

基于 IViT 的锂离子电池健康状态估计^{*}廖列法^{1,2} 占玉敏¹ 刘映宝¹

(1. 江西理工大学信息工程学院 赣州 341000; 2. 江西现代职业技术学院 南昌 330095)

摘要: 准确预测锂离子电池的健康状态(SOH)至关重要。针对电池单个周期的不同阶段退化机制存在差异和实际运用场景下数据获取不完整等挑战,提出一种基于 Involution-Vision Transformer(IViT)的锂离子电池 SOH 估计方法。从电压时间曲线中自动提取能有效表征锂离子电池退化信息的特征,使用 Involution 模块在不同位置上自适应地分配权重,利用 Vision Transformer 学习不同阶段的高级特征表示并捕获全局依赖关系。实验结果表明,IViT 的预测误差在 0.5% 左右,且当整体数据缺失 50% 的情况下误差仅为 2% 左右,证明了所提方法的有效性和稳定性。

关键词: 锂离子电池;健康状态;Involution;Vision Transformer

中图分类号: TM912;TN98 **文献标识码:** A **国家标准学科分类代码:** 530.4130

Lithium-ion battery state of health estimation based on IViT

Liao Liefan^{1,2} Zhan Yumin¹ Liu Yingbao¹

(1. School of Information Engineering, Jiangxi University of Science and Technology, Ganzhou 341000, China;

2. Jiangxi Modern Polytechnic College, Nanchang 330095, China)

Abstract: It is essential to accurately predict the state of health (SOH) of lithium-ion batteries. Aiming at challenges such as differences in degradation mechanisms at different stages of a single battery cycle and incomplete data acquisition in practical utilization scenarios, a lithium-ion battery SOH estimation method based on Involution-Vision Transformer (IViT) is proposed. Features that can effectively characterize the degradation information of lithium-ion batteries are automatically extracted from the voltage-time profile, weights are adaptively assigned at different positions using the Involution module, and Vision Transformer is used to learn the high-level feature representations at different stages and capture the global dependencies. The experimental results show that the prediction error of IViT is around 0.5%, and the error is only around 2% when the overall data is missing 50%, proving the effectiveness and stability of the proposed method.

Keywords: lithium-ion battery; state of health; Involution; Vision Transformer

0 引言

锂离子电池具有能量密度高、转换效率高、循环寿命长等优点,在工业场景中应用广泛^[1]。然而,随着充放电次数的增加,锂电池的容量逐渐减少,导致内部结构发生变化。此外,电池还会受到内部的化学成分、制造、环境和操作条件等多方面因素的影响^[2],如果管理不当,可能引发不良事件甚至是灾难性事故。因此,准确预测电池 SOH 的变化趋势具有重要意义。

当前 SOH 的估计方法可以分为两类,分别是基于模型的方法和基于数据驱动的方法。基于模型的方法主要是根据电池的内部电化学反应机理建立模型进行 SOH 的估

算,包括经验模型、电化学模型、等效电路模型等。经验模型主要是通过对以往数据的总结和分析得到的。Sadabadi 等^[3]提出了一种半经验模型来揭示电池的老化规律。电化学模型或等效电路模型可以模拟电池内部动态系统追踪电池的退化过程^[4]。Xu 等^[5]提出了一种结合电化学模型和等效电路模型的方法估计电池的 SOH。虽然这类方法具有良好的精度和可解释性,但需要大量先验知识,存在建模困难,模型复杂度较高等缺点。

数据驱动法因其只需最低限度的电池老化机制知识以及能够规避复杂的物理模型的优点,引起学术界和工业界的广泛关注^[6]。该方法仅通过挖掘历史数据中的电池退化规律就能实现 SOH 的精准预测。目前,数据驱动法发展

迅速,包括机器学习方法、深度学习方法等。He 等^[7]提出了一种基于部分充电曲线变异系数、特征处理和高斯过程回归(gaussian process regression, GPR)的 SOH 估计方法;Shu 等^[8]提出一种改进的支持向量机从部分充电电压曲线中提取健康特征进行 SOH 估计。但传统的机器学习方法对于复杂的非线性关系建模能力相对较弱,在处理复杂的数据集和问题时,无法捕捉到数据中的高阶特征或复杂的模式。Deng 等^[9]从电池的放电容量曲线中提取了 4 个特征,并利用电池早期老化数据和长短期记忆网络(long short-term memory, LSTM)实现退化模式识别和迁移学习(transfer learning, TL);Zhao 等^[10]从充电数据提取相关的健康特征,然后开发了一种融合卷积神经网络(convolutional neural network, CNN)、门控循环单元(gated recurrent unit, GRU)和注意力机制的混合深度模型来预测电池的 SOH。但基于循环神经网络(recurrent neural network, RNN)的神经网络由于梯度消失或梯度爆炸的原因,在处理长序列时难以捕捉到长期依赖关系,相比之下,Transformer 使用全局注意力机制在处理长序列问题上具有天然优势。Gu 等^[11]提出了一种基于数据预处理方法和 CNN-Transformer 框架的新型 SOH 估计。

然而,在电池的充放电周期中,不同阶段充放电的退化机制明显不同,由于难以自适应划分并提取电池整个生命周期的充放电阶段信息,大部分文献都未曾关注单个周期中充放电的不同阶段对预测结果的贡献权重差异,而且针对不同阶段的特征可能需要合适的模型进行处理,如何有效融合并优化这些模型以提升整体预测性能还有待研究;

其次,考虑到大部分电池数据在实际的工业场景获得的随机性,收集的数据大多是不完整的。因此,从缺失周期曲线中最大限度的保留关键信息尤为重要。

针对上述问题,本文提出了一种基于电压变化曲线分割充放电阶段的特征提取方法,通过考虑单个周期的充放电不同阶段所包含的退化规律,保留各阶段的关键数据信息,解决数据缺失问题。并基于此,利用 Involution 自适应地调整卷积核,捕捉电池不同阶段的局部信息,实现电池老化信息的初步提取,之后利用 Vision Transformer 通过自注意力机制处理长距离依赖关系,捕获不同阶段的全局信息。融合 Involution 和 Vision Transformer 的优点在不同尺度上提取全面特征以实现更精准的预测。

1 数据处理

1.1 数据集

本研究使用 Severson 等^[12]老化实验所生成的麻省理工大学(massachusetts institute of technology, MIT)数据集进行实验验证,包括 124 个在 72 种不同的快速充电条件下进行测试的磷酸铁锂/石墨(LFP/graphite)电池,寿命从 150~2 300 次循环不等,每次循环都包括完整的充电和放电过程,第 1 步以 C1 进行恒流充电,直到荷电状态(state of charge, SOC)达到指定值,第 2 步以 C2 进行恒流充电,直至 SOC 的 80%,其中 C1 和 C2 的范围为 3.6~8 C。随后,所有电池均以 1 C 进行恒流恒压充电,直至 SOC 达到 100%,最后,以 4 C 放电。电池容量衰减曲线如图 1(a)所示。




图 1 MIT 数据集容量衰减轨迹与特征提取

Fig. 1 Capacity decay trajectory and feature extraction for the MIT dataset

1.2 特征提取

由于原始实验数据存在信息冗余,而且不同电池在其生命周期中发生不同情况的退化等问题。有效的从原始

数据中正确选择和提取特征具有重要意义,因此,提出一种从充放电周期曲线中自动提取特征的方法。

如图 1(b)所示,随着循环周期的增加,电池的电压-时

间曲线显著向左偏移,表明电压-时间曲线能够清晰地反映电池的退化情况。然而,原始数据包含许多冗余的信息,并且容易受到噪声影响。因此,本文从电压-时间曲线中提取特征 F 对数据进行简化,在减少冗余信息的同时降低噪声干扰,定义为:

$$F_c = (V_c, t_c) \quad (1)$$

式中: c 表示第 c 次循环, V 和 t 分别表示从电压-时间曲线中获取的电压与时间的 68 维向量。电压变化剧烈或发生明显转折的地方往往对应着电池充放电过程中重要的化学变化,能较好地反映电池的健康状态及其变化趋势,因此通过检测局部的最大值和最小值充当特征曲线中的分割点自动实现单调段的识别,以此初步分割不同充放电阶段,分割点如图 1(c)粗点所示。随后,在分割点之间对所识别的单调段进行线性插值,保留电压-时间曲线的主要趋势,通过降低输入数据量的需求解决实际问题中数据收集不完整的问题。采样点如图 1(c)所示,在第一阶段和最后阶段均匀采样 24 个点,再将另外两个单调段分别采样 10 个点。通过检测分割点实现单调段的识别和线性插值,既能够有效保持数据整体趋势和结构,解决缺失数据问题,又能显著减少输入数据点的数量,降低计算复杂度。此外,本文随机抽取一些电池数据采用“零填充”方法,主要是利用数据“0”代替部分原始数据,以增加数据的多样性和鲁棒性。该特征提取方法通过提取电压-时间曲线中的关键信息,减少对完整数据的依赖,从而在数据不完整的情况下仍然能够有效地进行 SOH 估计。

1.3 数据处理

数据收集或特征采样期间可能出现异常值,对模型的可靠性和有效性产生不利影响。因此,在输入模型前,需要对数据进行预处理操作。首先,通过使用 Savitzky-Golay 滤波器^[13]消除特征的异常值以提高模型训练的性能。输入数据大小为 $(B \times C) \times F$, 其中 B 是电池总数, C 为每个电池的循环周期数, F 是单个周期的特征,表示为 $(P \times N)$, P 表示采样点数, N 表示特征数量。同时,本文引入滑动窗口来捕捉数据中的局部老化模式和长期退化趋势,从而提高模型对数据的理解和预测能力。当前输入数据大小为 $(B \times C) \times W \times F$, 其中 W 表示滑动窗口大小。

2 所提出的模型

IViT 的总体流程如图 2 所示。主要分为特征提取与数据处理、IViT 的模型结构及 SOH 估计,其中 IViT 包括 Involution Block 和 Vision Transformer 两个模块。首先,从原始数据中获取循环周期的充放电数据,通过第 1.2 节所述方法在有效的保留电池退化信息的同时降低数据维度,随后根据 1.3 节所述方法处理所提取的特征以获得高质量数据作为 IViT 的输入。IViT 首先利用 Involution 模块对电池老化信息实现初步提取,再使用 Vision Transformer 中 patch embedding 将数据划分为包含多个不同充放电阶段信息的 patch,随后由 Transformer Encoder 捕获电池不同阶段老化信息之间的全局依赖关系,最后通过多层感知器 (multilayer perceptron, MLP) 估计 SOH。




图 2 总体流程图

Fig. 2 Overall flow chart

2.1 Involution Block

CNN 因其可以利用卷积操作自动提取特征信息、降低数据的维度等优点被广泛使用。但传统的卷积操作具有一些缺点,比如卷积核的固定大小使得不同位置自适应

能力较弱,局部性限制了卷积的感受野导致无法有效的提取长距离特征依赖关系等。因此,提出一种基于内卷操作 (Involution) 的特征提取模块对电池老化信息进行初步提取。通过动态生成内卷核,自适应地为不同位置分配不同

的权重,从而更好地捕获不同位置的特征信息。相应内卷核的生成通用形式如下:

$$H_{i,j} = \phi(\mathbf{X}_{\varphi_{i,j}}) \quad (2)$$

式中: i 表示第 i 部分, j 表示第 j 个特征, $\varphi_{i,j}$ 为当前老化阶段邻域的集合, $\mathbf{X}_{\varphi_{i,j}}$ 为电池输入特征向量, $\phi(\cdot)$ 为内卷核的生成函数。当取 φ 为 $\{(i,j)\}$ 单点集时所得到的形式为:

$$H_{i,j} = \phi(\mathbf{X}_{i,j}) = W_1 \sigma(W_0 \mathbf{X}_{i,j}) \quad (3)$$

其中, $\mathbf{X}_{i,j}$ 表示输入特征, $W_0 \in R^{\frac{c}{r} \times c}$ 和 $W_1 \in R^{(K \times K \times G) \times \frac{c}{r}}$ 代表两个线性变换, $K \times K$ 附近所取邻域大小, c 为通道数, r 为通道缩减比率, $\sigma(\cdot) = \text{ReLU}(\text{BN}(\cdot))$, G 为所有通道共享数。将所得到的内卷核展平与对应位置的特征点在通道上进行积运算,在空间上进行和运算,最终输出一个与输入维度相对应的特征映射,输出特征映射为:

$$\mathbf{Y}_{i,j,k} = \sum_{(u,v) \in \Delta K} H_{i,j,u+\lfloor K/2 \rfloor, v+\lfloor K/2 \rfloor, \lceil KG/C \rceil} \mathbf{X}_{i+u, j+v, k} \quad (4)$$

其中, $k = 1, 2, \dots, \mathbf{X}_{i+u, j+v, k}$ 为输入, $\mathbf{Y}_{i,j,k}$ 为输出, $H_{i,j,u+\lfloor K/2 \rfloor, v+\lfloor K/2 \rfloor, \lceil KG/C \rceil} \in R^{H \times W \times K \times K \times G}$ 为 Involution 的核向量, ΔK 为邻域偏移集, Involution 操作示意图如图 3^[14] 所示。




图 3 Involution 示意图

Fig. 3 Schematic diagram of Involution

根据上述理论,提出基于 Involution 的特征提取模块,该模块包含内卷分支和直连(short-cut)分支,通过内卷分支的 2 层内卷操作提取电池的退化特征,通过直连分支将低层信息直接传递到深层,解决模型训练过程中浅层网络学习困难的问题。Involution 模块示意图如图 4。




图 4 Involution Block 示意图

Fig. 4 Schematic diagram of Involution Block

2.2 Vision Transformer

相比 CNN 缺乏时序信息捕捉能力和 LSTM 缺乏捕捉全局特征的能力,Transformer 可以使用自注意力机制来计算所有输入的注意力权重,具有很强的全局特征提取能力。另一方面,考虑到单个充放电周期的不同阶段对最终 SOH 预测所产生的影响至关重要,因此,本文使用 Vision Transformer(ViT)对输入的老化数据进行退化信息提取。

首先,ViT 将整个数据矩阵分割成若干个 patch 来得到充放电周期的不同阶段数据。随后,由 Transformer Encoder 利用自注意力机制自适应的为不同阶段的信息进行动态加权,更好的捕捉长距离依赖关系。针对当前的 SOH 预测任务,使用回归层对适合分类任务的 ViT 改进,使其更适合本文的回归任务。

1) Patch Embedding

由于 Transformer 只能接受序列数据,因此需要对三维输入进行处理,使用卷积核大小和步长相等的卷积操作实现 patch embedding 下采样,将电池数据矩阵划分为 $(P/P_{patch}) \times (N/N_{patch})$ 个大小相同的 patch,其中 $P \times N$ 是输入数据大小, P_{patch} 为 patch 中包含的离散化采样点, N_{patch} 为 patch 中包含的电池特征类型,每个 patch 都属于长度为 P_{patch} 的充放电不同阶段,包含这个阶段多个特征的 $P_{patch} \times N_{patch}$ 个采样点信息。由于 Transformer 将所有位置的 patch embedding 同时输入,会导致序列丢失顺序。然而,在电池数据中,时间的顺序非常重要,因此使用位置编码为每个 patch 向量增加位置信息来解决这一问题。将位置编码与之前得到的 patch 向量相加得到最终 Transformer 编码器的输入序列,patch embedding 如图 5 所示。




图 5 块嵌入

Fig. 5 Patch embedding

2) Transformer Encoder

自注意力(self-attention)机制是 Transformer 的核心,也是其实现并行计算的关键,如图 6 (a)所示,并行运算的整体公式如下:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (5)$$

其中, $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 为包含多个向量 $\mathbf{q}, \mathbf{k}, \mathbf{v}$ 的矩阵。使用线性层将输入的特征序列 $\mathbf{x}^i$ 投影得到包含退化信息的序列 $\mathbf{a}^i$, 分别乘以 $\mathbf{W}^q, \mathbf{W}^k, \mathbf{W}^v$ 3 个变换矩阵,得到 $\mathbf{q}, \mathbf{k}, \mathbf{v}$ 3 个不同退化角度的向量。公式如下:

$$\mathbf{q}^i = \mathbf{W}^q \mathbf{a}^i \quad (6)$$

$$\mathbf{k}^i = \mathbf{W}^k \mathbf{a}^i \quad (7)$$

$$\mathbf{v}^i = \mathbf{W}^v \mathbf{a}^i \quad (8)$$

为输入的不同阶段分别计算一个 score, 如图 6(b) 所示, 表示为 $\alpha_{1,i}$, 其中 d_k 表示 $\mathbf{q}, \mathbf{k}$ 的维度, 再进行 softmax 运算得到当前阶段的权重 $\bar{\alpha}_{1,i}$, 对 $\mathbf{v}^i$ 向量进行加权, 最终得到包含不同阶段相关性的输出向量 $\mathbf{b}^1$, 公式如下:

$$\alpha_{1,i} = \frac{\mathbf{q}^i \cdot \mathbf{k}^i}{\sqrt{d_k}} \quad (9)$$

$$\bar{\alpha}_{1,i} = \frac{\exp(\alpha_{1,i})}{\sum_j \exp(\alpha_{1,j})} \quad (10)$$




图 6 自注意力机制

Fig. 6 Self-attention mechanism

使用两层 MLP 得到 Transformer Encoder 的最终输出。MLP 的功能主要在于两个方面: 一是进行维度变换, 以确保 Transformer Encoder 的输入和输出维度保持一致; 二是引入非线性激活函数提供非线性特征并学习退化的复杂关系, 以弥补 MHSA 仅采用线性投影的不足, 从而加强模型的特征提取能力。

2.3 健康状态评估

对于锂离子电池来说, 容量是反映电池退化状态的重要指标, 通常定义为:

$$SOH = \frac{C}{C_{norm}} \times 100\% \quad (13)$$

其中, C 和 C_{norm} 分别是电池的实际容量和电池的额定容量。

为了验证所提预测方法的有效性, 选择常用的平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE) 和平均绝对百分比误差 (mean absolute percentage error, MAPE) 来作为模型预测精度的评价指标, 它们的公式定义如下:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (14)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (15)$$

$$\mathbf{b}^1 = \sum_i \bar{\alpha}_{1,i} \mathbf{v}^i \quad (11)$$

多头自注意力机制 (multi-head self attention, MHSA) 通过并行运行 Self-Attention 层, 形成多个子空间从而关注不同退化模式的信息, 再综合其结果, 进而增强模型特征提取能力, 多头注意力机制公式如下:

$$MHSA(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \sum_{m=1}^h \text{Attention}(\mathbf{Q}\mathbf{W}_Q^m, \mathbf{K}\mathbf{W}_K^m, \mathbf{V}\mathbf{W}_V^m) \quad (12)$$

其中, h 是头的个数, 代表 h 种不同的投影模式, $\mathbf{W}_Q^m, \mathbf{W}_K^m, \mathbf{W}_V^m$ 分别是矩阵 $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 在第 m 种投影模式下的线性投影参数矩阵。

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (16)$$

其中, N 表示一个电池从初始状态到故障状态的循环次数, y_i 表示测试电池在第 i 个循环时的实际值, $\hat{y}_i$ 表示由测试模型生成的估计值, $\bar{y}$ 表示测试电池实际平均值。

3 实 验

3.1 特征选择实验

不同的特征输入会对最终预测结果产生不同的影响, 为证明所提特征提取方法的有效性, 进行特征选择实验, 按输入特征分类为: 特征提取后的时间^[15] (t)、电压 (V); 特征提取后的 V_t 组合; 原始数据的 V_t 组合; 使用零填充的特征提取后的 V_t 组合。最终结果如表 1 所示。

表 1 特征选择实验结果

特征选择	MAE	RMSE	MAPE
t	0.960	1.119	0.942
V	1.514	2.018	1.513
V, t	0.686	0.951	0.688
V, t(all)	0.934	2.162	0.906
V, t(zero padding)	0.494	0.702	0.494

从表中可以看出,与单个特征输入相比,将电压与时间融合输入的预测精度更高。这是因为,多特征数据融合可以从多个角度反映电池的状态和性能,减少对单一数据源的依赖,避免特定情况下数据不敏感的影响,从而有效提高预测模型的准确性和鲁棒性。因此本文选择多特征融合数据作为模型输入。除此之外,在选择多特征融合输入的同时,采用随机“零填充”方法可以增强模型的多样性和泛化能力,能够在更好地适应实际应用场景的同时进一步提升预测精确度,结果如表 1 所示,MAE, RMSE, MAPE 分别下降 28.0%, 26.2% 和 28.2%。此外,与原始的电压和时间特征比较,本文所使用的方法在减少数据冗余信息的同时还提高了效率和预测精度,MAE, RMSE, MAPE 分别下降 47.1%, 67.5% 和 45.5%。结果表明,本文所提出的特征提取方法在所选的 3 个评估指标中均取

得最好成绩,验证了所提方法的有效性。

3.2 消融实验

为了证明所提出 IViT 模型不同模块的性能,本文进行了消融实验,实验结果如表 2 和图 7 所示。

表 2 消融实验结果

模型	MAE	RMSE	MAPE
Vision Transformer	1.020	1.176	1.007
CNN+Vision Transformer	0.578	0.877	0.575
Involution Block+Transformer	0.874	1.268	0.875
Involution Block+Vision Transformer	0.494	0.702	0.494




图 7 消融实验的 SOH 估计结果

Fig.7 SOH estimation results for ablation experiments

一方面,实验通过将 IViT 与 ViT 和 CNN + ViT 进行比较,从表中可以看出,使用 Involution 模块的误差结果明显低于不使用或者使用 CNN 的 ViT 模型,证明了当前所提出 Involution 模块的有效性。此外,本文展示了短、中、长 3 种不同电池寿命(分别为 509、1 093、1 638 个循环周期)电池的预测趋势,每个电池的运行工况差异较大,结果如图 7 所示,仅使用 ViT 模型在不同寿命电池前中后期均无法拟合电池退化趋势,误差结果较大。由于 CNN 具有强大的局部感知能力,CNN+ViT 预测的整体误差明显降低,前中期更能拟合退化趋势,但后期波动极大。Involution 可以自适应地为不同位置分配不同的权重以更好地拟合电池退化趋势,从而实现整个生命周期的稳定预测。

另一方面,为验证 ViT 模型的有效性,实验将 IViT 模型中的 ViT 模型换成 Transformer 模型进行比较。结果表明,Involution Block+Transformer 实验的评价指标明显高于本文提出的 IViT 模型。这是因为 Transformer 中缺少 Patch Embedding,无法从单个周期中捕获不同充放电阶段的贡献大小。

实验结果证明,IViT 的两个模块均能对 SOH 的预测

精度产生积极影响,评估指标 MAE, RMSE, MAPE 分别达到 0.494%, 0.702%, 0.494%。表明所提出的 IViT 模型能拟合不同工况和寿命范围电池的真实退化趋势,证明了模型的有效性和鲁棒性。

3.3 对比试验

为进一步证明当前提出方法的优越性,将其与当前使用相同数据集的其他方法进行对比,文献[9]从电池早期老化数据的放电容量曲线中提取 4 个特征,基于 LSTM 实现退化模式(degradation pattern, DP)识别和迁移学习,均可有效提高 SOH 估计精度,MAE 和 RMSE 的平均值仅为 0.94% 和 1.13%。文献[16]提出一种基于迁移学习和深度信念网络(deep belief network, DBN)-LSTM 混合网络的 SOH 估计方法,利用迁移学习学习源域和目标域的共享特征,并通过 DBN 和 LSTM 网络来增强特征提取和历史信息,MAE、RMSE 分别是 0.94% 和 1.13%;文献[17]提出了一种基于充电和放电过程中的电流、电压和温度曲线的 SOH 预测方法,通过滑动窗口周期获得输入,利用 LSTM 神经网络实现对 SOH 的多步预测,MAE、RMSE 分别是 0.77% 和 1.04%。实验结果如表 3 所示。从表中可以看出,基于 LSTM 捕获输入序列的依赖关系的

方法如 LSTM-DP recognition-TL、DBN-LSTM、SOH-window-XLSTM 在一定程度上避免训练时的梯度爆炸从而获得更好的预测精度,但对单个周期的较长输入序列的长期建模能力依旧较弱,而且这些方法均未考虑到充放电不同阶段的退化信息对最终预测的贡献不同。相比之下,首先针对电压变化进行初步的阶段划分,降低后续模型的计划复杂度,使用 VIT 的 Patch Embedding 的模块为充放电阶段赋予自适应的贡献权重,采用自注意力机制并行处理输入序列中的所有位置,捕捉不同位置之间的长距离依赖关系从而提升模型预测精度,且增加的 Involution 模块能够更好的提取特征信息的同时捕获长距离依赖关系。从结果可以看出,本文提出方法的误差结果均优于其他 SOH 估计方法,验证了所提方法的有效性。

表 3 与其他方法对比结果

Table 3 Comparison results with other methods %			
方法	MAE	RMSE	MAPE
LSTM-DP recognition-TL ^[9]	0.940	1.130	—
DBN-LSTM ^[16]	1.180	1.080	0.990
SOH-window-XLSTM ^[17]	0.770	1.040	—
IViT	0.494	0.702	0.494

3.4 窗口大小选择实验

窗口大小代表输入数据所覆盖的电池曲线范围,直接影响样本数量和模型参数,对模型准确预测电池的 SOH 具有重要意义。当输入样本不足,可能会使模型难以提取与电池退化规律密切相关的特征,相反,样本数量过多可能会导致模型过度拟合,从而降低模型在训练过程中的有效性。本实验主要分析窗口大小对模型性能的影响,分别将窗口大小设置为 1、5、10、15,结果如表 4 和图 8 所示。

表 4 滑动窗口试验结果

Table 4 Sliding window test results %			
窗口大小	MAE	RMSE	MAPE
1	0.494	0.702	0.494
5	0.510	0.712	0.507
10	1.352	1.465	1.320
15	1.868	2.415	1.888

结果显示,实验整体误差随着窗口变大的同时从缓慢增加到急剧上升,这是因为所提取的采样点已经包含足够的电池退化信息,窗口增大会出现信息的冗余现象。当窗口越大,所产生的冗余信息越多,误差增加越快。因此,本研究选择 1 作为最佳窗口大小,在获得最好的精度的同时加快模型效率。

3.5 模拟数据缺失实验

由于在实际工业运用场景中工作条件的随机性与多




图 8 滑动窗口实验误差

Fig. 8 Sliding window experimental error

样性,往往很难获得充放电过程中的完整曲线。因此,有必要研究本文所提出的方法在数据缺失场景下的预测性能,设置五组不同数据量缺失的对比试验,在特征提取之前使用 0 随机替换部分已有数据,结果如表 5 所示。

表 5 模拟数据缺失实验结果

Table 5 Experimental results of simulated missing data %			
缺失百分比	MAE	RMSE	MAPE
10	1.016	1.202	1.008
20	0.846	1.198	0.845
30	1.218	1.718	1.238
40	1.774	2.114	1.724
50	2.004	1.950	2.314

结果显示,数据缺失多少和误差结果的变化趋势并不单调,随着数据缺失百分比的增加,整体误差呈现下降后上升趋势。这也证明了充放电不同阶段数据对最终结果贡献权重不同,在缺失数据部位不同的情况下即使缺失数据增多也会出现误差降低的情况。此外,尽管实验在整体数据缺失 50% 时误差最大,误差仍然只有 2% 左右,因此能够表明本文所提出的方法在实际运用场景下的准确性和可行性。

4 结 论

为了提高电池的 SOH 估计精度,本文提出了一种基于 IViT 的锂离子电池 SOH 估计方法。首先,提出一种基于充放电电压时间曲线的特征提取方法,能够从充放电周期曲线中自动提取特征,以解决实际场景下数据获取不完整问题。随后,考虑单个周期中充放电不同阶段对最终 SOH 预测的贡献影响设计 IViT 模型。IViT 模型包括 Involution 和 Vision Transformer 两个模块,其中 Involution 模块在不同位置上自适应地分配权重,对电池老化信息进行初步提取,之后利用 Vision Transformer 学习不同阶段的高级特征表示并捕获全局依赖关系。最后,

使用来自 MIT 数据中的 124 个电池对所提方法进行验证。实验结果显示,本文所提方法获得了良好的 SOH 估计精度,验证了所提方法的有效性。其中 MAE, RMSE, MAPE 分别达到 0.494%, 0.702%, 0.494%。在模拟实际场景缺失数据实验中,整体数据缺失 50% 的情况下误差仅为 2% 左右。在未来的工作中,将尝试从其他运行条件中提取特征,并结合本文提出的方法针对不同的应用场景实现更加准确的健康状态评估。

参考文献

- [1] 陈新岗, 赵龙, 马志鹏, 等. 基于 ISSA-CNN-BiGRU-Attention 的锂电池健康状态评估[J]. 电子测量技术, 2024, 47(8): 45-52.
- [2] CHEN X G, ZHAO L, MA ZH P, et al. State of health assessment of lithium batteries based on ISSA-CNN-BiGRU-Attention [J]. Electronic Measurement Technology, 2024, 47(8): 45-52.
- [3] CHEN M ZH, MA G J, LIU W B, et al. An overview of data-driven battery health estimation technology for battery management system [J]. Neurocomputing, 2023, 532: 152-169.
- [4] SADABADI K K, RAMESH P, TULPUL P, et al. Design and calibration of a semi-empirical model for capturing dominant aging mechanisms of a PbA battery[J]. Journal of Energy Storage, 2019, 24: 100789.
- [5] JIANG SH D, SONG ZH X. A review on the state of health estimation methods of lead-acid batteries[J]. Journal of Power Sources, 2022, 517: 230710.
- [6] XU ZH CH, WANG J, LUND P D, et al. Co-estimating the state of charge and health of lithium batteries through combining a minimalist electrochemical model and an equivalent circuit model [J]. Energy, 2022, 240: 122815.
- [7] 金帅, 董静. 基于数据驱动的锂离子电池健康状态估计研究进展综述[J]. 仪器仪表学报, 2024, 45(3): 45-59.
- [8] JIN SH, DONG J. Review on progress of data-driven based health state estimation for lithium-ion batteries[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 45-59.
- [9] HE Y, BAI W, WANG L, et al. SOH estimation for lithium-ion batteries: An improved GPR optimization method based on the developed feature extraction[J]. Journal of Energy Storage, 2024, 83: 110678.
- [10] SHU X, LI G, SHEN J, et al. A uniform estimation framework for state of health of lithium-ion batteries considering feature extraction and parameters optimization[J]. Energy, 2020, 204: 117957.
- [11] DENG ZH W, LIN X K, CAI J W, et al. Battery health estimation with degradation pattern recognition and transfer learning[J]. Journal of Power Sources, 2022, 525: 231027.
- [12] ZHAO H Q, CHEN ZH, SHU X, et al. State of health estimation for lithium-ion batteries based on hybrid attention and deep learning [J]. Reliability Engineering & System Safety, 2023, 232: 109066.
- [13] GU X, SEE K W, LI P, et al. A novel state-of-health estimation for the lithium-ion battery using a convolutional neural network and transformer model [J]. Energy, 2023, 262: 125501.
- [14] SEVERSON K A, ATTIA P M, JIN N, et al. Data-driven prediction of battery cycle life before capacity degradation [J]. Nature Energy, 2019, 4 (5): 383-391.
- [15] GUO F, WU X, LIU L, et al. Prediction of remaining useful life and state of health of lithium batteries based on time series feature and Savitzky-Golay filter combined with gated recurrent unit neural network[J]. Energy, 2023, 270: 126880.
- [16] LI D, HU J, WANG CH H, et al. Involution: Inverting the inheritance of convolution for visual recognition[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 12321-12330.
- [17] PEPE S, CIUCCI F. Long-range battery state-of-health and end-of-life prediction with neural networks and feature engineering[J]. Applied Energy, 2023, 350: 121761.
- [18] MA Y, SHAN C, GAO J W, et al. Multiple health indicators fusion-based health prognostic for lithium-ion battery using transfer learning and hybrid deep learning method[J]. Reliability Engineering & System Safety, 2023, 229: 108818.
- [19] JORGE I, MESBAHI T, SAMET A, et al. Time series feature extraction for lithium-ion batteries state-of-health prediction[J]. Journal of Energy Storage, 2023, 59: 106436.

作者简介

廖列法, 博士, 教授, 主要研究方向为城市计算、电子商务、个性化推荐、自然语言处理。

占玉敏(通信作者), 硕士研究生, 主要研究方向为锂离子电池健康状态估计。

E-mail: 2540913430@qq.com

刘映宝, 硕士研究生, 主要研究方向为锂离子电池剩余使用寿命预测。