

基于CNN-Bi-LSTM网络的锂离子电池剩余使用寿命预测

梁海峰¹,袁 芃¹,高亚静²

(1. 华北电力大学 电力工程系,河北 保定 071003;2. 中国华能集团碳中和研究所,北京 100031)

摘要:锂离子电池的剩余使用寿命(RUL)预测可以评估电池的可靠性,降低电池使用的风险并为电池维护提供理论依据。结合卷积神经网络(CNN)与双向长短期记忆(Bi-LSTM)网络的优点,提出一种考虑多种寿命衰退特征与数据时序性的CNN-Bi-LSTM网络模型用于锂离子电池RUL预测。通过仿真得到CNN超参数,选择相关性高的特征参数作为预测输入量,最后在NASA锂离子电池老化数据集上进行仿真实验。实验结果表明CNN-Bi-LSTM网络模型能准确预测锂离子电池RUL,与其他网络模型相比,具有网络模型参数少、占用内存小的优势,在精确度和收敛性上都有较好表现。

关键词:锂离子电池;卷积神经网络;双向长短期记忆网络;剩余使用寿命预测

中图分类号:TM 911

文献标志码:A

DOI:10.16081/j.epae.202110030

0 引言

锂离子电池因具有安全性好、能量转换效率高、经济性强等优点在分布式储能中的应用日渐广泛,并逐渐成为光伏发电系统储能缓冲环节的主要设备^[1]。然而,以锂离子电池为代表的电化学电池充放电均是在电极上发生化学反应,因此充放电会造成电极中有效材料的损失,导致电池发生不可逆的老化^[2]。通常认为电池容量衰减至70%~80%或内阻增大100%表示锂离子电池的使用寿命结束^[3-4],不及时发现该情况并更换电池会导致巨大的安全风险^[5]。因此有必要准确预测锂离子电池的剩余使用寿命RUL(Remaining Useful Life),提前获取电池的寿命相关信息,以便及时更换达到阈值的电池,避免电池性能下降导致功率分配远离预期而引起故障,保证系统的安全可靠运行。同时预测锂离子电池RUL对于延长电池使用寿命、降低设备的维护成本和提高储能设备管理的经济性都有实际应用价值。

现有的锂离子电池RUL预测方法主要包括基于模型^[6]的方法和基于数据驱动的方法。基于模型的方法可以较好地反映电池电化学特性,如文献[7-8]都在一阶戴维南等效电路模型的基础上研究锂离子电池的内部参数,并得到较为精确的结果,但是计算过程和模型参数识别都略为复杂。基于数据驱动的方法只需从电池外部特性的历史数据中挖掘性能变化的规律,不需要了解内部的化学机理,具有较强的实用性^[9]。

目前人工神经网络ANN(Artificial Neural Network)^[10]等技术已经广泛应用于锂离子电池的RUL

预测中,其中长短期记忆LSTM(Long Short-Term Memory)网络解决了循环神经网络随着时间的增加会发生梯度下降或者梯度爆炸的问题。文献[11]在应用LSTM网络预测电池的寿命衰退情况时,使用均方根反向传播对网络进行自适应优化,并加入dropout技术解决过拟合的问题;文献[12]构建了一种改进的LSTM网络模型,基于电池的历史容量数据,动态选择不同的网络参数来实现RUL的预测。在此基础上,文献[13]提出基于双向长短期记忆Bi-LSTM(Bi-directional Long Short-Term Memory)网络的预测方法,与LSTM网络相比,其对强调顺序的数据表达能力更强。想要进一步提高预测精度和速度,不仅要学习电池的历史容量数据,还需要提取历史数据中的多个特征^[14]。文献[15]建立了动态LSTM网络,该网络通过学习历史测量电压的变化和滚动预测的方法在动态性和准确性上都有较大的提升,但输入特征仍过于单一,不能完全描述锂离子电池的老化规律;为了更好地学习锂离子电池的老化规律,文献[5,16]使用一维卷积神经网络CNN(Convolutional Neural Network)实现锂离子电池容量预测,CNN中的卷积核能够实现局部权值共享并逐层挖掘相邻数据间的共性规律,实用性更强。

综上所述,本文提出一种利用多种寿命衰退特征的锂离子电池RUL预测方法,构建一种结合CNN和Bi-LSTM网络的混合神经网络模型(下文简称CNN-Bi-LSTM网络模型),该模型可充分提取输入数据的高级特征,并利用数据的时序性特征进行锂离子电池RUL预测。首先利用锂离子电池相关先验知识在海量的电池数据中提取与锂离子电池寿命衰减最相关的参数信息并将其输入网络,然后利用CNN提取特征序列间的潜在关系作为特征信息,将特征信息输入Bi-LSTM网络进行预测。最后对比了

收稿日期:2021-04-01;修回日期:2021-09-02

基金项目:国家自然科学基金资助项目(51607068)

Project supported by the National Natural Science Foundation of China(51607068)

本文提出的 CNN-Bi-LSTM 网络模型与单独使用 CNN、Bi-LSTM 网络模型的预测结果,结果表明利用考虑多影响参数的 CNN-Bi-LSTM 网络模型进行锂离子电池 RUL 预测所需参数更少,且模型精度更高、收敛性更好。

1 基本网络模型

1.1 CNN

CNN 通过卷积核对输入信息局部区域的特征信息进行逐层提取,捕捉连续数据间的相关性。因为局部信息间所具有的特征关系接近,所以可通过共享卷积核参数的方式减少网络参数数量,降低所需计算量与模型大小。CNN 可以通过不同的卷积核尺寸提取数据间的不同特征,并与池化层交替使用来提高性能。卷积后进行池化计算,将上一层 CNN 所得结果输入池化层,池化核在卷积结果的宽度上进行计算,在特征信息的一定范围内取均值或最大值,进一步提取特征信息。池化计算可减少模型参数和计算量,并防止过拟合。最终,将得到的高级特征信息通过全连接层输入 Bi-LSTM 网络层进行下一步预测。CNN 示意图见附录 A 图 A1。

1.2 LSTM 网络

LSTM 网络基本单元包括遗忘门、输入门和输出门,其单元模型见附录 A 图 A2。LSTM 网络通过不断更新细胞内部的隐藏层状态与细胞状态,可以更好地处理时间序列,其正向传播过程的计算公式如式(1)~(6)所示。

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$\bar{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \bar{C}_t \quad (4)$$

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t \odot \tanh(C_t) \quad (6)$$

式中: t 和 $t-1$ 分别为当前时刻和前一时刻; f_t 为遗忘门; i_t 为输入门; O_t 为输出门; x_t 、 C_t 、 h_t 和 x_{t-1} 、 C_{t-1} 、 h_{t-1} 分别为当前时刻和前一时刻的输入、细胞状态、LSTM 单元输出值; $\bar{C}_t$ 为候选细胞状态; W_f 、 W_i 、 W_c 、 W_o 分别为遗忘门、输入门、输入状态、输出门的权值矩阵; b_f 、 b_i 、 b_c 、 b_o 分别为遗忘门、输入门、输入状态、输出门的偏置项; $\odot$ 表示按元素相乘; $\sigma(\cdot)$ 和 $\tanh(\cdot)$ 为激活函数,可以提高 LSTM 网络的非线性表达能力。

1.3 Bi-LSTM 网络

Bi-LSTM 网络由 2 个方向相反的 LSTM 网络构成,其网络结构见附录 A 图 A3。Bi-LSTM 网络的输入分别经过 2 个 LSTM 网络,输出结果也是 2 个方向结果的拼接。通过 Bi-LSTM 网络训练的模型可以综合考虑历史信息与未来信息,提升模型效率,降低过

拟合的风险。由于在充放电过程中,获得的外部测量数据都表现出时序性特征,因此本文采用 Bi-LSTM 网络对锂离子电池 RUL 进行预测:首先计算时刻 1 至时刻 t 的输出,并保存每个时刻前向传播层的输出,同时在反向传播层计算从时刻 t 至时刻 1 的输出,最后在输出层结合前向传播层与反向传播层的输出结果得到最终的输出结果,具体计算公式如式(7)~(9)所示。

$$h_t = f(w_1 x_t + w_2 h_{t-1}) \quad (7)$$

$$h'_t = f(w_3 x_t + w_5 h'_{t+1}) \quad (8)$$

$$O_t = g(w_4 h_t + w_6 h'_t) \quad (9)$$

式中: h_t 、 h'_t 分别为 t 时刻的前向传播层、后向传播层的输出; w_1 、 w_3 分别为输入层到前向和后向传播层的权值矩阵; w_2 、 w_5 分别为前向、后向传播层到自身传播层的权值矩阵; w_4 、 w_6 分别为前向和后向传播层到输出层的权值矩阵; O_t 为最终输出门的输出值;函数 $f(\cdot)$ 表示细胞计算过程;函数 $g(\cdot)$ 为对前向、后向传播结果进行拼接的函数。Bi-LSTM 网络通过合理利用前、后时刻信息,使预测过程更加全面,提高了预测精度。

2 CNN-Bi-LSTM 网络

2.1 模型构建

与传统神经网络相比,CNN 可以更好地提取数据内在特征,构建网络时所需参数更少,在保证精度的同时提高了计算速度,但 CNN 不能够充分利用锂离子电池数据集内部数据的时序性特征。单一的 LSTM 网络虽然可以有效利用数据的时序性特征,但其对原始数据的关联性分析不足。因此本文结合两者的优点,在 CNN 后接入 Bi-LSTM 网络构成 CNN-Bi-LSTM 网络,网络模型结构如图 1 所示。图中, n




图1 CNN-Bi-LSTM 网络模型示意图

Fig.1 Schematic diagram of CNN-Bi-LSTM network model

为数据数量; N_p 为池化核大小; N_c 为卷积核大小。

Bi-LSTM 网络中, CNN 部分主要负责提取时间序列的特征, Bi-LSTM 网络部分主要负责预测, 主要步骤为: ①将输入特征参数组成矩阵, 并按比例分割为训练集与预测集, 然后重构为网络所需要的维度的矩阵输入 CNN-Bi-LSTM 网络; ②以卷积形式提取参数间的潜在关系作为特征; ③将所得特征输入池化层, 通过池化计算减少模型参数并增强特征; ④将池化层所得结果输入 Bi-LSTM 网络, 通过遗忘门、输入门、输出门更新细胞状态并基于之前时刻与后续时刻的数据关系进行预测, 通过全连接层输出最终结果。CNN-Bi-LSTM 网络模型可充分提取输入数据的高级特征, 并利用数据的时序性特征进行锂离子电池 RUL 预测。

为加快模型的收敛速度并缩短模型的学习周期, 本文构建的 CNN-Bi-LSTM 网络模型采用 ReLU 激活函数^[17], 从而有效提高模型的非线性表达能力并避免训练过程中发生过拟合。另外, 本文在进行模型训练前对数据进行标准化处理, 以消除原始数据的特征尺度不一致的问题, 增强模型的稳定性, 加快收敛速度。

为了更好地评估模型的预测效果, 本文采用寿命偏差、均方根误差 E_{RMSE} 、模型判定系数 R^2 这 3 个指标对预测结果进行评定。其中, 寿命偏差指达到电池失效容量阈值时, 循环次数的预测值和实际值的差值与实际值的比值; E_{RMSE} 、 R^2 分别如式 (10)、(11) 所示。

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{k=1}^n (y^k - \hat{y}^k)^2} \quad (10)$$

$$R^2 = 1 - \frac{\sum_{k=1}^n (y^k - \hat{y}^k)^2}{\sum_{k=1}^n (y^k - \bar{y})^2} \quad (11)$$

式中: y^k 与 $\hat{y}^k$ 分别为第 k 次循环时锂离子电池容量的真实值与预测值; $\bar{y}$ 为实际值的平均值。

2.2 输入特征参数选择

本文采用 NASA 提供的 18650 电池老化数据集 (下文简称 NASA 数据集), 其包含 4 种锂离子电池 B_{0005} — B_{0007} 、 B_{0018} 的相关数据, 实验数据由室温下进行的循环充放电实验得到^[3]。锂离子电池的额定容量为 $2.0 \text{ A} \cdot \text{h}$, 实验时首先在恒流模式下对电池进行充电, 电流保持为 1.5 A , 直至电池电压增加到 4.2 V 后转为恒压充电模式, 电压保持为 4.2 V , 直至电池电流从 1.5 A 降至 20 mA ; 放电过程以 2 A 恒定电流放电, 直至 B_{0005} — B_{0007} 、 B_{0018} 的电压分别降至 2.7 、 2.5 、 2.2 、 2.5 V 。

由于在电池实际运行过程中, 容量及内阻等直

接性能参数难以获取, 为了实现 RUL 的在线监测, 需要从可监测的性能参数着手来模拟锂离子电池全寿命循环周期的过程。准确构建锂离子电池老化模型需要提取能表征电池寿命衰减的数据, 并证明其与锂离子电池 RUL 的相关性^[18]。电压和电流的变化易于监测和获取, 同时能较好地反映锂离子电池的衰退情况^[4]。恒压充电阶段的电流、恒流充电阶段的电压与循环次数的关系如图 2 所示。由图 2(a) 可知, 在每个充电周期内, 恒压充电电流随着充电时间的增加呈现相同的变化趋势, 且随着充放电循环次数的增加, 其达到同一终止电流的时间逐渐增加。由图 2(b) 可知, 随着充放电循环次数的增加, 从同一起始电压到达截止电压的时间逐渐缩短, 可见在电池老化过程中, 恒流充电时间会逐渐减少。因此本文选取等流降充电时间 S_1 、等压升充电时间 S_2 和循环次数 S_3 作为表征锂离子电池寿命衰减的特征参数。




图2 锂离子电池充电阶段的电流、电压

Fig.2 Current and voltage of lithium-ion battery in charging stage

为了验证所选参数的有效性, 采用 Pearson 相关性分析法定量分析 3 个参数与锂离子电池容量的相关性, 具体结果如表 1 所示。由表 1 可知, 选取的 3 种特征参数与锂离子电池容量的相关性系数绝对值

表 1 电池寿命衰减特征参数与锂离子电池容量间的相关系数

Table 1 Correlation coefficient between battery life degradation characteristic parameters and lithium-ion battery capacity

特征参数	相关系数	特征参数	相关系数
S_1	-0.9874	S_3	-0.9877
S_2	0.9331		

均在(0.9, 1.0)范围内,由此可得所选取的3种特征参数与锂离子电池容量之间具有很强的相关性,可以间接表征锂离子电池寿命衰减特性,所以本文将 S_1 — S_3 作为CNN-Bi-LSTM网络的输入。

2.3 CNN超参数设置

将 S_1 — S_3 作为CNN-Bi-LSTM网络的输入参数后进行CNN超参数选择。为防止网络层数过深造成梯度爆炸或梯度消失,本文设置CNN含有1个卷积层与1个池化层。卷积核过小可能会因为对时间序列的特征提取不足导致性能不佳,而卷积核过大可能会导致过拟合,因此在设计CNN时根据数据调整卷积核的大小。卷积步长指网络在预测未来值时,过滤器每次向前滑动的步长,步长偏小会增加计算量,步长偏大可能会在生成预测数值时丢弃有价值的信息,但有利于捕获时间序列的长期时间特征并消除序列中的噪声。

将 S_1 — S_3 输入CNN-Bi-LSTM网络模型,为充分发掘数据中的特征, N_c 和 N_p 在1~3范围内选取。以 B_{0005} 为例,不同的 N_c 和 N_p 下的电池RUL预测实验结果如图3所示。




图3 不同的 N_c 和 N_p 下 B_{0005} 的RUL预测结果对比

Fig.3 Comparison of RUL prediction results for B_{0005} among different values of N_c and N_p

为减小模型训练过程中的误差与偶然性,将不同 N_c 和 N_p 取值下的CNN-Bi-LSTM模型分别训练5次,提取预测数据并取均值进行比较,对应的评价指标如表2所示。

表2 不同 N_c 和 N_p 取值下的评价指标

Table 2 Evaluation indicators for different values of N_c and N_p

N_c	$E_{RMSE} / (A \cdot h)$			R^2			寿命偏差 / %		
	$N_p=1$	$N_p=2$	$N_p=3$	$N_p=1$	$N_p=2$	$N_p=3$	$N_p=1$	$N_p=2$	$N_p=3$
1	0.085	0.085	0.042	0.763	0.753	0.936	10.6	17.6	8.1
2	0.085	0.085	0.042	0.827	0.929	0.917	9.5	4.9	20.6
3	0.069	0.044	0.050	0.958	0.980	0.963	4.0	1.2	8.7

分析结果表明,合理选择卷积核与池化核的大小可以有效地提高预测效果。保持池化核大小不变,增加卷积核大小,则预测结果的 E_{RMSE} 有下降趋势, R^2 上升,寿命偏差下降。保持卷积核大小为3,

调整池化核大小,当池化核大小为2时,其5次训练得到的 E_{RMSE} 、 R^2 与寿命偏差分别为0.044 A·h、0.980、1.2%,预测效果最优。因此本文选用卷积核大小为3、池化核大小为2的CNN。

3 实验与分析

为了验证本文提出的CNN-Bi-LSTM网络模型预测锂离子电池RUL的有效性,在NASA数据集的基础上进行RUL预测,利用第2节建立的模型和选取的参数对不同型号的锂离子电池进行实验,并将CNN-Bi-LSTM网络模型的预测结果与CNN、Bi-LSTM网络模型的预测结果进行对比。

本文实验硬件所使用处理器为Intel(R)Core(TM)i5-6300HQ CPU@2.30 GHz,运行内存为8 GB,固态硬盘容量为500 GB,操作系统为Windows 10旗舰版64位操作系统。软件编程平台为Jupyter Notebook,以基于Keras深度学习工具的Tensorflow框架为支撑,实现CNN-Bi-LSTM网络仿真模型的搭建。循环充放电实验在室温下进行,实验同样基于2.2节中采用的NASA数据集, B_{0005} — B_{0007} 、 B_{0018} 的初始容量都为2 A·h,当容量下降到初始容量的70%,即1.4 A·h时电池失效, B_{0005} — B_{0007} 的总充放电循环次数均达到168次, B_{0018} 的总充放电循环次数为132次。4种锂离子电池的容量随着循环次数退化的曲线如图4所示。值得注意的是,图中可以看到波动的部分,这是因为电池电化学反应过程中的极化效应,使得连续循环充放电的电池静置一段时间后,其实际容量会出现一定的提升^[19],这从侧面说明了不能仅靠循环次数来预测电池RUL。




图4 锂离子电池容量退化曲线

Fig.4 Curves of lithium-ion battery capacity degradation

3.1 模型有效性验证

利用CNN-Bi-LSTM网络模型分别对4种锂离子电池进行容量预测,预测结果见附录B图B1,预测结果的评价指标如表3所示。

由表3可见,本文所提CNN-Bi-LSTM网络模型对不同型号锂离子电池的预测效果均较好,证明了该模型的有效性。

3.2 与现有网络模型的对比

为进一步验证本文所提CNN-Bi-LSTM网络模

表 3 4 种锂离子电池 RUL 预测结果的评价指标
Table 3 Evaluation indicators of RUL prediction results for four kinds of lithium-ion battery

电池	$E_{\text{RMSE}} / (\text{A} \cdot \text{h})$	R^2	寿命偏差 / %
B ₀₀₀₅	0.018	0.991	0
B ₀₀₀₆	0.029	0.985	1.8
B ₀₀₀₇	0.014	0.992	0
B ₀₀₁₈	0.022	0.980	1.0

型的有效性,将其与 CNN、Bi-LSTM 网络模型进行对比。以 B₀₀₀₅ 为例,3 种网络模型的 RUL 预测结果如图 5 所示。3 种网络模型对 B₀₀₀₅—B₀₀₀₇、B₀₀₁₈ 的 RUL 预测结果的评价指标见表 4。




图 5 3 种网络模型的 RUL 预测结果

Fig.5 RUL prediction results of three kinds of network models

由表 4 可见:CNN-Bi-LSTM 网络模型的 E_{RMSE} 和 R^2 指标都优于 Bi-LSTM、CNN 网络模型;单独对比 CNN-Bi-LSTM、Bi-LSTM 网络模型的评价指标可知,CNN-Bi-LSTM 网络模型中的 CNN 部分很好地提取了多个输入参数的特征;单独对比 CNN-Bi-LSTM、Bi-LSTM 网络模型的评价指标可知,CNN-Bi-LSTM 网络模型中的 Bi-LSTM 网络部分能够更好地表达连续时间序列。此外,对比 3 种网络模型的参数数量可知,CNN-Bi-LSTM 网络模型的参数数量大于 CNN 模型但明显少于 Bi-LSTM 网络模型,证明了本文所提 CNN-Bi-LSTM 网络模型结合了 CNN 与 Bi-LSTM

表 4 3 种网络模型的 RUL 预测结果评价指标

Table 4 Evaluation indicators of RUL prediction results by three kinds of network models

网络模型	$E_{\text{RMSE}} / (\text{A} \cdot \text{h})$					R^2					参数数量
	B ₀₀₀₅	B ₀₀₀₆	B ₀₀₀₇	B ₀₀₁₈	平均值	B ₀₀₀₅	B ₀₀₀₆	B ₀₀₀₇	B ₀₀₁₈	平均值	
CNN-Bi-LSTM	0.018	0.029	0.014	0.022	0.021	0.991	0.985	0.992	0.980	0.987	595 513
Bi-LSTM	0.027	0.044	0.027	0.022	0.030	0.980	0.969	0.971	0.980	0.975	1 015 441
CNN	0.167	0.247	0.046	0.132	0.148	0.749	0.684	0.915	0.785	0.783	70 377

4 结论

准确预测锂离子电池的 RUL 可以保证电池的安全可靠运行,从而延长电池使用寿命、降低设备的维护成本、提高储能设备管理的经济性,具有实际应用价值。本文提出了一种利用多种寿命衰退特征预测锂离子电池 RUL 的方法,并结合 CNN 与 Bi-LSTM

网络的优点,既减少了可训练参数的数量以降低算法运行所需的计算量和占用的内存量,又提高了模型的预测精度。

3 种网络模型的收敛性如图 6 所示。由图可见,随着模型训练次数增加,CNN-Bi-LSTM 网络模型的误差下降迅速,并在第 22 次训练后小于其他 2 种网络模型的误差,证明了 CNN-Bi-LSTM 网络模型具有更好的收敛性。




图 6 3 种网络模型的收敛性比较

Fig.6 Comparison of convergence among three kinds of network models

3.3 模型泛化性验证

为了进一步验证本文所提基于 CNN-Bi-LSTM 网络模型的锂离子电池 RUL 预测方法的适用性,本节基于 Oxford 电池老化数据集^[20](下文简称 Oxford 数据集)进行仿真验证,该数据集共包含了 8 块锂离子电池的测试数据。测试所采用的锂离子电池为 Kokam 公司生产的钴酸锂离子电池,其额定容量为 740 mA·h;重复进行恒定电流放电循环,且测试电池均在每 100 个循环后通过 0.74 A 恒定电流充放电进行一次容量标定。本节选取 1 号电池的数据作为训练集,对 2 号和 3 号电池进行预测,结果见附录 B 图 B2。由图可知本文所提出的基于 CNN-Bi-LSTM 网络模型的锂离子电池 RUL 预测方法对 Oxford 数据集中的 2、3 号电池均能实现较好预测,2、3 号电池对应的 E_{RMSE} 分别为 0.24 A·h 和 0.13 A·h, R^2 分别为 0.98 和 0.99,预测精度较高。

网络的优点构建了 CNN-Bi-LSTM 网络模型,该网络模型可同时考虑输入数据特征信息与时序信息进行 RUL 预测。首先选择相关性高的特征参数,通过实验选用卷积核大小为 3 与池化核大小为 2 的 CNN 用于构建 CNN-Bi-LSTM 网络模型。通过在不同电池数据集上进行仿真实验,验证了本文提出的 CNN-

Bi-LSTM网络模型具有泛化性和有效性,适用于锂离子电池RUL预测,且其在减少了模型参数数量的同时,在精确度和收敛性上也优于CNN模型与Bi-LSTM网络模型。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 彭飞,刘志祥,任敬国,等. 新型无均衡管理光伏锂电储能发电模组及其MPPT控制策略[J]. 电力自动化设备,2017,37(4): 73-81.
PENG Fei, LIU Zhixiang, REN Jingguo, et al. PV/li-ion energy-storage power module based on non-balancing cell management and its MPPT control[J]. Electric Power Automation Equipment, 2017, 37(4): 73-81.
- [2] HAN Xuebing, OUYANG Minggao, LU Languang, et al. A comparative study of commercial lithium ion battery cycle life in electric vehicle: capacity loss estimation[J]. Journal of Power Sources, 2014, 268: 658-669.
- [3] GOEBEL K, SAHA B, SAXENA A, et al. Prognostics in battery health management[J]. IEEE Instrumentation & Measurement Magazine, 2008, 11(4): 33-40.
- [4] 史永胜,施梦琢,丁恩松,等. 基于多退化特征的锂离子电池剩余寿命预测[J]. 电源技术, 2020, 44(6): 836-840.
SHI Yongsheng, SHI Mengzhuo, DING Ensong, et al. Remaining useful life prediction of lithium ion battery based on multiple degradation characteristics[J]. Chinese Journal of Power Sources, 2020, 44(6): 836-840.
- [5] 李超然,肖飞,樊亚翔,等. 基于卷积神经网络的锂离子电池SOH估算[J]. 电工技术学报, 2020, 35(19): 4106-4119.
LI Chaoran, XIAO Fei, FAN Yaxiang, et al. An approach to lithium-ion battery SOH estimation based on convolutional neural network[J]. Transactions of China Electrotechnical Society, 2020, 35(19): 4106-4119.
- [6] 毕晓君,胡崧益. 基于混合引导策略的高精度萤火虫优化粒子滤波算法[J]. 上海交通大学学报, 2019, 53(2): 232-238.
BI Xiaojun, HU Songyi. Firefly algorithm with high precision mixed strategy optimized particle filter[J]. Journal of Shanghai Jiao Tong University, 2019, 53(2): 232-238.
- [7] 严干贵,蔡长兴,段双明,等. 锂离子储能电池成组方式优化[J]. 电力自动化设备, 2021, 41(4): 148-153.
YAN Gangui, CAI Changxing, DUAN Shuangming, et al. Grouping mode optimization of lithium-ion energy storage battery[J]. Electric Power Automation Equipment, 2021, 41(4): 148-153.
- [8] 卫志农,原康康,成乐祥,等. 基于多新息最小二乘算法的锂电池参数辨识[J]. 电力系统自动化, 2019, 43(15): 139-145.
WEI Zhinong, YUAN Kangkang, CHENG Lexiang, et al. Parameter identification of lithium-ion battery based on multi-innovation least squares algorithm[J]. Automation of Electric Power Systems, 2019, 43(15): 139-145.
- [9] 刘月峰,张公,张晨荣,等. 锂离子电池RUL预测方法综述[J]. 计算机工程, 2020, 46(4): 11-18.
LIU Yuefeng, ZHANG Gong, ZHANG Chenrong, et al. Review of RUL prediction method for lithium-ion batteries[J]. Computer Engineering, 2020, 46(4): 11-18.
- [10] WU Ji, ZHANG Chenbin, CHEN Zhongcai. An online method for lithium-ion battery remaining useful life estimation using importance sampling and neural networks[J]. Applied Energy, 2016, 173: 134-140.
- [11] GAO Dong, HUANG Miaohua. Prediction of remaining useful life of lithium-ion battery based on multi-kernel support vector machine with particle swarm optimization[J]. Journal of Power Electronics, 2017, 17(5): 1288-1297.
- [12] 李向南. 基于神经网络模型的锂离子电池寿命预测研究[D]. 成都:电子科技大学, 2019.
LI Xiangnan. Research on prediction of lithium-ion battery life based on neural network model[D]. Chengdu: University of Electronic Science and Technology of China, 2019.
- [13] 吴晓欣,何怡刚,段嘉珺,等. 考虑复杂时序关联特性的Bi-LSTM变压器DGA故障诊断方法[J]. 电力自动化设备, 2020, 40(8): 184-193.
WU Xiaoxin, HE Yigang, DUAN Jiajun, et al. Bi-LSTM-based transformer fault diagnosis method based on DGA considering complex correlation characteristics of time sequence[J]. Electric Power Automation Equipment, 2020, 40(8): 184-193.
- [14] MA Jian, SHANG Pengchao, ZOU Xinyu, et al. A hybrid transfer learning scheme for remaining useful life prediction and cycle life test optimization of different formulation li-ion power batteries[J]. Applied Energy, 2021, 282(4): 116167.
- [15] WANG Cunsong, LU Ningyun, WANG Senlin, et al. Dynamic long short-term memory neural-network-based indirect remaining-useful-life prognosis for satellite lithium-ion battery[J]. Applied Sciences, 2018, 8(11): 2078.
- [16] 彭道刚,朱琪,车权,等. 基于CNN-LSTM神经网络的电网调度火电厂短期存煤预测[J]. 电力自动化设备, 2021, 41(6): 127-132.
PENG Daogang, ZHU Qi, CHE Quan, et al. Short-term coal storage forecasting of thermal power plant for power grid dispatching based on CNN-LSTM neural network[J]. Electric Power Automation Equipment, 2021, 41(6): 127-132.
- [17] 龚钢军,张帅,吴秋新,等. 基于TensorFlow的高压输电线路异物识别[J]. 电力自动化设备, 2019, 39(4): 204-209, 216.
GONG Gangjun, ZHANG Shuai, WU Qiuxin, et al. Foreign body identification based on TensorFlow for high voltage transmission line[J]. Electric Power Automation Equipment, 2019, 39(4): 204-209, 216.
- [18] 高栋,黄妙华,周亚鹏. 基于充电电流数据的锂电池容量估计[J]. 电源技术, 2018, 42(10): 1447-1450, 1581.
GAO Dong, HUANG Miaohua, ZHOU Yapeng. Lithium-ion battery's capacity estimation based on charging current data[J]. Chinese Journal of Power Sources, 2018, 42(10): 1447-1450, 1581.
- [19] 武骥. 微电网环境下可再生能源存储与利用方法研究[D]. 合肥:中国科学技术大学, 2018.
WU Ji. Research on storage and utilization of the renewable energy in micro-grids[D]. Hefei: University of Science and Technology of China, 2018.
- [20] BIRKL C R. Diagnosis and prognosis of degradation in lithium-ion batteries[D]. Oxford, UK: University of Oxford, 2017.

作者简介:



梁海峰

梁海峰(1976—),男,河北保定人,副教授,博士,研究方向为微电网技术、新能源发电并网及储能技术等(E-mail: hliang@ncepu.edu.cn);

袁芃(1997—),女,湖北武汉人,硕士研究生,研究方向为微电网储能优化配置(E-mail: yuanpeng8@ncepu.edu.cn)。

(编辑 任思思)

Remaining useful life prediction of lithium-ion battery based on CNN-Bi-LSTM network

LIANG Haifeng¹, YUAN Peng¹, GAO Yajing²

(1. Department of Electrical Engineering, North China Electric Power University, Baoding 071003, China;

2. Carbon Neutrality Research Institute of China Huaneng Group Co., Ltd., Beijing 100031, China)

Abstract: The RUL (Remaining Useful Life) prediction of the lithium-ion battery can evaluate the reliability of the battery, reduce the risk of battery use and provide a theoretical basis for battery maintenance. Combining the advantages of CNN (Convolutional Neural Network) and Bi-LSTM (Bi-directional Long Short-Term Memory) network, the CNN-Bi-LSTM network model for lithium-ion battery RUL prediction is proposed, which considers both multiple degradation characteristics and time sequence. The hyperparameters of CNN are obtained by simulation, the highly correlated feature parameters are selected as the prediction input, and the simulation experiment is carried out on the NASA lithium-ion battery aging data set. The experimental results show that the CNN-Bi-LSTM network model can accurately predict the RUL of lithium-ion batteries. Compared with other network models, it has the advantages of fewer network model parameters and smaller memory usage, and has good performance in accuracy and convergence.

Key words: lithium-ion battery; convolutional neural network; bi-directional long short-term memory network; remaining useful life prediction

(上接第 198 页 continued from page 198)

Self-adaptive integrated control strategy of battery energy storage system considering SOC for primary frequency regulation

WANG Yufei, YANG Mingcheng, XUE Hua, ZHANG Yuhua, MI Yang

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

Abstract: Considering improving the adaptability of primary frequency response under the limitation of BESS (Battery Energy Storage System) capacity, an integrated control strategy of BESS considering SOC (State Of Charge) for primary frequency regulation is proposed. The dynamic model of BESS for primary frequency regulation is established. The regulation characteristics of virtual inertia and virtual droop control on the grid frequency deviation are compared and analyzed. A self-adaptive integrated control strategy of BESS considering SOC for primary frequency regulation is designed, in which a self-adaptive factor of a dynamic combination of input coefficient considering frequency deviation and its rate of change and feedback coefficient considering SOC is introduced. The input coefficients are adaptively adjusted by fuzzy logic controller and the feedback coefficients are adaptively adjusted by regression function. Finally, the simulation model is built to compare and analyze different control strategies under step and continuous load disturbance. The simulation results show that the proposed control strategy can adaptively control the output of BESS and effectively improve the primary frequency regulation effect.

Key words: battery energy storage system; primary frequency regulation; self-adaptive factor; integrated control strategy; state of charge




图 A1 CNN 示意图
Fig.A1 Schematic diagram of CNN




图 A2 LSTM 网络单元示意图
Fig.A2 Schematic diagram of LSTM network unit




图 A3 Bi-LSTM 网络示意图
Fig.A3 Schematic diagram of Bi-LSTM network




图 B1 4 种电池的预测结果

Fig.B1 Prediction results of four kinds of batteries




图 B2 Oxford 电池的预测结果

Fig.B2 Prediction results of Oxford batteries