

• 电气工程 •

DOI:10.12454/j.jsuese.202300930



本刊网刊

基于时间卷积网络的电池寿命评估方法

孙玉树^{1,2}, 安娟³, 黄存强³, 张舜祯³, 党艳阳², 裴玮¹, 唐西胜^{1*}

(1. 中国科学院电工研究所, 北京 100190; 2. 特变电工股份有限公司, 新疆 昌吉 831100; 3. 国网青海省电力公司经济技术研究院, 青海 西宁 810008)

摘要: 为了提高电池系统应用的技术经济性, 本文基于时间卷积网络从健康状态和剩余使用寿命两个角度对电池寿命进行评估。首先, 介绍时间卷积网络的电池寿命评估原理, 阐述其相较于经典递归神经网络的优势; 然后, 基于电池易测量的时间、电压、电流和温度等数据提取 14 个相关间接健康特征因素, 利用 KL 散度、皮尔逊相关系数和灰色关联度 3 种算法分别分析不同因素与健康状态的相关程度, 并与时间卷积网络相关性方法进行对比和分析, 筛选出对电池健康状态影响较大的 5 个特征因素, 即循环时间、电压平均值、电压样本熵、温度样本熵和电流值; 接着, 利用核主成分分析法对选取的主导特征因素进行降维处理, 筛选出贡献率较大的主成分, 以减小后续计算复杂度。使用时间卷积网络、长短时记忆神经网络和反向传播神经网络进行仿真对比分析, 结果表明本文的时间卷积网络具有较高的健康状态预测精度; 另外, 由于电池存在容量再生现象, 利用健康状态对电池寿命表征存在较大误差, 而通过对电池剩余循环次数进行寿命预测, 可以克服健康状态预测的缺点。仿真结果验证了本文所提的时间卷积网络的电池寿命评估策略对电池寿命精确评估具有有效性。

关键词: 电池; 时间卷积网络; 核主成分分析法; 健康状态; 剩余使用寿命

中图分类号: TM 614

文献标志码: A

文章编号: 2096-3246(2025)04-0259-10

国家发展改革委和国家能源局发布了《关于加快推进新型储能发展的指导意见》, 指出: 到 2030 年, 实现新型储能全面市场化发展, 新型储能装机规模基本满足新型电力系统相应需求, 成为能源领域碳达峰、碳中和的关键支撑之一^[1]。作为新型储能的重要组成, 电池储能因能量密度大、组网灵活等特点受到人们的青睐。但由于其电化学特性, 随着充放电循环次数的增加, 电池会不断老化。老化到一定程度易发生故障, 从而导致高昂的维修成本和巨大的安全风险, 甚至产生火灾等不可预期的后果^[2-3]。因此, 开展电池健康状态(SOH)和剩余使用寿命(RUL)的精准评估, 对提高电池储能系统的智能化运维水平十分重要。

目前, 对电池 SOH 和 RUL 的评估方法主要包括物理模型法和数据驱动法^[4-5]。物理模型法基于电化学机理, 建立锂电池全寿命周期内运行条件、材料特性和失效机理相结合的动态物理模型, 通过历史数据和

实时数据对相关参数进行辨识, 并预测剩余使用寿命。该方法主要针对特定的电池材料、使用环境和充放电条件开展研究, 一般根据电极的物理特性来获取模型参数, 因此模型难以动态跟踪环境条件的变化, 导致准确度较差, 并且, 作为复杂多变的电化学系统, 若要对电池退化特征及老化原因进行详细描述, 则模型的复杂程度较高, 实际应用难度较大。当前, 物理模型主要包括电化学模型和等效电路模型。关于电化学模型方面的研究较多, 例如: Khodadadi Sadabadi 等^[6]利用汽车充电数据开发一种基于增强单粒子模型参数估计的剩余使用寿命预测算法。高仁璟等^[7]提出一种基于伪 2 维模型参数的估算方法, 通过拆解同类估算目标电池, 以扫描电镜测量的电池结构为参数, 利用遗传算法辨识其他未知电化学模型参数, 建立一种基于化学计量比的电池正极容量计算法则, 来估算电池健康状态。Bi 等^[8]提出一种基于高保真降阶物理寿

收稿日期: 2023-11-19 修回日期: 2023-12-23 网络出版日期: 2024-06-05

基金项目: 国家重点研发计划项目(2023YFB2407902); 中国科学院青年创新促进会项目(2023000018)

作者简介: 孙玉树(1987—), 男, 副研究员, 博士。研究方向: 可再生能源; 储能及微电网。E-mail: yushusun@mail.iee.ac.cn

* 通信作者: 唐西胜, 研究员, E-mail: tang@mail.iee.ac.cn

命模型的健康状态和老化参数的在线估计方法,以提高计算效率。关于等效电路模型方面的研究也较多,例如:张凤珠等^[9]建立锂电池 2 阶 RC 等效电路模型,基于平方根扩展卡尔曼滤波算法实现锂电池 SOH 估计。任璞等^[10]以三元锂电池为研究对象,建立 2 阶 RC 等效模型对电池的工作特性进行表征,从内阻增加及容量衰减两方面分析健康状态变化。Shi 等^[11]基于递推最小二乘法对电池寿命内动态工况下的等效电路模型参数进行辨识,并引入多元逐步回归分析等统计分析方法来表征参数对 SOH 估计的敏感性。

数据驱动法是将电池看作“黑箱”或“灰箱”,通过对大量运行数据进行统计分析、数据挖掘或模式识别,找出与电池健康状态相关的主导物理量。数据驱动法规避电池复杂的电化学反应建模,利用电池外特性数据推导出电池系统将出现的状态趋势,实现电池剩余使用寿命的预测,可以克服物理模型法的动态精度不足及普适性较差的问题。目前,数据驱动法如高斯回归、向量机、人工神经网络等,在对电池剩余使用寿命的预测中得到快速应用^[12]。例如:Liu 等^[13]建立高斯回归模型,解决电池容量衰减的再生现象,有效实现对锂离子电池的 SOH 估计。Chen 等^[14]提出一种基于蝙蝠算法优化的动态集成相关向量机的锂离子电池 SOH 在线估计方法,与单一数据驱动方法相比,该方法具有更高的精度和泛化能力。王雪等^[15]设计一种基于改进的多目标布谷鸟搜索和 BP 神经网络的锂离子电池健康状态估计方法,在避免算法陷入局部最优的同时可自适应改变布谷鸟搜索算法更新概率和搜索步长。上述机器学习方法虽计算速度较快,但预测精度普遍较低。

在时序数据预测研究方面,深度学习,特别是递归神经网络比机器学习更有优势,其通过建立深度映射结构表征数据之间的关系,经过大量的数据训练最终确定内在关联。例如:Veeraraghavan 等^[16]采用循环神经网络建立电动汽车电池老化估计模型。Ren 等^[17]提出一种自动编码器与深度神经网络相结合的集成学习方法,以预测锂离子电池剩余使用寿命。胡天中等^[18]提出多尺度深度神经网络的锂电池健康退化预测模型,采用深度置信网络和长短期记忆网络分别对主趋势和波动数据进行建模。李苏阳等^[19]提出一种基于注意力机制和双向长短期记忆网络的锂电池 SOH 估算模型,通过充分学习序列特征,利用注意力机制分配特征隐含状态下的权重,最终映射得到目标值 SOH。但递归神经网络对大样本数据的处置能力和模型预测精度还有待提升。

目前,对电池寿命的预测主要侧重于 SOH 的评估,忽略了电池容量的再生现象。随着时间卷积网络

的快速发展,其具有更强大的时间序列信息存储和挖掘能力,比经典的递归神经网络结构更简单、更清晰,预测结果更精确。因此,为了更好地掌握电池的实时状态,本文提出基于时间卷积网络开展电池 SOH 和 RUL 联合评估方法。首先,给出了时间卷积网络的原理;然后,通过多种相关性分析方法辨识电池 SOH 的影响因素,利用核主成分分析对主要影响因素进行数据降维;最后,通过仿真对电池 SOH 和 RUL 进行预测,以克服电池容量的再生现象。

1 时间卷积网络

时间卷积网络(TCN)^[20]是一种基于卷积神经网络的新型架构。不同于一般卷积神经网络,TCN 采用扩大因果卷积和残差块等结构,使其具有从大样本时间序列中提取特征和实现预测的能力,且可以在网络训练过程中有效解决深层次网络的性能退化问题。本文采用时间卷积网络对电池寿命进行评估,时间卷积网络的具体原理如下。

1) TCN 建模

当输入序列为 x_0, x_1, \dots, x_T , 预测输出序列 y'_0, y'_1, \dots, y'_T 与输入序列的表达式为:

$$(y'_0, y'_1, \dots, y'_t, y'_{t+1}, \dots, y'_T) = f(x_0, x_1, \dots, x_t, x_{t+1}, \dots, x_T) \quad (1)$$

式中: y'_t 仅与当前时刻 t 及之前时刻的输入序列 x_0, x_1, \dots, x_t 有关,与之后的 $x_{t+1}, x_{t+2}, \dots, x_T$ 无关; T 为时间。TCN 建模是为了建立输入序列与输出序列之间的映射关系,其目标是使实际输出 y_0, y_1, \dots, y_T 和预测输出 y'_0, y'_1, \dots, y'_T 之间的误差损失最小。

2) 扩大因果卷积(DCC)

DCC 的结构如图 1 所示。




图 1 扩大因果卷积结构

Fig. 1 Dilated causal convolution structure

采用 DCC 的 TCN 模型能够并行地输入时序数据,提升神经网络中神经元的感受野,在处理大样本时间序列时有更快的网络训练速度。DCC 的具体表达式为:

$$F(i) = \sum_{j=0}^{k-1} h(j)x(i-dj) \quad (2)$$

式中: $F(i)$ 为 i 的卷积; $h(j)$ 为卷积核; d 为扩大因子,当 $d=1$ 时为标准因果卷积。

3) 残差块

残差块通过引入一个跳过1层或多层的“跳连接”操作,解决深度学习网络的退化问题,其具体结构如图2所示。图2中, x 为残差块输入, o 为残差块输出, $\Gamma(x)$ 为残差。

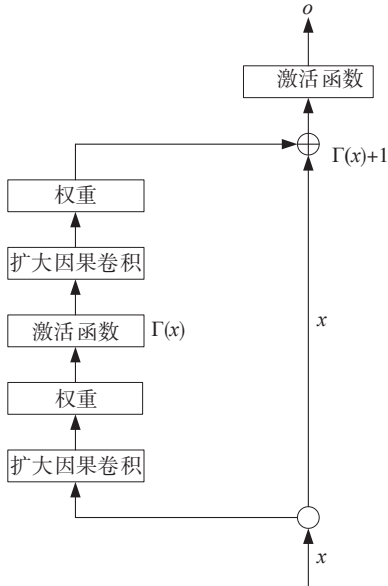


图2 残差块结构

Fig. 2 Residual block structure

4) TCN的优点

①并行性。递归神经网络必须等待前面的任务完成后才能进行后续的预测;而TCN的每层都有滤波器,可以利用卷积并行计算。因此,TCN可以将长输入序列数据作为一个整体进行处理,克服了递归神经网络需要顺序处理的缺点。

②灵活的感受野。TCN可以通过使用更大的膨胀因子,堆叠更多的扩张(因果)卷积层,甚至增加滤波器的大小等多种方式,根据需要控制模型的内存大小,来改变感受野的大小,适应性较强。

③稳定的梯度。由于TCN的反向传播路径与序列的时间方向不同,其梯度更加稳定。

④训练时内存要求低。在处理较长序列数据时,长短时记忆网络(LSTM)易占用大量内存来存储多个单元门的部分结果。由于TCN的滤波器可跨层共享,且反向传播路径仅取决于网络深度,所以TCN更加节约内存。

⑤可变长度输入。TCN可以通过滑动1维卷积核对任意可变长度的数据进行接收,具有强大灵活的数据处理能力。

与经典递归神经网络相比,TCN更稳定,数据处理速度更快,数据适应性和处理能力更好,节约更多的内存等。因此,本文使用TCN对电池的SOH和RUL

进行评估。

2 相关性分析方法

为了量化不同因素对电池寿命的影响,使用KL散度、皮尔逊相关系数、灰色关联度3种相关性分析方法,与TCN相关性分析结果进行对比,选取对电池寿命影响较大的因素,作为后续分析的输入。

1) KL散度

KL散度^[21],也称相对熵,能够度量2个过程的概率分布的差别。设 $p(x)$ 、 $q(x)$ 为2个过程的概率,则KL距离为:

$$\delta(p, q) = \sum_{x \in N} p(x) \lg \frac{p(x)}{q(x)} \quad (3)$$

进而,得到 $p(x)$ 、 $q(x)$ 之间的KL散度为:

$$D(p, q) = \delta(p, q) + \delta(q, p) \quad (4)$$

KL散度是对2个过程的概率分布夹角的度量,其值越大,表示相关性的差别越大;反之,其值越小则差异越小;当2类概率分布完全相同时,数值为0。

假定概率分布分别为 $p(x)$ 、 $q(x)$,求信号 $X = \{x_1, x_2, \dots, x_n\}$ (其中, n 为样本数量)和信号 $Y = \{y_1, y_2, \dots, y_n\}$ 之间的KL散度的具体过程如下。

首先,计算信号 X 的概率分布,本文采用非参数估计法求解概率分布:

$$p(x) = \frac{1}{nh} \sum_{i=1}^n K \left[\frac{x_i - x}{h} \right], x \in R \quad (5)$$

式中: $p(x)$ 为核密度估计后的概率密度函数; h 为给定的正数,称为窗宽或平滑参数; $K(\cdot)$ 为核函数,常用高斯核函数为:

$$K(u) = \frac{1}{\sqrt{2\pi}} e^{-u^2/2} \quad (6)$$

式中, u 为核函数的自变量。

然后,同理,可以得到 Y 的概率分布 $q(x)$ 。

最后,将 $p(x)$ 、 $q(x)$ 代入式(3)求解 X 和 Y 的KL距离 $\delta(p, q)$ 和 $\delta(q, p)$;进一步利用式(4)计算出KL散度 $D(p, q)$ 。

2) 皮尔逊(Pearson)相关系数

Pearson相关系数^[22]被广泛用于度量两个变量之间的线性相关程度,其绝对值越大,两者的线性关联度越好。 X 、 Y 的Pearson相关系数的表达式如下:

$$\gamma = \frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum (X - \bar{X})^2 \sum (Y - \bar{Y})^2}} \quad (7)$$

式中, \bar{X} 、 \bar{Y} 分别为变量 X 、 Y 的期望值。

3) 灰色关联度

灰色关联度^[23]通过分析不同曲线的几何接近性评

估它们之间的关系,接近性越高,说明相关性越紧密。

假定参考序列 X_0 和比较序列 X_k 分别表示为:

$$X_0 = \{x_0(1), x_0(2), \dots, x_0(n)\} \quad (8)$$

$$X_k = \{x_k(1), x_k(2), \dots, x_k(n)\} \quad (9)$$

式中, $x_0(n)$ 和 $x_k(n)$ 均为样本数据。

为减少参数在维度上的差异,初始化 X_0 和 X_k :

$$Y_0 = \frac{X_0}{x_0(1)} = \{1, \frac{x_0(2)}{x_0(1)}, \dots, \frac{x_0(n)}{x_0(1)}\} = \{y_0(1), y_0(2), \dots, y_0(n)\} \quad (10)$$

$$Y_k = \frac{X_k}{x_k(1)} = \{1, \frac{x_k(2)}{x_k(1)}, \dots, \frac{x_k(n)}{x_k(1)}\} = \{y_k(1), y_k(2), \dots, y_k(n)\} \quad (11)$$

假定 $\xi_i(h)$ 为 Y_0 和 Y_k 在 h 时刻的灰色关联系数,则有:

$$\xi_i(h) = \frac{\min_k \min_h |Y_0(h) - Y_k(h)|}{|Y_0(h) - Y_k(h)| + \rho \max_k \max_h |Y_0(h) - Y_k(h)|} + \frac{\rho \max_k \max_h |Y_0(h) - Y_k(h)|}{|Y_0(h) - Y_k(h)| + \rho \max_k \max_h |Y_0(h) - Y_k(h)|} \quad (12)$$

式中, ρ 为分辨系数,本文取 0.5。

故 Y_0 和 Y_k 的灰色关联度为:

$$\zeta_i = \frac{1}{Q} \sum_{i=1}^n \xi_i(h) \quad (13)$$

式中: $i = 1, 2, \dots, n; h = 1, 2, \dots, Q$ 。

3 SOH 评估的影响因素

本文选用美国国家航空航天局(NASA)的锂电池数据^[24]作为研究对象,充放电循环步骤如下:在室温下,以 1.5 A 恒流充电;当电压达到 4.2 V,转为恒压充电,直到充电电流降至 20 mA;进而以 2 A 恒流放电,直到电压降至 2.5 V。重复以上充放电步骤来循环加速电池老化,当电池额定容量衰减到 70% 时,认为电池失效。

本文选用额定容量为 2 A·h 的 18650 型锂离子电池 B0018 进行 SOH(以容量值表示)分析。电池的容量随循环次数的变化曲线如图 3 所示。




图 3 电池容量随循环次数的变化曲线

Fig. 3 Variation curve of battery capacity with the number of cycles

虽然,电池的容量能够简单明了地表明电池的老化程度,但是在实际运行当中,电池的容量不易直接测量,因此本文从易测量的时间、电压、电流和温度入手,提取出更多的间接的健康指标,具体分为以下 4 类,共 14 个特征因素,如图 4~9 所示。




图 4 每个放电循环时间随循环次数的变化曲线

Fig. 4 Variation curve of each discharge cycle time with the number of cycles




图 5 电流随循环次数的变化曲线

Fig. 5 Variation curve of current with the number of cycles




图 6 第 1 部分电压相关参数随循环次数的变化曲线

Fig. 6 Variation curves of part 1 voltage related parameters with the number of cycles




图 7 第 2 部分电压相关参数随循环次数的变化曲线

Fig. 7 Variation curves of part 2 voltage related parameters with the number of cycles




图8 第1部分温度相关参数随循环次数的变化曲线
Fig. 8 Variation curves of part 1 temperature related parameters with the number of cycles




图9 第2部分温度相关参数随循环次数的变化曲线
Fig. 9 Variation curves of part 2 temperature related parameters with the number of cycles

第1类,每个放电循环所用的时间,每个放电循环时间随循环次数的变化曲线如图4所示。

第2类,每个放电循环的电流,电流随循环次数的变化曲线如图5所示。

第3类,每个放电循环的最大电压、最小电压、平均电压、最大最小电压的电压差、电压对时间的最大变化值、电压样本熵,电压相关参数随循环次数的变化曲线分别如图6~7所示。

第4类,每个放电循环的最大温度、最小温度、平均温度、最大最小温度的温度差、温度对时间的最大变化值、温度样本熵,温度相关参数随循环次数的变化曲线如图8~9所示。图7、9中,电压样本熵和温度样本熵是对每个放电循环的电压和温度曲线进行样本熵计算。

由于上述14个特征因素的变化趋势各不相同,为了分析不同特征因素和容量的相关性,采用KL散度、皮尔逊相关系数和灰色关联度进行相关性的量化分析,得出上述3个指标的重要性排序结果,如表1所示。

从表1中可以看出:以KL散度作为评价指标时,温度平均值的KL散度最小,则温度平均值与电池容量的相关性最高;而电流值的KL散度最大,则电流值与电池容量的相关性最低。以皮尔逊相关系数作为

表1 不同特征因素与SOH的关系

Tab. 1 Relationship between different characteristic factors and SOH

重要性排序	KL散度	重要性排序	皮尔逊相关系数	重要性排序	灰色关联度	重要性排序	TCN预测误差
温度平均值	37.569 1	循环时间	0.992 6	循环时间	0.957 1	循环时间	0.030 2
温度最小值	40.727 4	电压平均值	0.985 6	电压平均值	0.870 3	电压平均值	0.048 9
温度差	51.245 7	温度样本熵	-0.975 3	温度最小值	0.868 5	电压样本熵	0.071 6
温度最大值	51.493 3	电压样本熵	-0.974 9	电压最小值	0.861 4	温度样本熵	0.073 7
电压差	70.774 3	温度差	-0.931 2	电压最大值	0.859 4	电流值	0.108 4
电压最小值	96.390 4	温度对时间的最大变化值	-0.902 7	电流值	0.859 2	温度最小值	0.126 1
电压平均值	256.078 3	温度最大值	-0.695 2	电压差	0.856 8	电压最大值	0.127 9
单个循环时间	316.396 9	电压最大值	0.605 9	温度平均值	0.854 7	电压最小值	0.137 5
电压样本熵	1 364.338 0	温度最小值	0.423 0	温度最大值	0.843 9	电压差	0.160 2
温度样本熵	3 150.105 0	电压对时间的最大变化值	-0.294 0	电压对时间的最大变化值	0.831 2	温度最大值	0.162 7
电压对时间的最大变化值	5 722.840 0	温度平均值	-0.200 1	温度差	0.808 1	温度差	0.171 7
温度对时间的最大变化值	9 837.769 0	电压最小值	0.117 6	温度对时间的最大变化值	0.751 2	温度对时间的最大变化值	0.173 3
电压最大值	10 437.330 0	电压差	-0.094 5	温度样本熵	0.624 4	电压对时间的最大变化值	0.196 7
电流值	15 540.990 0	电流值	0.059 4	电压样本熵	0.522 4	温度平均值	0.283 0

评价指标时,循环时间的皮尔逊相关系数最大,则循环时间与容量的相关性最高;电流值的皮尔逊相关系数最小,则电流值与电池容量的相关性最低。以灰色关联度作为评价指标时,循环时间的灰色关联度最大,则循环时间与电池容量的相关性最高;电压样本熵的灰色关联度最小,电压样本熵与电池容量的相关性最低。另外,基于TCN对6个特征因素分别进行容量预测,以验证每个特征因素对容量预测精度的影响,求取6次预测结果的平均值作为预测误差,将预测误差的重要性排序也列入表1中。由表1还可见,预测精度较高的前5个因素为循环时间>电压平均值>电压样本熵>温度样本熵>电流值。由此可见,相关性评价指标在一定程度上能够反映不同特征因素的重要程度,其中,皮尔逊相关系数和TCN预测误差的相关性分析结果较为类似,但也主要是集中在重要性排序靠前的4个特征因素,这是因为不同的评价指标的相关性分析的原理不同,导致分析结果的差异。

由于不同特征因素对电池容量的影响不同,本文采用TCN进行预测时,选取预测误差较小的5个特征因素:循环时间、电压平均值、电压样本熵、温度样本熵、电流值,作为神经网络的输入参量,以提高预测算法的适应性和预测结果的准确性。

4 SOH和RUL预测

通过第3节分析选取的5个特征因素,与电池容量之间均有较高的相关性,但特征因素之间也存在相同元素属性的交叉,会导致特征因素之间不可避免存在的重叠信息,本文采用核主成分分析法将输入特征因素之间的重叠信息与多余信息进行分离与优化,以提高计算的效率和精确度。

核主成分分析^[25]是一种非线性扩展形式的主成分分析。由于主成分分析是一种线性方法,难以有效地提取数据中的非线性部分,而电池寿命的影响因素之间存在复杂的非线性关系,因此,不适合使用主成分分析方法对电池数据进行降维处理。核主成分分析法运用核函数将低维变量空间映射到高维特征空间,使低维空间中的非线性问题转化为高维空间中的线性问题,以达到在高维空间中应用主成分分析降维的效果。

对于 n 个输入样本 x_k (其中, $k=1,2,\dots,n$),其协方差矩阵可表示为:

$$C = \frac{1}{n} \sum_{j=1}^n x_j x_j^T \quad (14)$$

主成分分析法以协方差矩阵中贡献率较大的特征值和特征向量为主成分。而核主成分分析方法引入线性映射函数,将输入样本 x_k 映射到特征空间 $\varphi(x_k)$

中,其对应的协方差矩阵为:

$$C^\varphi = \frac{1}{n} \sum_{j=1}^n \varphi(x_j) \varphi(x_j)^T \quad (15)$$

应用主成分分析求解特征空间中的方程 $\lambda v = C^\varphi v$,其中, λ 为特征值, v 为特征向量。具体表达式为:

$$\lambda [\varphi(x_k) \cdot v] = \varphi(x_k) \cdot C^\varphi v \quad (16)$$

特征向量 v 由特征空间数据进行线性化:

$$v = \sum_{i=1}^n a_i \varphi(x_i) \quad (17)$$

式中, a_i 为第 i 个特征空间数据的线性系数。定义 n 阶核矩阵 K ,其元素 $K_{ij} = \varphi(x_i) \varphi(x_j)$,则式(17)可转换为:

$$n \lambda a = K a \quad (18)$$

式中, a 为特征空间数据的系数矩阵。求解式(18)即可得特征值 λ 和特征向量 v 。

通过对输入样本在特征空间上的投影 V^k ,获取贡献率大的投影特征值和投影特征向量作为主成分。具体表达式为:

$$V^k \cdot \varphi(x) = \sum_{i=1}^n a_i^k [\varphi(x_i) \varphi(x)] \quad (19)$$

1) SOH预测

利用核主成分分析法求取5个特征因素的主成分进行SOH预测的贡献率,如表2所示。由表2可见,主成分1和2两者的贡献率之和为97.97%,故主要应用主成分1和2作为神经网络的输入参量,进行电池容量衰减的预测。主成分1和2的曲线如图10所示。

表2 不同主成分进行SOH预测的贡献率

Tab. 2 Contribution rate of different principal components for SOH prediction

主成分序号	贡献率
1	78.021 8
2	19.948 5
3	1.377 5
4	0.503 2
5	0.148 9

基于TCN算法对电池的容量进行预测,其预测结果如图11所示。由图11可看出,TCN算法能够较好地跟踪电池容量的衰减趋势,及预测老化过程中的电池容量波动,在较小的数据量下也获得了较准确的电池容量预测结果,其预测的RMSE为0.020 5。

为了进一步验证TCN算法的有效性,在相同的数据和约束下,使用TCN与BP、LSTM算法进行电池容量的预测,结果如图12所示。由图12可见,TCN算法对实际容量的跟踪效果最好,LSTM算法次之,BP算法最差。

表3给出了不同算法的SOH预测的RMSE。




图 10 主成分1和2曲线

Fig. 10 Principal component 1 and 2 curves

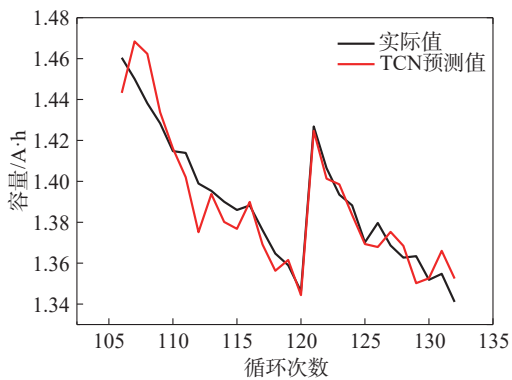


图 11 使用 TCN 进行电池容量的预测结果

Fig. 11 Battery capacity prediction results based on TCN

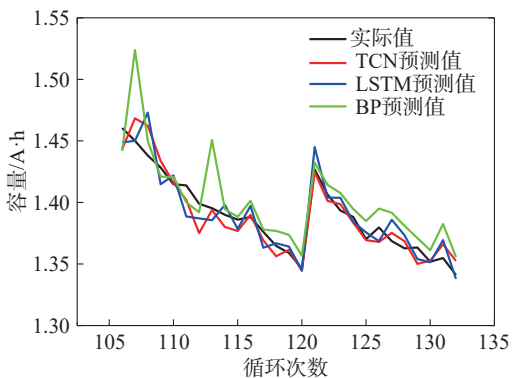


图 12 不同算法的电池容量预测结果

Fig. 12 Battery capacity prediction results of different algorithms

表 3 不同算法的 SOH 预测误差

Tab. 3 SOH prediction RMSE of different algorithms

算法	RMSE
TCN	0.020 5
LSTM	0.024 3
BP	0.042 4

由表3可见:LSTM算法的预测误差为0.024 3, BP算法的预测误差为0.042 4,在目前数据量较少情况下,TCN算法的预测误差比LSTM算法小得不多,

这是由于与LSTM、BP相比,TCN算法在时序序列预测的优势会在后期随着数据量的增加而有所体现,则TCN的预测精度会进一步提高。

2) RUL 预测

电池寿命分析中,对电池容量的评价可以反映电池的SOH,而对电池剩余循环次数的评价可以反映电池的RUL,两者对电池的健康程度均能进行不同形式的表征。但在实际使用过程中,电池存在容量再生现象,即电池会在不同的循环次数或时段出现容量相当的现象。如图3所示,在第45次循环和第59次循环时的电池容量相当,都在1.59 A·h附近,但两者之间相差14个循环;第100次循环和第126次循环时的电池容量相当,都在1.37 A·h附近,但两者相差了26个循环。因此,在不同循环次数或时段出现相当的电池容量,并不代表两个时刻电池的SOH相当,反而SOH可能差别很大。

由于电池的可用循环次数是固定的,随着使用次数的增加,其剩余循环次数逐渐减少,该过程是不可逆的,所以剩余循环次数更能精确地表征电池的寿命。为此,本文在电池容量的基础上,进一步分析电池剩余循环次数,利用循环时间、电压平均值、电压样本熵、温度样本熵、电流值,以及电池容量,来预测剩余循环次数。先对这6个特征因素进行降维,利用核主成分分析法求取各主成分进行RUL预测的贡献率,具体如表4所示。由表4可见,主成分1和2进行RUL预测的贡献率之和为98.17%,因此,选用主成分1和2作为输入,预测电池的剩余循环次数。

表 4 不同主成分进行 RUL 预测的贡献率

Tab. 4 Contribution rate of RUL prediction with different principal components

主成分序号	贡献率
1	81.549 530
2	16.629 080
3	1.163 062
4	0.439 057
5	0.143 293
6	0.075 969

对比TCN与LSTM、BP算法的RUL预测结果和误差,如图13和表5所示。由图13和表5可知,TCN算法能够很好地预测电池的RUL,其RMSE最低,为0.019 3。

因此,基于本文的TCN算法,先利用循环时间、电压平均值、电压样本熵、温度样本熵、电流值5个特征因素对电池容量进行预测,再对剩余循环次数RUL进行评估,可以更为全面地掌握电池的健康程度。

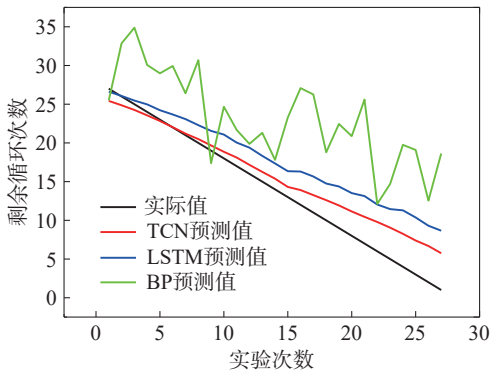


图 13 剩余循环次数预测结果

Fig. 13 RUL prediction results

表 5 不同算法的 RUL 预测的误差

Tab. 5 RUL prediction RMSE of different algorithms

算法	RMSE
TCN	0.019 3
LSTM	0.034 2
BP	0.079 9

5 结 论

本文基于 TCN 算法对电池的 SOH 和 RUL 联合估计进行了分析。主要结论如下。

1) 为了提高预测精度,在电压、电流和温度输入数据的基础上,衍生出 14 个特征因素,利用 KL 散度、皮尔逊相关系数和灰色关联度 3 种方法分析上述 14 个特征因素与容量的相关性,并与 TCN 算法的相关性分析结果进行对比,选取出影响电池容量的 5 个重要特征因素,即循环时间、电压平均值、电压样本熵、温度样本熵和电流值。

2) 利用核主成分分析法对 5 个输入特征因素进行降维,选取贡献率较大的主成分进行电池 SOH 预测,通过 TCN 和 LSTM、BP 算法对比分析得出 TCN 的预测误差 RMSE 最小,为 0.020 5。

3) 由于电池存在容量再生现象,在 5 个特征因素的基础上结合电池容量,进行 RUL 的预测,先利用核主成分分析法提取贡献率大的主成分,再通过 TCN 和 LSTM、BP 算法的对比分析可知,TCN 算法的评估精度最高,其 RMSE 仅为 0.019 3,从而验证了本文的 TCN 算法提高了电池寿命预测结果的精度和可信度。

深度神经网络虽然在处理非线性复杂问题方面具有独特优势,但其通常被看作黑盒模型,只能观察到模型的预测结果,而不能了解模型产生决策的原因,导致在涉及需要做出关键决策判断的领域或要求决策合规的应用中,会极大限制深度学习技术及系统的大范围推广。因此,进一步研究深度学习模型的可解释性就显得格外重要,可解释性有利于模型的使用

者更好地理解其优劣势,明确知识边界,更恰当地信任和使用模型来进行寿命评估。对模型的设计者而言,可解释性有利于优化和改进模型,避免其中的歧视和偏见。后续的研究将侧重于研究可解释神经网络在电池系统寿命评估的应用,为电池系统的智能运维提供技术支撑。

参考文献:

- [1] Liu Chun, Li Pai, Zhang Jinping, et al. Research of the role of energy storage system in power and energy balance of the new type power system[J/OL]. Power System Technology(2025-03-12)[2025-06-15]. <https://doi.org/10.13335/j.1000-3673.pst.2024.2070>. [刘纯, 李湃, 张金平, 等. 储能在新电力系统电力电量平衡中的作用研究[J/OL]. 电网技术(2025-03-12)[2025-06-15]. <https://doi.org/10.13335/j.1000-3673.pst.2024.2070>.]
- [2] Li Jianlin, Xiao Heng. Review on modeling of lithium-ion battery[J]. Energy Storage Science and Technology, 2022, 11(2):697-703. [李建林, 肖珩. 锂离子电池建模现状综述[J]. 储能科学与技术, 2022, 11(2):697-703.]
- [3] Sui Xin, He Shan, Vilsen S B, et al. A review of non-probabilistic machine learning-based state of health estimation techniques for Lithium-ion battery[J]. Applied Energy, 2021, 300:117346.
- [4] Zhang Cheng, Lu Wanlin, Zhang Dongqing, et al. Joint estimation of lithium battery states based on improved fuzzy entropy fusion weighting method with regulation factors[J/OL]. Transactions of China Electrotechnical Society(2025-04-15)[2025-06-15]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.242101>. [张程, 陆万林, 张东清, 等. 基于调节因子改进模糊熵融合加权法的锂电池状态联合估计[J/OL]. 电工技术学报(2025-04-15)[2025-06-15]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.242101>.]
- [5] Sun Yushu, Gong Yichun, Dong Liang, et al. Review of state estimation for battery energy storage systems[J]. Journal of Central South University(Science and Technology), 2024, 55(6):2320-2333. [孙玉树, 龚一菀, 董亮, 等. 电池储能系统状态估计综述[J]. 中南大学学报(自然科学版), 2024, 55(6):2320-2333.]
- [6] Khodadadi Sadabadi K, Jin Xin, 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] Gao Renjing, Lü Zhiqiang, Zhao Shuai, et al. Health state estimation of Li-ion batteries based on electrochemical model[J]. Transactions of Beijing Institute of Technology, 2022, 42(8):791-797. [高仁璟, 吕治强, 赵帅, 等. 基于电化学模型的锂离子电池健康状态估算[J]. 北京理工大学学报, 2022, 42(8):791-797.]
- [8] Bi Yalan, Yin Yilin, Choe S Y. Online state of health and ag-

- ing parameter estimation using a physics-based life model with a particle filter[J]. *Journal of Power Sources*, 2020, 47(6):228655.
- [9] Zhang Fengzhu, Zhang Zhiyu, Ma Wentao. SREKF based state of health estimation for lithium battery[J]. *Chinese Journal of Power Sources*, 2020, 44(5):740–743. [张凤珠, 张志禹, 马文涛. 基于SREKF的锂电池健康状态估计[J]. *电源技术*, 2020, 44(5):740–743.]
- [10] Ren Pu, Wang Shunli, He Mingfang, et al. State of health estimation of Li-ion battery based on dual calibration of internal resistance increasing and capacity fading[J]. *Energy Storage Science and Technology*, 2021, 10(2):738–743. [任璞, 王顺利, 何明芳, 等. 基于内阻增加和容量衰减双重标定的锂电池健康状态评估[J]. *储能科学与技术*, 2021, 10(2):738–743.]
- [11] Shi Gaoya, Chen Siqi, Yuan Hao, et al. Determination of optimal indicators based on statistical analysis for the state of health estimation of a lithium-ion battery[J]. *Frontiers in Energy Research*, 2021, 9:690266.
- [12] Chen Yi, Bai Yunfei, He Ying. Comparison of data-driven lithium battery state of health estimation methods[J]. *Energy Storage Science and Technology*, 2019, 8(6): 1204–1210. [陈翌, 白云飞, 何瑛. 数据驱动的锂电池健康状态估算方法比较[J]. *储能科学与技术*, 2019, 8(6):1204–1210.]
- [13] Liu Datong, Pang Jingyue, Zhou Jianbao, et al. Prognostics for state of health estimation of lithium-ion batteries based on combination Gaussian process functional regression[J]. *Microelectronics Reliability*, 2013, 53(6):832–839.
- [14] Chen Zewang, Zhang Songyuan, Shi Na, et al. Online state-of-health estimation of lithium-ion battery based on relevance vector machine with dynamic integration[J]. *Applied Soft Computing*, 2022, 129:109615.
- [15] Wang Xue, You Guodong, Fang Chengxin, et al. SOH estimation of lithium-ion battery based on IMOCS-BP neural network[J]. *Journal of Power Supply*, 2024, 22(1): 94–100. [王雪, 游国栋, 房成信, 等. 基于IMOCS-BP神经网络的锂离子电池SOH估计[J]. *电源学报*, 2024, 22(1):94–100.]
- [16] Veeraraghavan A, Adithya V, Bhave A, et al. Battery aging estimation with deep learning[C]//*Proceedings of the 2017 IEEE Transportation Electrification Conference*. Pune: IEEE, 2017:1–4.
- [17] Ren Lei, Zhao Li, Hong Sheng, et al. Remaining useful life prediction for lithium-ion battery: A deep learning approach[J]. *IEEE Access*, 2018, 6:50587–50598.
- [18] Hu Tianzhong, Yu Jianbo. Life prediction of lithium-ion batteries based on multiscale decomposition and deep learning[J]. *Journal of Zhejiang University(Engineering Science)*, 2019, 53(10):1852–1864. [胡天中, 余建波. 基于多尺度分解和深度学习的锂电池寿命预测[J]. *浙江大学学报(工学版)*, 2019, 53(10):1852–1864.]
- [19] Li Suyang, Chen Fuan. Lithium battery SOH prediction based on Bi-LSTM attention mechanism[J]. *Chinese Journal of Power Sources*, 2022, 46(7): 739–742. [李苏阳, 陈富安. 基于注意力机制的双向LSTM锂电池SOH估算模型[J]. *电源技术*, 2022, 46(7):739–742.]
- [20] Wu Pin, Sun Junwu, Chang Xuting, et al. Data-driven reduced order model with temporal convolutional neural network[J]. *Computer Methods in Applied Mechanics and Engineering*, 2020, 360:112766.
- [21] Li Zihao, Wu Wenchuan, Zhang Boming, et al. Kullback–Leibler divergence-based distributionally robust optimisation model for heat pump day-ahead operational schedule to improve PV integration[J]. *IET Generation, Transmission & Distribution*, 2018, 12(13):3136–3144.
- [22] Chen Zexi, Sun Yushu, Zhang Yan, et al. Research on energy storage optimal allocation considering complementarity of wind power and PV[J]. *Transactions of China Electrotechnical Society*, 2021, 36(Supp1):145–153. [陈泽西, 孙玉树, 张妍, 等. 考虑风光互补的储能优化配置研究[J]. *电工技术学报*, 2021, 36(增刊1):145–153.]
- [23] Chen Haiyan, Yang Zhenpeng, Li Xinjian, et al. Grey incidence analysis for factors influencing SOP of power battery[J]. *Chinese Journal of Power Sources*, 2019, 43(6): 1032–1033. [陈海燕, 杨振鹏, 李新建, 等. 影响动力电池输出功率因素的灰色关联分析[J]. *电源技术*, 2019, 43(6): 1032–1033.]
- [24] Bole B, Kulkarni C S, Daigle M. Adaptation of an electrochemistry-based Li-ion battery model to account for deterioration observed under randomized use[C]//*Proceedings of 2014 Annual Conference of the Prognostics and Health Management Society*. Texas:PHM Society, 2014:1–9.
- [25] Souza Filho J B O, Diniz P S R. Improving KPCA online extraction by orthonormalization in the feature space[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(4):1382–1387.

Battery Life Evaluation Method Based on Temporal Convolution Network

SUN Yushu^{1,2}, AN Juan³, HUANG Cunqiang³, ZHANG Shunzhen³, DANG Yanyang², PEI Wei¹, TANG Xisheng^{1*}

(1. Institute of Electrical Engineering, Chinese Academy of Sciences, Beijing 100190, China;

2. Tebian Electric Apparatus Stock Company Limited, Changji 831100, China;

3. State Grid Qinghai Electric Power Company Economics and Technology Research Institute, Xining 810008, China)

Abstract:

Objective To improve the technical economy of battery system applications, a temporal convolutional network (TCN) is employed to evaluate

battery life from two perspectives: State of health (SOH) and remaining useful life (RUL). SOH is typically quantified by capacity, while RUL is measured in terms of the remaining number of charge-discharge cycles.

Methods First, the TCN-based approach to battery life assessment is introduced. Compared to classical recurrent neural networks, TCN has the advantages of improved gradient stability, faster data processing, and reduced memory consumption. Next, 14 indirect health-related features are extracted from readily available battery data including time, voltage, current, and temperature. The relevance of each feature to capacity is assessed using three correlation techniques: KL divergence, Pearson correlation coefficient, and gray relational analysis. Additionally, a polling strategy is employed using the TCN: each feature is used individually for capacity prediction, and the mean of six prediction outcomes per feature is taken as the final correlation score. Correlation results from all four methods are compared. Although Pearson correlation and TCN-based analysis yield similar rankings, both focus primarily on the top features. Due to the different principles of these methods, their outcomes often diverge significantly. Therefore, TCN-derived results are considered the most reliable for identifying factors influencing capacity prediction. For lithium-ion battery data from NASA, five features with the greatest impact on SOH are identified (in descending order of importance): cycle time, average voltage, voltage sample entropy, temperature sample entropy, and current.

Results and Discussions To address redundancy caused by overlapping information among these features, Kernel principal component analysis (KPCA) is applied for dimensionality reduction. The contribution rates of principal components are calculated, and the top two principal components (PC1 and PC2) are selected as inputs for simulation to eliminate noise and improve computational efficiency. A comparative analysis of three prediction models including TCN, long short-term memory (LSTM) networks, and Backpropagation (BP) neural networks shows that the TCN achieves the lowest root mean square error (RMSE) of 0.019 3, indicating the highest predictive accuracy. Battery capacity regeneration can result in similar capacities at different numbers of cycles or times. When SOH is used to characterize battery life, significant errors will be introduced. In contrast, RUL will irreversibly decrease as the service time increases, which can provide a more reliable criterion for evaluation. To predict RUL, the same five key features (cycle time, average voltage, voltage sample entropy, temperature sample entropy, current) along with capacity are used. Six principal components are obtained through KPCA analysis, and PC1 and PC2 are also selected for prediction. Among the three models compared, the RMSE of TCN is lowest (0.019 3), which further proves its outstanding accuracy in RUL estimation.

Conclusions This study validates the effectiveness of TCN for battery life prediction. By evaluating both SOH and RUL, the proposed TCN-based framework provides a more accurate and robust assessment of battery health.

Key words: battery; temporal convolution network; kernel principal component analysis; state of health; remaining useful life

(编辑 赵 婧)

引用格式: Sun Yushu, An Juan, Huang Cunqiang, et al. Battery life evaluation method based on temporal convolution network [J]. *Advanced Engineering Sciences*, 2025, 57(4): 259–268. [孙玉树, 安娟, 黄存强, 等. 基于时间卷积网络的电池寿命评估方法[J]. *工程科学与技术*, 2025, 57(4): 259–268.]