

一种基于卷积运算和 LSTM 的锂离子电池健康状态估计方法

●林得巍 于跃* 曾东



[摘要] 由于锂离子电池内部的化学反应是不可观测的,锂离子电池的工作环境是恶劣、复杂的,目前锂离子电池的 SOH 估计仍存在较大误差。过大的 SOH 估计误差不仅对锂离子电池组的使用和寿命产生不利影响,还可能导致整个储能系统的崩溃。长短期记忆神经网络(LSTM)具有良好的泛化性,在时间序列问题上表现优秀,广泛应用于各种分类、回归、异常检测等实际问题中。但 LSTM 算法存在梯度爆炸、消失问题,且高度依赖数据关联性,导致估计精度、鲁棒性下降。因此,本文提出了一种新的基于卷积运算和 LSTM 算法的 CON-LSTM 算法。该方法利用卷积运算提取出更具差异性的数据特征,再由 LSTM 实现锂离子电池 SOH 的回归估计。文中设计了对比实验来测试 CON-LSTM 算法和 LSTM 算法估计锂离子电池 SOH 的效果。实验结果证明,采用 CON-LSTM 算法对锂电池的 SOH 估计在鲁棒性和精确度方面均优于传统的 LSTM 算法。

[关键词] 锂离子电池;健康状态;长短期记忆神经网络;卷积运算

锂 离子电池是广泛应用于电动汽车、新能源储能系统、移动设备储能系统中。锂离子电池的健康状态(State of Health, SOH)无法直接测量,只能通过测量相关参数如电压、电流、温度和内阻,使用模型、滤波技术或公式来进行估计。其中涉及到材料科学、电化学和数学等多个学科,是一项具有挑战性的任务。目前常用的估计方法主要分为基于传统模型的方法和数据驱动的方法。

基于传统模型的方法通常利用建立电化学模型、经验模型和等效电路模型来估计锂离子电池的 SOH,但该方法的估计精度受到模型准确性的制约,且该方法的通用性较差。数据驱动的方法利用海量数据构建学习模型,再利用训练好的模型估计锂离子电池的 SOH。数据驱动的方法不需要建立准确的模型,具有很好的方法泛化性,但是其估计精度受到数据质量影响较大。随着传感器数量的增加,大数据应用的普及,数据驱动方法逐渐成为主流方法。

Q 锂电池 SOH 估计

根据已有研究,锂离子电池 SOH 的概念可以用电池容量法进行描述,其定义如下:

$$SOH = \frac{C_{nom}}{C_{new}} \times 100\% \quad (1)$$

其中, C_{nom} 表示电池的当前最大容量, C_{new} 为电池的初

始最大容量。

Q 长短期记忆神经网络

长短期记忆神经网络(Long Short-Term Memory, LSTM)包括用于实现信息传递的记忆单元和输入门、遗忘门、输出门这三个功能门。通过输入门处理输入信息,实现废弃信息的丢弃和新信息的增加。遗忘门通过处理上一时刻的信息和历史信息,根据需要进行丢弃或遗忘。最终通过输出门来实现模型的输出。网络中利用反向传播求取各个参数的梯度,进行参数值的更新、迭代,实现整个网络模型的构建。LSTM 的网络结构如图 1 所示,算法公式见公式 2。




图 1 LSTM 网络的网络结构图

$$\begin{cases} f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \\ i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \\ o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \\ c_t = f_t c_{t-1} + i_t \tanh(W_c x_t + U_c h_{t-1} + b_c) \\ h_t = o_t \tanh(c_t) \end{cases} \quad (2)$$

公式(2)中, 锂离子电池的特征值输入 $X = \{x_1, x_2, x_3, \dots, x_t\}$ 为输入层, $H = \{h_1, h_2, h_3, \dots, h_t\}$ 为隐藏层, f 为网络遗忘门输出, i 为输入门输出, o 为输出门输出, c 为神经元输出, U_i 、 W_i 、 U_f 、 W_f 、 U_o 、 W_o 分别为输入门、遗忘门及输出门的权重系数, 为偏置系数。通过公式(2)可以说明 LSTM 使用门控系统对信息进行选择性记忆及遗忘, 拥有了存储历史信息的能力。

LSTM 在传播过程中利用单元存储器、输入门、遗忘门、输出门对 LSTM 单元中信息的遗忘、更新进行选择, 且该算法的梯度在传播过程中可以不变化。因此, LSTM 网络的估计精度受到求导的影响较小。然而 LSTM 网络模型并未完全解决网络中存在的梯度下降和梯度爆炸问题, 同时 LSTM 算法需要输出与时间序列及输入特征向量与输出结果有较好的关联性, 否则会导致模型迭代次数增加, 估计精度下降。为了解决上述问题并提升模型的估计精度,

本文提出了一种用于进行锂离子电池 SOH 估计的 CON-LSTM 算法。

结合卷积运算的 LSTM 神经网络锂电池 SOH 估计

本文采用卷积运算作为 LSTM 神经网络特征提取算法对 SOH 预测输入数据进行处理, 从而提取输入数据的特征性, 减少了 LSTM 运算量的同时也突出了数据的特征化。

(一) 卷积运算

在 LSTM 特征提取的过程中加入卷积运算可以准确提取数据不同维度的空间特征。LSTM 神经网络输入向量矩阵 $X(i, j)$, 卷积核 $w(m, n)$ 则卷积运算后的结果为 $s(i, j)$, 卷积运算的基本原理如公式 3 所示。

$$s(i, j) = (X * W)(i, j) = \sum_m \sum_n x(i-m, j-n) w(m, n) \quad (3)$$

(二) CON-LSTM 网络结构构建

将锂离子电池预测所需特征向量首先进行数据预处理, 将数据预处理后的数据进行卷积运算, 为更有效的突出数据的特征性, 本文采用均值卷积核的形式。再将卷积运算后的结果输入至 LSTM 神经网络的估计结构中, 文中所提出的 CON-LSTM 网络结构图如图 2 所示, 网络结构参数如表 1 所示。




图 2 CON-LSTM 网络结构图

表 1 CON-LSTM 网络结构参数

序号	名称	数值
1	卷积核	均值卷积核
2	LSTM 输入数	9
3	LSTM 网络层数	3
4	每层神经元	10
5	全连接神经元	10
6	循环次数	1000
7	优化算法	Adam
8	学习率	0.1
9	批处理	10

实验分析与验证

(一) 数据集的选取及处理

实验采用的是 NASA 开源锂离子电池数据集。该数据集包含了 18650 电池在不同工况和循环次数下的电池数据。本文采用 B0005-B0007 数据集作为估计训练集, B0018 数据集作为测试数据集。

(二) 特征向量的选取

端电压随时间的变化与锂离子电池 SOH 的变化具有一定程度的关联性。由于锂离子电池在放电初期存在显著的电压波动, 因此文中选择将放电过程中的前 81 次记录的端电压作为特征向量。

(三) 估计模型流程

步骤 1: 对输入特征向量进行归一化。

步骤 2: 使用均值卷积核对归一化后的特征向量进行卷积运算, 生成新数据作为 LSTM 模型的训练输入。

步骤 3: 初始化 LSTM 的三个功能门。

步骤 4: 更新 LSTM 的三个功能门数据, 迭代, 直到达

到预设的迭代次数。

步骤 5: 利用迭代输出的三个功能门参数构建 CON-LSTM 估计模型, 用于锂离子电池的 SOH 估计。

(四) 结果对比及分析

为了更好地研究 SOH 估计算法, 本研究还使用了 LSTM 算法对相同的数据进行预测。我们将 CON-LSTM 的预测结果与真实的 SOH 值以及 LSTM 算法的估计结果进行对比, 如图 3 所示为算法的预测结果, 而图 4 展示了算法的预测误差图。




图 3 算法预测结果图




图 4 算法预测误差图

从图 3 和图 4 的结果可以看出, 本文提出的 CON-LSTM 算法估计电池 SOH 的最大误差约为 4%, 多数样本误差在 1%~2% 之间, 均方根误差不足 0.5%。而 LSTM 算法的最大结果误差达到 8%, 大部分误差超过 2%。可见 CON-LSTM 算法比 LSTM 算法的估计精度高。表 2 中的结果显示, 使用 CON-LSTM 算法对电池 SOH 进行回归预测得到的平均绝对误差 AAE 为 0.0099, 均方根误差 RMSE 为 0.0136, 最大绝对误差 MAE 为 0.0407。而使用 LSTM 算法对电池 SOH 进行回归预测得到的 AAE 为 0.0209, RMSE 为 0.0277, MAE 为 0.0796。可见 CON-LSTM 算法的预测结果具有很好的鲁棒性, 而 LSTM 算法的整体误差波动较大。综合上述结果, 我们可以看出, 本文提出的 CON-LSTM 算法具有更好的精度和鲁棒性, 其对电池 SOH 的估计结果更加准确可靠。

表 2 预测结果误差对比表

	CON-LSTM(本文)	LSTM
AAE	0.0099	0.0209
RMSE	0.0136	0.0277
MAE	0.0407	0.0796

Q 结束语

针对 LSTM 算法存在的估计精度低、鲁棒性差问题, 文中提出了一种新的基于卷积运算和 LSTM 算法的 CON-LSTM 算法。该算法采用了卷积运算对原始数据进行预处理, 使得模型可以更好地捕获数据特征, 提高了模型的精度和鲁棒性。同时, CON-LSTM 算法还使用了 LSTM 网络结构, 可以有效解决时间序列数据中的长期依赖问题, 提高了模型在时间序列预测中的适用性。利用 NASA 数据集设计了对比实验。实验结果表明, 相较于传统的 LSTM 算法, CON-LSTM 算法在锂离子电池的 SOH 预测方面表现出更好的模型准确性和更强的抗干扰能力, 证明了 CON-LSTM 算法的优越性。随着电池运行工况的日益复杂和储能系统安全要求的不断提升, 团队后续将集中于研究复杂工况下锂离子电池 SOH 估计方法。

参考文献

- [1] 罗伟林, 张立强, 吕超, 等. 锂离子电池寿命预测国外研究现状综述[J]. 电源学报, 2013, 11(01): 140-144.
- [2] 李肖辉, 陈北海, 古领先, 等. 锂离子电池健康状态评估方法研究进展[J]. 电源技术, 2021, 45(06): 818-822.
- [3] 张吉昂. 基于模型和数据驱动融合方法的锂离子电池状态估计研究[D]. 天津: 天津大学, 2021.

基金项目:

湛江市非资助科技攻关计划项目, 项目名称: 多工况下锂离子电池健康状态估计方法研究, 项目编号: 2022B01178。

作者简介:

林得巍(1990—), 男, 汉族, 黑龙江省佳木斯人, 硕士, 工程师, 广东粤电湛江风力发电有限公司, 研究方向: 设备故障分析、储能技术及应用。

曾东(1985—), 男, 汉族, 湖北武汉人, 硕士, 高级工程师, 广东粤电湛江风力发电有限公司, 研究方向: 海上风电防护措施。

通信作者:

于跃(1991—), 女, 汉族, 吉林通化人, 硕士, 讲师, 广东海洋大学电子与信息工程学院, 研究方向: 储能技术、故障诊断技术、智能控制技术。