3)为了验证本文提出的 SVAL-Transformer 集成模型在电池 RUL 预测上的优越性,将其预测结果与几种典型的单一模型进行对比说明,如图 9 所示。由预测曲线可知,本文所提方法具有更好的预测跟踪能力,证明了集成模型的优越性,克服了单一模型的局限性。

为进一步验证 SVAL-Transformer 方法的性能,将其与 DAE-LSTM、ICA-GPR^[16]、AUKF-GASVR^[17] 三种集成方法进行预测精度比较,对比结果如表 6 所示,可看出 SVAL-Transformer 方法在起点 60 下的预测精度较高。

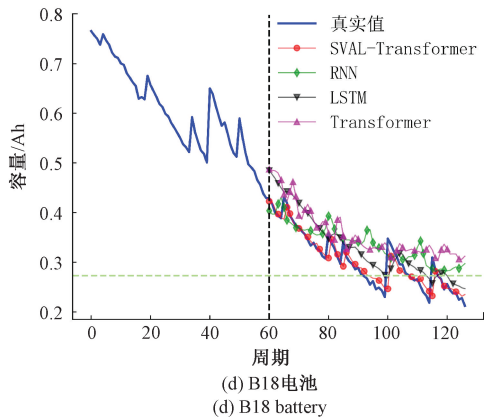


图 9 不同预测方法的预测结果对比

Fig. 9 Comparison of prediction results using different prediction methods

表 6 现有模型预测指标对比



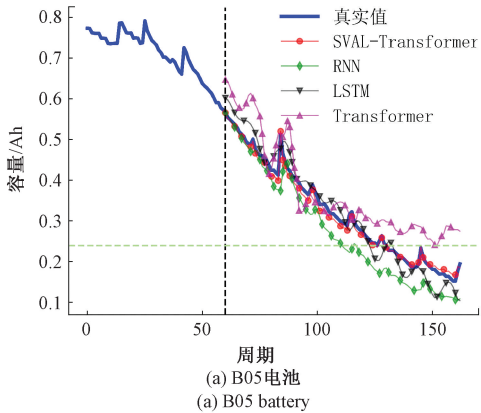
Table 6 Comparison of prediction metrics among existing models

类型	方法	RMSE	MAE
B05	DAE-LSTM	0.028	2
	ICA-GPR	0.039	10
	AUKF-GASVR	0.023	0
	SVAL-Transformer	0.010	0
B06	DAE-LSTM	0.031	3
	ICA-GPR	0.036	10
	AUKF-GASVR	0.051	10
	SVAL-Transformer	0.023	1
B07	DAE-LSTM	0.020	2
	ICA-GPR	—	—
	AUKF-GASVR	0.013	3
	SVAL-Transformer	0.011	0
B18	DAE-LSTM	0.038	3
	ICA-GPR	0.021	4
	AUKF-GASVR	0.023	4
	SVAL-Transformer	0.020	1

4 结 论

针对锂电池剩余寿命预测中特征输入的尺度单一、数据量不足、单一模型预测精度低等问题,本文从特征数据处理、预测模型构建以及超参数优化 3 个方面展开研究。

1)特征数据处理:提出一种基于 SVD-VMD-APP 方法对电池容量信号进行直接健康因子的提取,通过 SVD 算法确定最佳模态数以此来优化 VMD 算法的分解,这样就同时考虑了信号的全局和局部特性,结果证明分解重构后的分量聚焦了数据最关键的动态特征。采用 APP 算法对重构后的分量进行数据扩充,使新生成的人工标记数据



与容量值的相关度均高于 0.97,证明了处理后的数据质量较高,增加了直接健康因子数据的多样性;结合 GRA 算法所择取的间接健康因子,最终组成了双尺度寿命信息数据供模型训练。

2)预测模型构建:对 Transformer 模型中的解码器进行改进,形成 LSTM-Transformer 预测模型,将此模型与上述 SVD-VMD-APP 方法结合,形成本文提出的 SVAL-Transforemr 预测方法,并通过多项实验证明,该方法能对不同类型的电池在不同的预测起点下,将 RMSE 控制在 2.39%以内,MAE 在 1.59%以内,证明了该方法具有较高的稳定性和可靠性;且不同电池在起点 60 的预测情况下均优于常见的单一预测模型,证明了该集成模型的优越性。通过与现有文献中的预测方法进行横向对比,结果证明在相同的预测起点下,本方法能提供精度较高的预测效果。此外,本文所提模型的结构。

3)超参数寻优:通过 Optuna 框架实现了模型超参数的寻优,并分析出 LSTM-Transformer 模型结构中各个超参数对模型精度的影响占比情况。

综上所述,本文提出的 SVAL-Transforemr 锂电池寿命预测的方法具有理想的准确性、稳定性和可靠性。

实验所用的数据集是在稳定状态下监测的锂电池数据,而锂电池在不同应用场景下的负荷波动较大,会影响预测的结果,后期还需进一步结合不同工况下的锂电池数据进行电池的 RUL 预测研究。

参考文献

- [1] 卢奇秀. 锂电巨头市场重心转向储能[N], 中国能源报, 2023-09-18(2).
LU Q X. Lithium battery giants shift market focus to energy storage[N]. China Energy News, 2023-09-18(2).
- [2] MA Y, YAO M H, LIU H C, et al. State of health estimation and remaining useful life prediction for lithium-ion batteries by improved particle swarm optimization-back propagation Neural Network [J]. Energy Storage, 2022, 52(PA).
- [3] 舒星, 刘永刚, 申江卫, 等. 基于改进最小二乘支持向量机与 Box-Cox 变换的锂离子电池容量预测[J]. 机械工程学报, 2021, 57(14): 118-128.
SHU X, LIU Y G, SHEN J W, et al. Capacity prediction for lithium-ion batteries based on improved least squares support vector machine and Box-Cox transformation [J]. Chinese Journal of Mechanical Engineering, 2021, 57(14): 118-128.
- [4] REN L, ZHAO L, HONG S, et al. Remaining useful life prediction for lithium-ion battery: A deep learning approach[J]. IEEE Access, 2018, 6: 50587-50598.
- [5] 张朝龙, 卢阳, 杨璇, 等. 基于集成 ARIMA 模型与 BP 神经网络的锂电池容量预测 [J]. 安庆师范大学学报,

2022, 28(2): 15-18.

ZHANG ZH L, LU Y, YANG X, et al. Capacity prediction of lithium battery based on integrated ARIMA model and BP neural network[J]. Journal of Anqing normal university, 2022, 28(2): 15-18.

- [6] 吴菲, 郑秀娟. 基于 PF-GPR 算法的锂离子电池剩余使用寿命预测 [J]. 武汉科技大学学报, 2022, 45(3): 189-196.
WU F, ZHENG X J. Remaining useful life prediction of lithium-ion battery based on PF-GPR algorithm[J]. Journal of Wuhan University of Science and Technology, 2022, 45(3): 189-196.

- [7] 叶鑫, 王海瑞, 李远博, 等. 基于 VMD 和优化的 LSTM 锂离子电池寿命预测方法[J]. 电子测量技术, 2022, 45(23): 153-158.

YE X, WANG H R, LI Y B, et al. Remaining useful life prediction method of lithium-ion battery based on variational mode decomposition and optimized LSTM[J]. Electronic Measurement Technology, 2022, 45 (23): 153-158.

- [8] 尹杰, 刘博, 孙国兵, 等. 基于迁移学习和 DAE-LSTM 的锂离子电池剩余寿命预测 [J]. 电工技术学报, 2024, 39(1): 289-302.

YIN J, LIU B, SUN G B, et al. Transfer learning DAE-LSTM for remaining useful life prediction of Li-Ion Batteries [J]. Transactions of China Electrotechnical Society, 2024, 39(1): 289-302.

- [9] 刘琼, 张豹. 基于 GBDT 算法的锂电池剩余使用寿命预测 [J]. 电子测量与仪器学报, 2022, 36 (10): 166-172.

LIU Q, ZHANG B. Remaining useful lifetime prediction for lithium battery based on GBDT algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10): 166-172.

- [10] 王冉, 后麒麟, 石如玉, 等. 基于变分模态分解与集成深度模型的锂电池剩余寿命预测方法[J]. 仪器仪表学报, 2021, 42(4): 111-120.

WANG R, HOU Q L, SHI R Y, et al. Remaining useful life prediction method of lithium battery based on variational mode decomposition and integrated deep model[J]. Chinese Journal of Scientific Instrument, 2021, 42(4): 111-120.

- [11] 陈锐, 丁凯, 祖连兴, 等. 基于 AED-CEEMD-Transformer 的锂离子电池健康状态估计[J]. 储能科学与技术, 2023, 12(10): 3242-3253.

CHEN R, DING K, ZU L J, et al. Prediction of state of health of lithium-ion battery based on AED-CEEMD-Transformer network [J]. Energy Storage

- Science and Technology,2023,12(10):3242-3253.
- [12] HAN K, XIAO A, WU EH, et al. Transformer in transformer [J]. Advances in Neural Information Processing Systems,2021,34:15908-15919.
- [13] 黄飞虎,赵红磊,弋沛玉,等. 一种改进 Transformer 的电力负荷预测方法[J]. 现代电力,2023,40(1):50-58.
HUANG F H, ZHAO H L, GE P Y, et al. An improved power load forecasting method based on Transformer[J]. Modern Electric Power,2023,40(1):50-58.
- [14] CHEN J, CHEN T L, LIU W J, et al. Combining empirical mode decomposition and deep recurrent neural networks for predictive maintenance of lithium-ion battery [J]. Advanced Engineering Informatics, 2021,50(9):101405. 1-101405. 23.
- [15] AKIBA T, SANO S, YANASE T, et al. Optuna: A nextgeneration hyperparameter optimization framework[C]. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery&Data Mining, Anchorage. AK, USA:IEEE, 2019:2623-2631.
- [16] PANG X. Q, LIU X. Y, JIA J. F, et al. A lithium-ion battery remaining useful life prediction method based on the incremental capacity analysis and Gaussian process regression [J]. Microelectronics. Reliability, 2021,127:114405.
- [17] XUE Z. W, ZHANG Y, CHENG C, et al. Remaining useful life prediction of lithium-ion batteries with adaptive unscented kalman filter and optimized support vector regression [J]. Neurocomputing 2020, 376:95-102.

作者简介

赵昱坡, 硕士研究生, 主要研究方向为寿命预测。

E-mail: yp19990118@163. com

黄伟(通信作者), 副教授, 主要研究方向为智能控制、系统辨识、故障诊断、大数据在数字化电站中的应用。

E-mail: janehwg@163. com

张剑飞, 高级工程师, 主要研究方向为电厂设备运维。

E-mail: cxzjf@163. com