



基于健康特征参数的 CNN-LSTM&GRU 组合锂电池 SOH 估计

戴彦文, 于艾清

(上海电力大学电气工程学院, 上海 200090)

摘 要: 锂电池健康状态(state of health, SOH)是表征电池实际寿命的关键性参数。SOH 不可直接测量, 为进一步提升锂电池 SOH 估计的精度, 提出一种基于健康特征参数的 CNN-LSTM 与 GRU 组合 SOH 估计方法。首先, 从锂电池充电曲线中初步选取健康特征参数, 并通过 Spearman 相关系数提取健康特征, 具体包括恒定电流充电时长、恒定电压充电时长、恒定电流充电时长与恒定电压充电时长的比值以及恒定电流充电阶段温度曲线在时间上的积分与恒定电压充电阶段温度曲线在时间上的积分。其次, 采用卷积神经网络(convolutional neural network, CNN)提取健康特征的局部特征, 长短期神经网络(long short-term memory, LSTM)挖掘数据时间序列特征, 构造 CNN-LSTM 融合神经网络。然后, 将 CNN-LSTM 网络与门控循环单元(gated recurrent unit, GRU)通过自适应权重因子构成组合 SOH 估计模型。最后, 以 NASA 锂电池数据集 5 号、6 号、7 号、18 号电池参数为依据进行验证。实验结果表明, 所提组合模型相比于 CNN-LSTM、LSTM 和 GRU 此类单一模型, 平均绝对误差分别降低了 71.8%、62.4%、22.6%, 均方根分别降低了 84.1%、79.8%、44.3%。

关键词: 锂离子电池; 健康状态; 健康特征; CNN-LSTM; GRU

doi: 10.19799/j.cnki.2095-4239.2021.0623

中图分类号: TM 911

文献标志码: A

文章编号: 2095-4239 (2022) 05-1641-09

Combined CNN-LSTM and GRU based health feature parameters for lithium-ion batteries SOH estimation

DAI Yanwen, YU Aiqing

(College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: The State of Health (SOH) of lithium batteries is a key parameter to characterize the actual useful life. SOH is not directly measurable, and a combined CNN-LSTM and GRU estimation method based on health feature parameters is proposed to further improve the accuracy of SOH estimation. Firstly, the health feature parameters are initially selected from the Li-ion battery charging curve, and the health features are extracted by Spearman correlation coefficient. Secondly, Convolutional Neural Network (CNN) is used to extract local features of health features and Long Short-Term Memory (LSTM) to mine data time series features to construct a CNN-LSTM fusion neural network. Subsequently, the CNN-LSTM and the Gated Recurrent Unit (GRU) are combined to form a combined SOH estimation model by adaptive weighting factors. Finally, the validation is based on the NASA lithium battery dataset 5, 6, 7, and 18 battery parameters. The experimental results show that the estimation accuracy of the proposed combined model is better than that of the single model, and the estimation error is further reduced.

收稿日期: 2021-11-23; 修改稿日期: 2021-12-08。

基金项目: 上海绿色能源并网工程技术研究中心项目 (13DZ2251900)。

第一作者及通讯联系人: 戴彦文 (1997—), 男, 硕士研究生, 主要研

究方向为基于数据驱动的锂电池健康状态预测, E-mail: 1209742263@qq.com。

Key words: lithium-ion battery; state of health; health feature; CNN-LSTM; GRU

能源危机和环境问题日益严重,世界各国政府都在积极推动电动汽车(electric vehicle, EV)的发展,以减少碳排放和化石能源消耗^[1-2]。锂离子电池因其能量密度和输出电压高、无记忆效应、自放电率低、使用寿命长等优点,已成为电动汽车的首选电池类型^[3-4]。然而,锂离子电池的老化现象是不可避免的。当电池的退化积累到一定程度时,电动汽车的性能就会大大下降,容量减小是电池老化过程中最主要的现象之一^[5]。因此,为了确保动力电池的安全运行,需对电池的老化程度作出准确估计。其中,健康状态(state of health, SOH)是表征电池老化程度的关键性指标^[6]。通常情况下认为当SOH降至70%~80%时,电池需要更换^[7]。

SOH无法通过测量设备直接获得,因此,如何准确评估真实车辆在复杂多变的运行条件下的电池老化情况,成为实现电池精细化管理的关键。目前,电池SOH的估计方法主要可分为基于机理模型^[8-10]的方法和基于数据驱动^[11-13]的方法。前者通过建立电池的寿命退化模型来分析电池内部材料变化与SOH之间的对应关系,此类方法依靠建立模型的准确性,且计算量大,耗费时间长,不适用于SOH的实时在线测量。后者则是通过数据分析挖掘可测量数据与电池寿命之间的潜在关系,实现SOH的间接测量,不需要特定的机理模型且具备更广的适用性。

在各种数据驱动方法中,由于神经网络具有深度挖掘数据间非线性关系的优势,在电池寿命预测领域受到了广泛关注。其中,长短期记忆网络(long short-term memory, LSTM)解决了递归神经网络(recursive neural network, RNN)本身结构存在的梯度消失与梯度爆炸问题,在电池寿命预测领域已取得了较为满意的结果,但单一模型的数据驱动方法的泛化能力受到已有电池数据量的影响,其预测精度以及鲁棒性仍较差。

为进一步提升锂电池SOH预测精度,本文提出一种基于健康特征参数的CNN-LSTM组合估计方法。由于SOH难以直接测量,首先采用Spearman相关系数从电池充电阶段电压、电流及温度曲线中提取健康特征参数。然后,利用卷积神经网络(convolutional neural network, CNN)提取输入参

数的局部特征,并将局部特征以时间序列方式传递至LSTM,构建CNN-LSTM融合模型以深度挖掘健康特征与SOH之间的潜在关系。针对单一模型难以取得最优估计结果的问题,通过自适应权重将CNN-LSTM与门控循环单元(gated recurrent unit, GRU)联合,构建多模型组合预测模型,从而实现锂电池SOH的准确估计。

1 电池数据与健康特征提取

电池的可用容量能够直接反映电池的老化程度,但很难找到一个可直接测得的物理量来判断当前电池的容量,而根据电池充电过程中电压、电流以及电池表面温度的变化,可间接得到电池的可用容量。

1.1 电池数据来源

本文采用NASA锂电池数据集^[14]研究电池的健康状态。以5号、6号、7号和18号电池参数为依据,观察在室温为24℃时电池老化对电池内部各参数的影响,主要参数包括充电电压、充电电流、电池表面温度。电池充电过程包括恒定电流充电和恒定电压充电两个阶段,即先以1.5 A的恒定电流模式充电至电池电压达到4.2 V,再以恒定电压模式充电至电池电流降至20 mA。电池的充电电压、充电电流曲线与电池表面温度曲线分别如图1和图2所示。




图1 锂电池充电电压与充电电流曲线

Fig. 1 Charging voltage and charging current curve of Lithium-ion battery

1.2 健康特征提取

在所提NASA数据集中,每一次充放电循环过程中仅给出一个可用容量值,因此本文以每一次循环为单位,提取健康特征进行SOH估算研究。

随着电池老化程度的增加,恒定电流充电时间




图2 锂电池充电过程中表面温度变化曲线

Fig. 2 Surface temperature change curve of Lithium-ion battery charging

缩短, 恒定电压充电阶段电流的变化速率逐渐降低, 导致恒定电压阶段的充电时间逐渐增加^[15-16]。除了上述特点外, 电池温度也是其退化的重要指标。电化学反应速率和内阻均被认为是反映电池恶化的重要指标, 但在锂离子电池的实际应用中难以得到有效的测量, 因此温度是唯一可以掌握的关键

参数^[17]。因此, 本文拟提取的健康特征具体包括: 恒定电流充电时长 T_{cc} 与恒定电压充电时长 T_{cv} , 两者的比值 T_{cc}/T_{cv} 以及总充电时长 T_c ; 恒定电流充电阶段温度平均值 A_{cc} 与恒定电压充电阶段温度平均值 A_{cv} ; 恒定电流充电阶段温度曲线在时间上的积分 F_{cc} , 恒定电压充电阶段温度曲线在时间上的积分 F_{cv} 。

为进一步量化上述所提健康特征与电池 SOH 之间的相关程度, 采用统计学中 Spearman 相关系数计算各特征与 SOH 之间的相关性。其计算公式和计算结果分别如式(1)和表 1 所示。

$$\text{Spearman} = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_i (x_i - \bar{x})^2} \sqrt{\sum_i (y_i - \bar{y})^2}} \quad (1)$$

式中, x 、 y 为样本; \bar{x} 、 \bar{y} 分别为样本 x 和 y 的均值。

表1 Spearman 相关系数计算结果

Table 1 Calculation of Spearman correlation coefficient

健康特征	T_{cc}	T_{cv}	T_{cc}/T_{cv}	T_c	A_{cc}	A_{cv}	F_{cc}	F_{cv}
Spearman	0.9573	-0.8917	0.9465	-0.2389	-0.3191	-0.0189	0.9515	-0.8735

Spearman 相关系数绝对值越大, 代表两者之间相关性越高^[18]。相关系数大于 0 代表该健康特征与可用容量正相关, 反之则负相关。选择相关系数绝对值大于 0.85 的健康特征作为 SOH 预测的输入参数, 即 5 个健康特征: T_{cc} 、 T_{cv} 、 T_{cc}/T_{cv} 、 F_{cc} 和 F_{cv} 。

2 CNN-LSTM 与 GRU 组合 SOH 估计模型

2.1 CNN-LSTM

2.1.1 卷积神经网络

卷积神经网络(convolutional neural network, CNN)是一种由输入层、卷积层、池化层、全连接层和输出层组成的多层监督学习神经网络^[19]。由于 CNN 引入了卷积运算, 可有效提高数据运算速度。根据卷积运算维度的不同, 可以分为一维 CNN、二维 CNN 和三维 CNN。一维 CNN 主要用于序列数据处理, 二维 CNN 常用于图像和文本识别, 三维 CNN 主要用于医学图像和视频数据识别。因此, 本文采用一维 CNN。一维卷积时间序列的特征提取公式为

$$Y = \sigma(W \cdot X + b) \quad (2)$$

式中, Y 为提取的特征; σ 为 sigmoid 激活函数; W 为权重矩阵; X 为时间序列; b 为偏置向量。

2.1.2 长短期记忆网络

长短期记忆网络(long short-term memory, LSTM)是循环神经网络的一种变体结构, 通过将存储器单元添加到隐藏层中, 以控制时间序列数据的存储器信息。LSTM 引入门控制结构, 通过控制输入门、遗忘门、输出门实现信息在隐藏层不同单元之间的传输, 从而控制先前信息和当前信息的记忆和遗忘程度^[20]。其中, 输入门决定当前时刻保存至单元状态的数据量, 遗忘门决定上一时刻的单元状态有多少需要保留到当前时刻, 输出门则控制单元状态输出多少信息。与传统 RNN 相比, LSTM 具有长期记忆函数, 可以避免其梯度消失问题。LSTM 网络的结构如图 3 所示。

其中, 主要计算公式如式(3)~(9)所示。

$$f(t) = \sigma\{W_f \cdot [H(t-1), x(t)] + b_f\} \quad (3)$$

$$i(t) = \sigma\{W_i \cdot [H(t-1), x(t)] + b_i\} \quad (4)$$

$$\tilde{C}(t) = \tanh\{W_c \cdot [H(t-1), x(t)] + b_c\} \quad (5)$$

$$C(t) = f(t) * C(t-1) + i(t) * \tilde{C}(t) \quad (6)$$

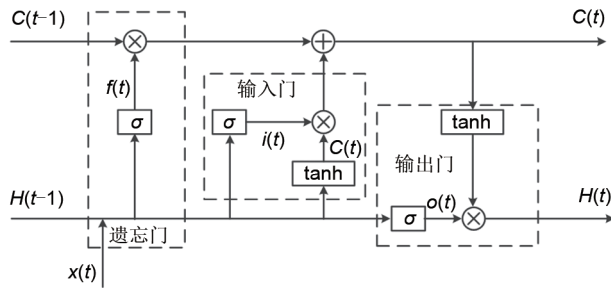


图3 LSTM网络结构

Fig. 3 Network structure of LSTM

$$o(t) = \sigma\{W_o \cdot [H(t-1), x(t)] + b_o\} \quad (7)$$

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (9)$$

式中, σ 为 sigmoid 激活函数, 其输出值在 0 到 1 之间, 0 表示“所有信息不允许通过”, 1 表示“所有都通过”。 W_f 、 W_i 、 W_c 和 W_o 为输入权值, b_f 、 b_i 、 b_c 和 b_o 为偏置权值, t 表示当前时间状态, $t-1$ 为前一时间状态, x 表示输入; H 表示输出; C 为单元状态; \tilde{C} 为新的单元状态。

2.1.3 CNN-LSTM网络结构

结合 CNN 与 LSTM 网络结构的优点, 将两者融合构成 CNN-LSTM 深度学习模型, 如图 4 所示。首先, 通过 CNN 模型的卷积层(convolution layer)和池化层(pooling layer)实现提取输入数据的特征、抽象信息得到特征数据, 再经由 Flatten 层传递至 LSTM 网络。其中, 卷积与池化过程能够有效降低输入数据的复杂性, 防止过拟合现象出现。利用 LSTM 的遗忘门和输出门, 可实现关联数据信息的筛选和更新。




图4 CNN-LSTM网络结构

Fig. 4 Network structure of CNN-LSTM

2.2 门控循环单元网络

门控循环单元网络(gated recurrent unit, GRU)为 LSTM 的一种变体结构, GRU 将 LSTM 中的输入门和遗忘门合并为更新门, 并加入了细胞状态和隐

藏状态^[21]。GRU 与 LSTM 相比, GRU 神经网络通过将三个门简化为更新门和重置门, 减少了计算过程中所需的参数数量, 相应地缩短了训练所需的时间, 加快收敛速度。GRU 简要结构如图 5 所示, 其计算公式如式(10)~(13)所示

$$z(t) = \sigma\{W_z \cdot [H(t-1), x(t)]\} \quad (10)$$

$$r(t) = \sigma\{W_r \cdot [H(t-1), x(t)]\} \quad (11)$$

$$\tilde{H}(t) = \tanh\{W_{\tilde{H}} \cdot [r(t) \times H(t-1), x(t)]\} \quad (12)$$

$$H(t) = [1 - z(t)] \times H(t-1) + z(t) \times \tilde{H}(t) \quad (13)$$

式中, $z(t)$ 、 $r(t)$ 分别为重置门和更新门的隐状态; $H(t)$ 为输出候选集; W_z 、 W_r 和 $W_{\tilde{H}}$ 分别为重置门、更新门和输出候选集的权值。

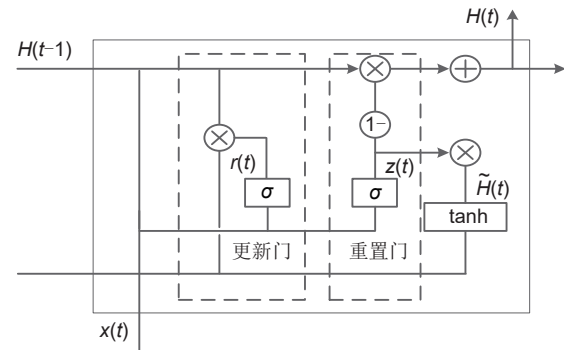


图5 GRU网络结构

Fig. 5 Network structure of GRU

2.3 基于自适应权重的CNN-LSTM与GRU组合模型

结合 CNN-LSTM 与 GRU 各自的优点, 建立 CNN-LSTM 与 GRU 组合模型, 以提高对 SOH 的估计精度。首先, 由于 LSTM 不能挖掘非连续数据之间的潜在联系, 在 LSTM 网络前加入 CNN 提取电池数据的局部特征。然后, 分别采用 CNN-LSTM 网络与 GRU 网络进行并行 SOH 估计, 通过自适应权重因子将 CNN-LSTM 与 GRU 模型进行组合, 以进一步提升 SOH 的估计精度。

根据所提取的健康特征参数, 将 $\mathbf{x}_m = [x_i^{T_{cc}}, x_i^{T_{cv}}, x_i^{T_{cc}/T_{cv}}, x_i^{F_{cc}}, x_i^{F_{cv}}]$ 作为 CNN-LSTM 与 GRU 组合模型的输入。其中, \mathbf{x}_m 为第 i 次循环充电阶段数据提取的健康特征。 $\mathbf{y}_i = [y_1^{[i]}, y_2^{[i]}, \dots, y_{n-1}^{[i]}, y_n^{[i]}]$ 为 CNN-LSTM 网络的输出, $\mathbf{y}_j = [y_1^{[j]}, y_2^{[j]}, \dots, y_{n-1}^{[j]}, y_n^{[j]}]$ 为 GRU 网络的输出。通过 dense 层对 \mathbf{y}_i 、 \mathbf{y}_j 分别赋予权重 ω_1 和 ω_2 , 其中 $\omega_1 + \omega_2 = 1$; 再通过 Add 层将两者配权后的输出 \mathbf{y}_{cl} 、 \mathbf{y}_g 线性叠加得到最终输出

结果 Y 。CNN-LSTM 与 GRU 组合模型具体过程如图6所示。

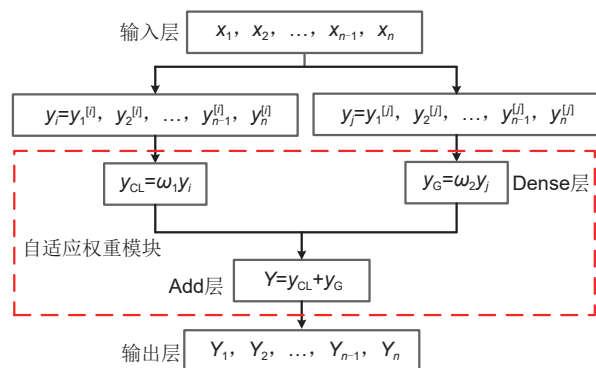


图6 CNN-LSTM&GRU组合模型结构
Fig. 6 Combined model of CNN-LSTM&GRU

3 锂电池 SOH 估计方法

3.1 数据处理

在测量电池充电阶段数据时, 由于测量设备本身存在的噪声影响, 所测数据不可避免地存在异常值。为提升所提组合模型的精度, 采用 Boxplot 法筛选异常数据, 进一步提升数据挖掘潜力^[22]。其中, 异常值采用四分位数和四分位距判定, 设定小于 $Q_1 - 1.5I_{QR}$ 和大于 $Q_3 + 1.5I_{QR}$ 的数据为异常数据^[23], 如式(14)所示。

$$[d_{lower}, d_{upper}] = [Q_1 - 1.5I_{QR}, Q_3 + 1.5I_{QR}] \quad (14)$$

式中, d_{lower} 、 d_{upper} 为异常数据边界; Q_1 、 Q_3 分别为电池充电数据的第一和第三分位数; I_{QR} 为四分位距。

在识别出电池异常数据后, 采用插值法覆盖异常数据, 实现数据的异常值修正。计算公式如式(15)所示。

$$d_{amend} = \frac{d_{t-1} + d_{t+1}}{2} \quad (15)$$

式中, d_{amend} 为异常数据修正值; d_{t-1} 、 d_{t+1} 分别为 t 时刻上一时刻和下一时刻电池数据。

电池各健康特征量纲不同, 为提高所提模型的收敛速度, 采用 min-max 标准化对各健康特征进行归一化处理

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (16)$$

式中, x' 为归一化后的健康特征; x_{min} 、 x_{max} 为健康特征的最值。

3.2 锂电池 SOH 估计方法

SOH 整体估计流程如图7所示。首先, 对电池充电电压、充电电流、电池表面温度数据进行异常数据筛选与替换, 通过 Spearman 相关系数提取健康特征参数, 并归一化处理; 然后, 将归一化后的健康特征参数作为输入分别输入 CNN-LSTM 网络和 GRU 网络, 两者并行运行, 输出结果通过自适应权重模块线性相加, 最终实现 SOH 估计。

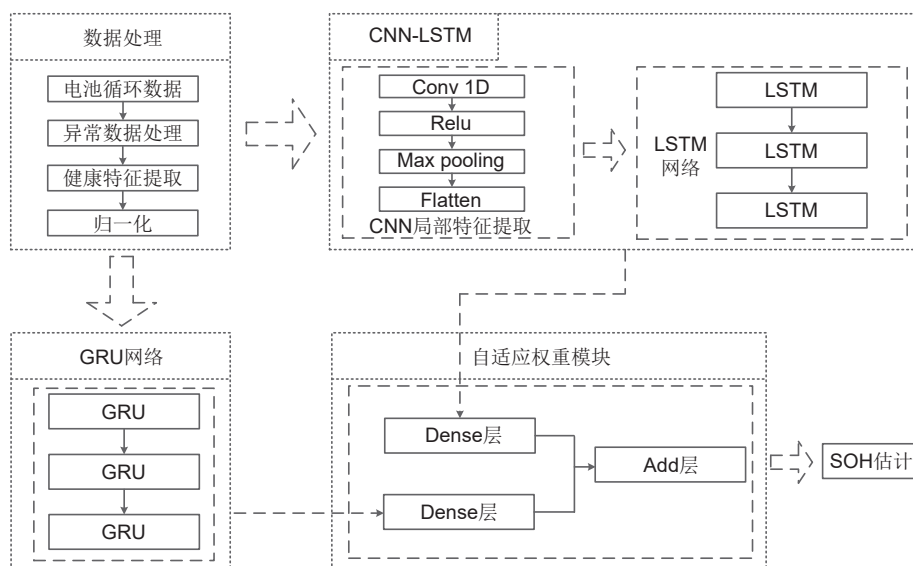


图7 SOH估计整体流程
Fig. 7 Flowchart of SOH estimation

4 算例分析

为验证所提 CNN-LSTM&GRU 组合模型对于提升锂电池 SOH 估计精度的可行性, 采用 NASA 数据集作为仿真数据。其中, 电池 B5-B7 循环次数为 168 次, 电池 B18 循环次数为 132 次, 将 4 块电池的前 80 次循环周期数据作为训练集^[24]。同时, 四种方法的参数设置如下: CNN 卷积核个数为 16, 大小为 2; LSTM 输入层的时间步长为 10, 数据的

维度为 5, 中间隐藏的神经元个数为 256, Dropout 层参数设置为 0.3, 最大训练次数为 1000; GRU 网络模块初始参数设置为 1 层 GRU, 神经元数目为 16, 失活系数为 0.02。

在 MATLAB 仿真环境中, 分别采用 CNN-LSTM&GRU、CNN-LSTM、LSTM 和 GRU 对锂电池的 SOH 进行估计, 结果如图 8 所示。测试集中电池容量预测值和真实值间误差的绝对值, 如图 9 所示。




图8 四种算法锂电池SOH预测结果

Fig. 8 Lithium batteries SOH estimation results for four algorithms

由图 8 和图 9 分析对比可知, 经上述四种算法学习训练, 相比于传统 LSTM、GRU、CNN-LSTM, 采用 CNN-LSTM&GRU 具有更优的跟踪效果, 有效提升了锂电池 SOH 的估计精度。

基于 CNN-LSTM&GRU、CNN-LSTM、LSTM 和 GRU 四种算法的估计结果如表 2 所示。表 2 中, E_{SOH} 为电池 SOH 的估计值, E_{r} 为预测误差的绝对值。当电池的容量衰退至失效阈值时, 实际所经历的循环次数和所预测的循环次数之间的误差定义为 E_{Er} , 即

$$E_{\text{Er}} = \frac{|E_{\text{SOH}} - R_{\text{SOH}}|}{R_{\text{SOH}}} \times 100\% \quad (17)$$

式中, R_{SOH} 为电池 SOH 真实值。

由表 2 可知, 相比于传统 LSTM、GRU、CNN-LSTM, CNN-LSTM&GRU 所得到的 E_{r} 和 E_{Er} 值更小。例如, 对于 B5 电池, CNN-LSTM 对应的 E_{r} 、 E_{Er} 分别为 3 和 9.7%; LSTM 和 GRU 对应的 E_{r} 、 E_{Er} 均为 5 和 16.1%; 而 CNN-LSTM&GRU 对应的 E_{r} 、 E_{Er} 均为 0。同时由表 2 可见, CNN-LSTM 的估计误差在 3 个循环周期内, LSTM 和 GRU 的估计




图9 四种算法锂电池 SOH 预测误差对比
Fig. 9 Lithium batteries SOH estimation error for four algorithms

表2 四种方法的 SOH 估计结果

Table 2 SOH estimation results for the four methods

型号	预测起点	SOH	CNN-LSTM&GRU			CNN-LSTM			LSTM			GRU		
			E_{SOH}	E_{tr}	$E_{E_r}/\%$	E_{SOH}	E_{tr}	$E_{E_r}/\%$	E_{SOH}	E_{tr}	$E_{E_r}/\%$	E_{SOH}	E_{tr}	$E_{E_r}/\%$
B5	80	31	31	0	0	28	3	9.7	26	5	16.1	26	5	16.1
B6	80	19	18	1	5.2	16	3	15.7	14	5	26.3	15	4	21.1
B7	80	66	67	1	1.5	64	2	3.0	62	4	6.1	62	4	6.1
B18	80	32	33	1	3.1	29	3	9.4	24	8	25.0	27	5	15.6

误差分别在 8 个和 5 个循环周期内，而文中采用的 CNN-LSTM&GRU 的估计误差在 1 个循环周期内。综上分析可知，基于 CNN-LSTM&GRU 的锂电池 RUL 估计精度更高。

为了进一步对比分析四种算法估计的精确度，本文采用文献[25]中平均绝对误差(mean absolute

error, MAE) 和均方根误差(root mean square error, RMSE, RMSE)进行对比分析，结果如表 3 所示。

由表 3 可见，文中所提组合估计方法相较于传统 LSTM、GRU 和 CNN-LSTM 单一估计方法，具有更小的估计误差。例如，对于 B5 号电池，文中

表3 四种方法的 SOH 估计误差

Table 3 SOH estimation error for the four methods

型号	预测起点	RUL	CNN-LSTM&GRU		CNN-LSTM		LSTM		GRU	
			MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
B5	80	31	0.0096	0.0152	0.0124	0.0273	0.0341	0.0957	0.0255	0.0755
B6	80	19	0.0332	0.0390	0.0418	0.0624	0.0502	0.0566	0.0752	0.1038
B7	80	66	0.0162	0.0212	0.0426	0.0468	0.0681	0.0850	0.0470	0.0569
B18	80	32	0.0260	0.0322	0.0387	0.0742	0.1038	0.1122	0.0753	0.0900

所提 CNN-LSTM&GRU 相比于传统 LSTM、GRU 和 CNN-LSTM, MAE 分别降低了 71.8%、62.4%、22.6%; RMSE 分别降低了 84.1%、79.8%、44.3%。对于电池组 B6、B7 和 B18, 基于 CNN-LSTM&GRU 模型得到的 MAE 和 RMSE 的值也均小于其余三种方法。因此通过对比分析可知, 文中所提基于 CNN-LSTM 的预测方法具有更高的预测精度。

3 结 论

为进一步提升锂离子电池 SOH 的估计精度, 提出一种基于健康特征参数的 CNN-LSTM&GRU 组合估计方法。估计结果表明, 该方法相较于 CNN-LSTM、LSTM 和 GRU 单一模型, 具有更高的精度, 还具有以下特点。

(1) 采用 Spearman 相关系数提取与电池 SOH 相关度高的健康特征参数, 可有效减小输入数据的复杂度, 提升运行效率。

(2) 将 CNN-LSTM 网络与 GRU 网络通过自适应权重进行组合, 解决了单一模型难以获得最优估计结果的问题。

(3) 所提估计方法相较于 CNN-LSTM、LSTM 和 GRU, MAE 分别降低了 71.8%、62.4%、22.6%, RMSE 分别降低了 84.1%、79.8%、44.3%。

参 考 文 献

- [1] CAMPI T, CRUCIANI S, MARADEI F, et al. Magnetic field mitigation by multicoil active shielding in electric vehicles equipped with wireless power charging system[J]. IEEE Transactions on Electromagnetic Compatibility, 2020, 62(4): 1398-1405.
- [2] FAN S, LIU J, WU Q, et al. Optimal coordination of virtual power plant with photovoltaics and electric vehicles: A temporally coupled distributed online algorithm[J]. Applied Energy, 2020, 277: 115583.
- [3] ZHANG L, FAN W T, WANG Z P, et al. Battery heating for lithium-ion batteries based on multi-stage alternative currents[J]. Journal of Energy Storage, 2020, 32: 101885.
- [4] 张振宇, 汪光森, 聂世雄, 等. 脉冲大倍率放电条件下磷酸铁锂电池荷电状态估计[J]. 电工技术学报, 2019, 34(8): 1769-1779.
- ZHANG Z Y, WANG G S, NIE S X, et al. State of charge estimation of LiFePO₄ battery under the condition of high rate pulsed discharge[J]. Transactions of China Electrotechnical Society, 2019, 34(8): 1769-1779.
- [5] SUI X, HE S, 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.
- [6] LIPU M S H, HANNAN M A, HUSSAIN A, et al. A review of state of health and remaining useful life estimation methods for lithium-ion

battery in electric vehicles: Challenges and recommendations[J]. Journal of Cleaner Production, 2018, 205: 115-133.

- [7] LIN C P, CABRERA J, YANG F F, et al. Battery state of health modeling and remaining useful life prediction through time series model[J]. Applied Energy, 2020, 275: 115338.
- [8] 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.
- REN P, WANG S L, HE M F, 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.
- [9] ZHANG C, ALLAFI W, DINH Q, et al. Online estimation of battery equivalent circuit model parameters and state of charge using decoupled least squares technique[J]. Energy, 2018, 142: 678-688.
- [10] 严干贵, 李洪波, 段双明, 等. 基于模型参数辨识的储能电池状态估算[J]. 中国电机工程学报, 2020, 40(24): 8145-8154, 8251.
- YAN G G, LI H B, DUAN S M, et al. Energy storage battery state estimation based on model parameter identification[J]. Proceedings of the CSEE, 2020, 40(24): 8145-8154, 8251.
- [11] 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 Y K, ZHANG H, WANG X H. Hybrid 1DCNN-LSTM model for predicting lithium ion battery state of health[J]. Energy Storage Science and Technology, 2022, 11(1): 240-245.
- [12] 徐超, 李立伟, 杨玉新, 等. 基于改进粒子滤波的锂电池 SOH 预测[J]. 储能科学与技术, 2020, 9(6): 1954-1960.
- XU C, LI L W, YANG Y X, et al. Lithium-ion battery SOH estimation based on improved particle filter[J]. Energy Storage Science and Technology, 2020, 9(6): 1954-1960.
- [13] 杨胜杰, 罗冰洋, 王菁, 等. 基于容量增量曲线峰值区间特征参数的锂离子电池健康状态估算[J]. 电工技术学报, 2021, 36(11): 2277-2287.
- YANG S J, LUO B Y, WANG J, et al. State of health estimation for lithium-ion batteries based on peak region feature parameters of incremental capacity curve[J]. Transactions of China Electrotechnical Society, 2021, 36(11): 2277-2287.
- [14] National Aeronautics and Space Administration Prognostics Center of Excellence. PCoE Datasets[EB/OL]. <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/#battery>.
- [15] YANG J F, XIA B, HUANG W X, et al. Online state-of-health estimation for lithium-ion batteries using constant-voltage charging current analysis[J]. Applied Energy, 2018, 212: 1589-1600.
- [16] WANG Z K, ZENG S K, GUO J B, et al. State of health estimation of lithium-ion batteries based on the constant voltage charging curve[J]. Energy, 2019, 167: 661-669.
- [17] YE Y H, SHI Y X, CAI N S, et al. Electro-thermal modeling and experimental validation for lithium ion battery[J]. Journal of Power Sources, 2012, 199: 227-238.
- [18] 张小利, 李雄飞, 李军. 融合图像质量评价指标的相关性分析及性能评估[J]. 自动化学报, 2014, 40(2): 306-315.
- ZHANG X L, LI X F, LI J. Validation and correlation analysis of metrics for evaluating performance of image fusion[J]. Acta

- Automatica Sinica, 2014, 40(2): 306-315.
- [19] 殷浩然, 苗世洪, 韩估, 等. 基于三维卷积神经网络的配电物联网异常辨识方法[J]. 电力系统自动化, 2022, 46(1): 42-50.
- YIN H R, MIAO S H, HAN J, et al. Anomaly identification method for distribution Internet of Things based on three-dimensional convolutional neural network[J]. Automation of Electric Power Systems, 2022, 46(1): 42-50.
- [20] 孙黎霞, 白景涛, 周照宇, 等. 基于双向长短期记忆网络的电力系统暂态稳定评估[J]. 电力系统自动化, 2020, 44(13): 64-72.
- SUN L X, BAI J T, ZHOU Z Y, et al. Transient stability assessment of power system based on Bi-directional long-short-term memory network[J]. Automation of Electric Power Systems, 2020, 44(13): 64-72.
- [21] 孟安波, 陈顺, 王陈恩, 等. 基于混沌CSO优化时序注意力GRU模型的超短期风电功率预测[J]. 电网技术, 2021, 45(12): 4692-4700.
- MENG A B, CHEN S, WANG C N, et al. Ultra-short-term wind power prediction based on chaotic CSO optimized temporal attention GRU model[J]. Power System Technology, 2021, 45(12): 4692-4700.
- [22] 顾国庆, 李晓辉. 基于箱线图异常检测的指数加权平滑预测模型[J]. 计算机与现代化, 2021(1): 28-33.
- GU G Q, LI X H. Exponential weighted smoothing prediction model based on abnormal detection of box-plot[J]. Computer and Modernization, 2021(1): 28-33.
- [23] REHMAN A U, BELHAOUARI S B, IJAZ M, et al. Multi-classifier tree with transient features for drift compensation in electronic nose[J]. IEEE Sensors Journal, 2020, 21(5): 6564-6574.
- [24] 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 Y K, ZHANG H, WANG X H. Hybrid 1DCNN-LSTM model for predicting lithium ion battery state of health[J]. Energy Storage Science and Technology, 2022, 11(1): 240-245.
- [25] 张吉昂, 王萍, 程泽. 基于充电电压片段和融合方法的锂离子电池SOC-SOH-RUL联合估计[J/OL]. 电网技术: 1-12[2021-10-31]. <https://doi.org/10.13335/j.1000-3673.pst.2021.0888>.
- ZHANG Ji'ang, WANG Ping, CHENG Ze. A Joint estimation framework of SOC-SOH-RUL for lithium batteries based on charging voltage segment and hybrid method[J/OL]. Power System Technology 1-12[2021-10-31]. <https://doi.org/10.13335/j.1000-3673.pst.2021.0888>.