

文章编号: 2095-4980(2025)02-0182-06

## 基于深度学习的电动汽车锂电池寿命预测模型

范晋衡<sup>1</sup>, 刘琦颖<sup>1</sup>, 马力<sup>1</sup>, 刘力豪<sup>2</sup>

(1. 广东电网有限责任公司 广州供电局, 广东 广州 510630; 2. 烟台海颐软件股份有限公司, 山东 烟台 264000)

**摘要:** 针对目前电动汽车锂电池剩余使用寿命预测存在预测性能低的问题, 提出一种基于混合深度学习的电动汽车锂电池剩余使用寿命预测模型。通过经验模态(EMD)分解将电池数据分解, 形成电池容量序列的高频和低频分量; 通过使用多层长短时记忆(LSTM)和 Elman 神经网络学习高频和低频电池容量特征, 提取电池容量高层表示; 通过叠加规则组合高频和低频预测结果, 实现电池剩余使用寿命高精度预测。实验结果表明, 所提混合深度学习检测模型在训练集产生的损失约为 7.87%。与支持向量机(SVM)、逻辑回归(LR)、循环神经网络(RNN)和 LSTM 模型相比, 所提混合深度学习模型综合指标性能更优, 平均绝对百分比误差(MAPE)仅为 1.438%。实验验证了所提模型的有效性及其实用性。

**关键词:** 电动汽车; 锂电池; 剩余使用寿命预测; 特征提取; 长短时记忆(LSTM)

中图分类号: TP393

文献标志码: A

doi: 10.11805/TKYDA2023204

## Lithium battery life prediction model for electric vehicles based on hybrid deep learning

FAN Jinheng<sup>1</sup>, LIU Qiying<sup>1</sup>, MA Li<sup>1</sup>, LIU Lihao<sup>2</sup>

(1. Guangzhou Power Supply Bureau, Guangdong Power Grid Corporation, Guangzhou Guangdong 510630, China;

2. Yantai Haiyi Software Co., Ltd., Yantai Shandong 264000, China)

**Abstract:** In response to the current issue of low prediction performance in the remaining service life of electric vehicle lithium batteries, a hybrid deep learning model for predicting the remaining service life of electric vehicle lithium batteries is proposed. The model employs Empirical Mode Decomposition(EMD) to decompose battery data, forming high-frequency and low-frequency components of the battery capacity sequence. It utilizes Multilayer Long Short-Term Memory(MLSTM) and Elman neural networks to learn high-frequency and low-frequency battery capacity characteristics, extracting high-level representations of battery capacity. It combines high-frequency and low-frequency prediction results through stacking rules to achieve high-precision prediction of the battery's remaining service life. Experimental results show that the loss generated by the proposed hybrid deep learning detection model in the training set is approximately 7.87%. Compared with Support Vector Machine(SVM), Logistic Regression(LR), Recurrent Neural Network(RNN), and LSTM models, the proposed hybrid deep learning model demonstrates superior comprehensive performance indicators, with an Mean Absolute Percentage Error(MAPE) of only 1.438%. The experiments validate the effectiveness and practicality of the proposed model.

**Keywords:** electric vehicles; lithium battery; prediction of remaining service life; feature extraction; Long Short Term Memory(LSTM)

相对于其他电池化学物质, 锂离子电池<sup>[1]</sup>具有高能量和高功率密度、低自放电率和无记忆效应的优点, 已广泛用于电动汽车的电源中。但由于副反应的存在, 锂电池在整个使用寿命内承受容量衰减或内阻增加方面的持续性能下降, 这将相应缩短电动汽车每次充电的续航里程和功率能力, 是阻碍其大规模采用的主要因素<sup>[2]</sup>。通常, 20%的容量衰减或100%的内阻增加表明电动汽车应用中锂离子电池的寿命终止。此外, 老化的电池更容易

收稿日期: 2023-07-25; 修回日期: 2023-09-11

基金项目: 南方电网广州供电局科技资助项目(GZHKJXM20210055)

发生故障，甚至出现严重的安全问题<sup>[3-5]</sup>。因此，电池健康状况(State-of-Health, SOH)监测和剩余使用寿命(Remaining Useful Life, RUL)预测对确定电池系统的维护和更换时间至关重要，对确保电动汽车中电池系统的安全可靠运行具有重要意义。

目前，许多学者对电池 RUL 预测进行了研究。文献[6]提出了基于多健康特征融合的锂电池 SOH 和 RUL 预测方法。该方法建立多项式回归模型对间接健康特征随电池循环次数增加的变化趋势进行预测，但间接健康特征通常是非平稳的数据，且被噪声和异常值破坏，预测精确度还有待提升。文献[7]提出一种基于主成分分析的锂离子电池 RUL 间接预测模型，但该模型需要大量的记录数据预测电池退化趋势，且短期内电池的 RUL 预测能力有限。文献[8]提出一种基于自注意力机制的双向门控循环单元网络模型。深度神经网络模型可有效学习电池数据的短期依赖性，但电池数据特征复杂，直接学习法学习原始数据的预测能力较低。

为提高锂电池 RUL 预测性能，本文提出一种基于混合深度学习模型的电动汽车锂电池 RUL 预测模型。该模型基于经验模态分解(EMD)、多层长短时记忆网络(Multilayer LSTM, MLSTM)和 Elman 神经网络实现电池 RUL 预测。

### 1 电池老化试验与数据收集

为研究锂离子电池的降解特性，将 8 个额定容量为 1.1 (A·h) 的棱柱形电池均匀地分为 2 组进行电池老化测试。测试方案由标准充电、放电以及其间的休息时间重复循环组成。放电和充电的截止电压分别设定为 2.7 V 和 4.2 V，表 1 为测试电池单元参数设置。

表 1 测试电池单元的参数设置  
Table1 Parameter settings for testing battery cells

battery parameters	value
rated capacity/(mA·h)	1 100
chemical composition	LiCoO <sub>2</sub> cathode and graphite anode
weight/g	21.1
size	5.4 mm×33.6 mm×50.6 mm

试验中，电池充电采用恒流恒压充电协议，即以 0.55 A 的恒定电流对电池充电，直到 4.2 V 的截止电压；然后对电压进行箝位，直到充电电流降至 0.05 A 以下。测试的电池分别在 25 °C 的恒定环境温度下以 1C(C 表示电池的额定容量(Capacity)的放电倍率)和 0.5C 放电。值得注意的是，以安培为单位的 1C 放电电流等于以 (A·h) 为单位的测试电池的额定容量。

老化试验中，选取电池 CS2#33 和 CS2#34 在 0.5C 下放电，CS2#36 和 CS2#37 在 1C 下放电。同时，从 CS2#33 和 CS2#36 收集的数据用于实时预测电池 RUL，而 CS2#34 和 CS2#37 用于模型测试。

### 2 混合 Elman-LSTM 预测模型

为提高电动汽车锂电池寿命预测准确率，本文提出一个混合 Elman-LSTM 电动汽车锂电池寿命预测模型。预测模型结构如图 1 所示。首先，使用 EMD 算法<sup>[9]</sup>将不同循环下测得的电池容量分解为高频分量、低频分量和趋势分量；其次，由 Elman 神经网络预测低频分量和趋势分量，由多层 LSTM 神经网络预测高频分量；最后，通过叠加规则进行预测结果组合，最终形成电池 RUL 预测结果。

#### 2.1 电池序列数据分解

给定原始时间序列数据  $x(t)$ ，EMD 执行过程可描述如下：

步骤 1：确定所有局部最大值点和最小值点后，应用三次样条插值获得上包络  $x_H(t)$  和下包络  $x_L(t)$ 。2 个包络的平均值  $m(t)$  为：

$$m(t) = \frac{x_H(t) + x_L(t)}{2} \tag{1}$$

步骤 2：计算  $m(t)$  和原始时间序列数据  $x(t)$  之间的差值  $x_1(t)$ ，并确定  $x_1(t)$  是否满足固有模态函数(Intrinsic Mode function, IMF)的 2 个条件。如果符合，则将其视为第 1 个 IMF，并用  $c_1(t)$  表示；否则，重复上述步骤，直到找到满足 IMF 2 个条件的  $x_1(t)$ 。此时，原始时间序列数据  $x(t)$  和  $c_1(t)$  之间的差值  $r_1(t)$  为：

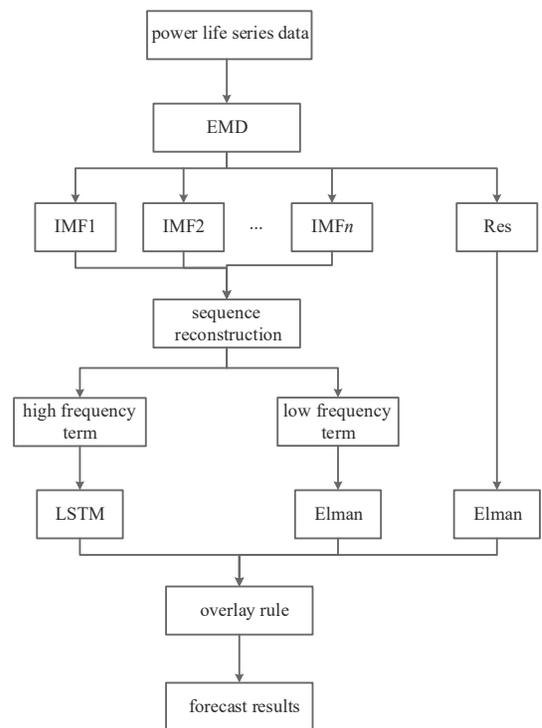


Fig.1 Hybrid Elman-LSTM battery life prediction model  
图 1 混合 Elman-LSTM 电池寿命预测模型

$$x_1(t) = x(t) - m(t) \quad (2)$$

$$r_1(t) = x(t) - c_1(t) \quad (3)$$

步骤3: 将  $r_1(t)$  作为新的时间序列数据, 继续执行步骤1~步骤2。筛选过程的终止条件为标准偏差(Standard Deviation, SD)小于极限值:

$$D_s = \sum_{i=0}^N \left[ \frac{|c_{(i-1)}(t) - c_i(t)|^2}{c_{(i-1)}^2(t)} \right], i=1, 2, \dots \quad (4)$$

式中:  $c_{(i-1)}(t)$  为第  $i-1$  个 IMF;  $c_i(t)$  为第  $i$  个 IMF;  $N$  为时间序列数据的总数。一般情况下,  $D_s$  的参考值通常设置在 0.2~0.3 之间。

步骤4: 重复上述筛选过程  $n$  次, 原始时间序列  $x(t)$  可重构如下:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (5)$$

式中  $r_n(t)$  为第  $i$  个趋势分量, 通常用 Res 表示。

## 2.2 Elman 神经网络预测

标准 Elman 神经网络结构如图 2 所示。为将 Elman 神经网络用于电池 RUL 预测, 将电池容量序列数据 IMF 中低频分量和趋势分量作为输入特征。Elman 神经网络<sup>[10]</sup>的详细计算过程可表示为:

$$\mathbf{h}_n = \sigma_h(\mathbf{W}_h \mathbf{x}_n + \mathbf{U}_h \mathbf{h}_{n-1} + \mathbf{b}_h) \quad (6)$$

$$\mathbf{y}_n = \sigma_y(\mathbf{W}_y \mathbf{h}_n + \mathbf{b}_y) \quad (7)$$

式中:  $\mathbf{x}_n$  为电池容量序列向量;  $\mathbf{h}_n$  为隐含层向量;  $\mathbf{y}_n$  为预测的容量序列向量;  $\mathbf{W}$  和  $\mathbf{U}$  为加权矩阵;  $\mathbf{b}_h$  和  $\mathbf{b}_y$  为偏置向量;  $\sigma$  为神经网络的激活函数:

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

## 2.3 MLSTM 网络预测

为提高经典 LSTM 的学习效率, 提出一种 MLSTM 网络预测模型, 其结构如图 3 所示。模型包括 3 个功能模块: 输入层、隐藏层、输出层。输入层负责对高频特征数据进行初步处理, 满足网络输入要求; 隐藏层使用多个 LSTM 单元构建预测网络; 输出层提供预测结果。网络训练采用随机梯度下降法(Stochastic Gradient Descent, SGD)作为优化器。

LSTM<sup>[11]</sup>单元中, 状态单元通过遗忘门和输入门控制。遗忘门决定了前一时刻  $\mathbf{h}_{n-1}$  的电池状态可以保持到当前时刻  $\mathbf{h}_n$  的程度。对于电池 RUL 预测, 遗忘门控制前一时刻的电池容量, 以生成下一时刻电池容量预测的输入参数。遗忘门  $\mathbf{f}_n$  由式(9)给出:

$$\mathbf{f}_n = \sigma(\mathbf{W}_f \cdot [\mathbf{h}_{n-1}, \mathbf{x}_n] + \mathbf{b}_f) \quad (9)$$

式中:  $\mathbf{W}_f$  和  $\mathbf{b}_f$  分别为遗忘门的权重矩阵和偏置;  $[\mathbf{h}_{n-1}, \mathbf{x}_n]$  为输入矢量, 该矢量由电池容量序列和循环数据组成。 $\mathbf{W}_f$  的维数与  $[\mathbf{h}_{n-1}, \mathbf{x}_n]$  有关, 可重写为:

$$[\mathbf{W}_f] \begin{bmatrix} \mathbf{h}_{n-1} \\ \mathbf{x}_n \end{bmatrix} = [\mathbf{W}_{fh} \quad \mathbf{W}_{fx}] \begin{bmatrix} \mathbf{h}_{n-1} \\ \mathbf{x}_n \end{bmatrix} \quad (10)$$

类似地, 输入门以 S 形函数的形式控制状态单元, 可描述为:

$$\mathbf{i}_n = \sigma(\mathbf{W}_i \cdot [\mathbf{h}_{n-1}, \mathbf{x}_n] + \mathbf{b}_i) \quad (11)$$

式中:  $\mathbf{i}_n$  为输入门向量;  $\mathbf{W}_i$  和  $\mathbf{b}_i$  分别为输入门的权重矩阵和偏置矩阵。

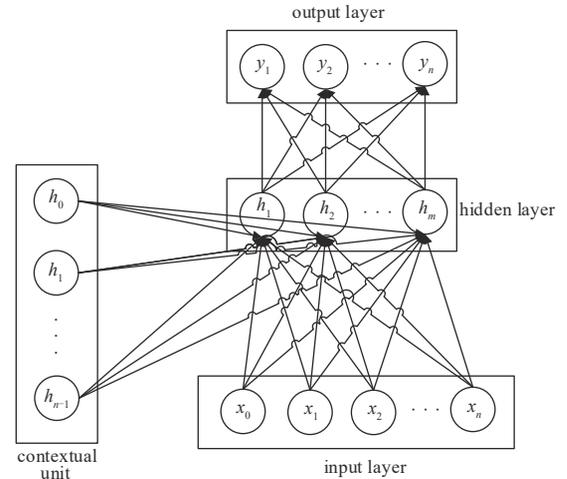


Fig.2 Standard Elman neural network structure  
图2 标准Elman神经网络结构

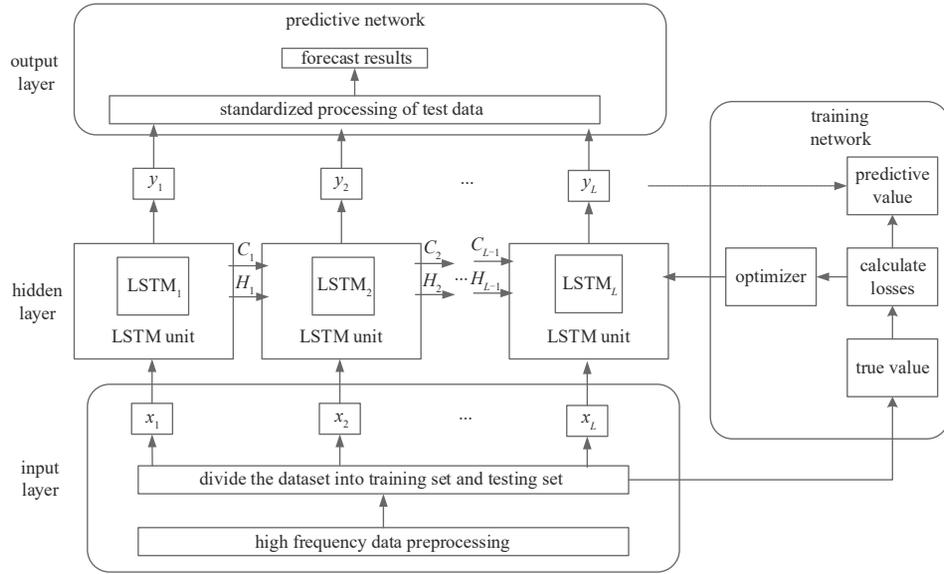


Fig.3 Structure diagram of multi-layer LSTM prediction model  
图3 多层LSTM预测模型结构图

输入门使用 tanh 函数计算当前输入状态单元，且由遗忘门、输入门以及电流输入序列共同确定：

$$\tilde{S}_n = \tanh(W_c \cdot [h_{n-1}, x_n] + b_c) \tag{12}$$

$$S_n = f_n S_{n-1} + i_n \tilde{S}_n \tag{13}$$

式中： $S_n$ 为状态门向量； $\tilde{S}_n$ 为当前状态单元； $S_{n-1}$ 为长期存储器状态单元； $W_c$ 和 $b_c$ 为状态门权重矩阵和偏置。

LSTM中，输入门可防止无关信息影响记忆过程，并可通过遗忘门保留长期信息；同时，长期信息会影响通过输出门控制的当前输出。LSTM的最终输出由输出门和更新状态单元确定：

$$O_n = \sigma(W_o [h_{n-1}, x_n]) + b_o \tag{14}$$

$$h_n = O_n \tanh(S_n) \tag{15}$$

式中： $O_n$ 为输出门向量； $W_o$ 和 $b_o$ 为输出门权重矩阵和偏置。

多层 LSTM 网络采用交叉熵损失最小化标签输出结果和预测结果之间的预测误差：

$$L_1 = \sum_{x_i} -y_i \log(\hat{y}_i) \tag{16}$$

式中： $x_i$ 为训练数据； $y$ 为标签结果； $\hat{y}$ 为模型的预测结果。

### 2.4 叠加规则

EMD 获得的分量具有相对稳定的频率，最终预测结果可表示为 Elman 神经网络和 LSTM 预测分量的叠加，具体叠加规则为：

$$y_{all} = y_1^{MLSTM} + y_2^{MLSTM} + \dots + y_n^{MLSTM} + y_1^{Elman} + y_2^{Elman} + \dots + y_m^{Elman} + y_0^{Res} \tag{17}$$

式中： $y_{all}$ 为最终电池寿命预测结果； $y_i^{MLSTM}(i=1,2,\dots,n)$ 为由 MLSTM 模型产生的第  $i$  个预测结果； $y_j^{Elman}(j=0,2,\dots,m)$ 为由 Elman 神经网络模型产生的预测结果； $y_0^{Res}$ 为趋势分量预测结果。

## 3 仿真与分析

### 3.1 数据集与实验环境

首先，基于不同放电速率的数据集对所提出的混合模型进行训练，并将其用于电池 RUL 预测。数据集包含约 360 组电池容量数据以及温度湿度相关数据。实验时将 CS2#33 和 CS2#36 收集的数据集样本用于模型训练，CS2#34 和 CS2#37 数据集用于电池 RUL 预测模型测试，训练集和测试集比例约为 2:1。

仿真软件环境为 pycharm 建立的算法框架，并由 python 基于 pytorch 搭建学习算法；同时，算法运行硬件环境为：Intel Core i9-9280X CPU，内存 32G；操作系统为 Ubuntu 18.04 64 位；显卡 2 块，为 NVIDIA RTX2080Ti 11G。

### 3.2 实验设置

为完成模型的训练，具体的实验设置为：首先，处理训练集数据，并基于 EMD 对原始电池数据进行分解；进一步，将分解获得的低频和趋势分量特征代入 Elman 神经案例模型进行训练。同时，将高频特征代入 LSTM 预测模型进行训练。网络的序列数据维度设置为 128，特征参数包括历史序列数据和相关因素数据(温度和湿度)的统计数据，历史数据的时间跨度设置为 8；最后，将输出的结果经叠加规则形成最终预测结果。

模型训练过程中参数设置为：LSTM 层设置为 2，初始学习率设置为  $10^{-3}$ ，数据批量处理大小设置为 50，学习率衰减倍数设置为 0.2，正则化参数设置为  $10^{-5}$ ，最大迭代次数为 15 000。训练时使用 Adam 算法优化模型完成网络参数的更新和优化。

### 3.3 指标选取

为验证所提模型的有效性，将所提模型预测结果与 RNN、LSTM 等模型进行比较。同时，选取平均绝对百分比误差(MAPE)、平均绝对误差(Mean Absolute Error, MAE)和均方根误差(Root Mean Square Error, RMSE)评估预测性能。其中，MAPE 表示预测和目标之间的绝对平均预测偏差，MAE 和 RMSE 评估预测结果的预测精确度和性能。

### 3.4 结果与分析

不同模型训练集和测试集损失对比如图 4 所示。可以看出，所提混合深度学习模型训练性能优于 RNN 和 LSTM 模型。RNN 和 LSTM 在训练集上的最低损失约为 18.43% 和 16.69%；在测试集中，RNN 的最低损失的最大值约为 18.48%，；其次为 LSTM 模型，约为 17.58%。这主要是因为 RNN 学习了太多训练数据集的特征，存在过拟合问题，导致在测试数据集中性能下降严重；LSTM 模型较 RNN 模型有一定缓解，但性能提升有限。与 RNN 和 LSTM 不同，所提混合深度学习检测模型在训练集产生的损失约为 7.87%，但在测试集上的损失约为 11.13%。训练集和测试集之间的误差约为 3.26%。试验结果表明，所提混合深度学习检测模型更多关注电池数据高质量的特征，从而获得更优的训练性能。

将本文所提算法与经典机器学习模型支持向量机(SVM)、逻辑回归(LR)、RNN、LSTM 等深度学习模型进行综合性能对比。同时，为比较所提 EMD 对原始电池数据分解的有效性，实验时对原始数据以及所提 EMD 对原始电池数据进行分解下的数据性能进行分析。

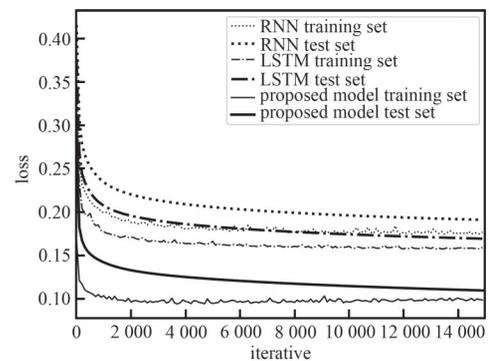


Fig.4 Comparison of loss between training and testing sets of different models

图 4 不同模型训练集和测试集损失对比

表 2 不同模型综合指标统计情况

Table 2 Statistics of comprehensive indicators for different models

model	index	raw data	EMD decomposition
SVM	MAPE/%	4.850	4.520
	MAE/(A·h)	0.045	0.042
	RMSE/(A·h)	0.988	0.915
LR	MAPE/%	5.660	5.630
	MAE/(A·h)	0.056	0.053
	RMSE/(A·h)	1.163	1.148
RNN	MAPE/%	4.150	3.470
	MAE/(A·h)	0.037	0.033
	RMSE/(A·h)	1.281	1.118
LSTM	MAPE/%	2.990	1.615
	MAE/(A·h)	0.030	0.014
	RMSE/(A·h)	0.974	0.202
proposed model	MAPE/%	2.490	1.438
	MAE/(A·h)	0.020	0.012
	RMSE/(A·h)	0.339	0.101

不同模型综合指标统计情况如表 2 所示。可以看出，SVM 和 LR 综合性能明显低于深度学习模型(RNN 和 LSTM)。原因是电池数据维度高，传统机器学习模型 SVM 和 LR 无法更深层次理解特征与特征之间的关系。同

时, 原始数据和 EMD 分解相比, 利用 EMD 分解后模型综合性能更优。与 SVM、LR、RNN 和 LSTM 模型相比, 所提混合深度学习模型综合指标性能更优, MAPE 仅为 1.438%。原因是所提基于混合深度学习的电池寿命预测模型更容易关注且有效学习包含关键事件的信息。实验结果验证了所提模型的可行性和有效性。

#### 4 结论

本文对电动汽车锂电池寿命预测进行了研究与分析, 建立了一种基于混合深度学习的电池寿命预测模型。该模型可基于 EMD 对原始电池数据进行分解, 将分解获得的低频和趋势分量特征代入 Elman 神经案例模型进行训练。同时, 将高频特征带入 LSTM 预测模型进行训练。模型可有效学习电池数据特征信息, 从而高效准确地对电池寿命进行预测。

所提混合深度学习模型的故障检测模型可为电动汽车电池数据分析以及电池安全管理提供一定借鉴作用。

#### 参考文献:

- [1] 孔德全,黄小龙,薛少华,等. 基于三元锂离子电池的变电站直流应急电源自动维护研究[J]. 自动化技术与应用, 2023,42(2): 129-131. (KONG Dequan,HUANG Xiaolong,XUE Shaohua,et al. Research on automatic maintenance of DC emergency power supply in substation based on ternary Li-ion battery[J]. Techniques of Automation and Applications, 2023,42(2):129-131.)
- [2] 郭桐,刘涛,方德宇,等. 锂离子电池健康评估研究进展[J]. 电池工业, 2023,27(1):48-54. (GUO Tong,LIU Tao,FANG Deyu,et al. Research progress in health assessment of lithium-ion batteries[J]. Chinese Battery Industry, 2023,27(1):48-54.)
- [3] 刘祖明,李杰慧,孙建平,等. 新型风光抽水蓄能系统研究[J]. 云南师范大学学报(自然科学版), 2023,43(2):11-14. (LIU Zuming,LI Jiehui,SUN Jianping,et al. Research on a new type of wind & PV powered pumping energy storage system[J]. Journal of Yunan Normal University(Natural Sciences Edition), 2023,43(2):11-14.) doi:10.7699/j.ynnu.ns-2023-018.
- [4] 陈辉,李艳,林思远. 大数据驱动下全接触渠道的电力客户精准画像[J]. 云南师范大学学报(自然科学版), 2023,43(2):34-38. (CHEN Hui,LI Yan,LIN Siyuan. Construction of accurate portrait system of power customers through full contact channels driven by big data[J]. Journal of Yunan Normal University(Natural Sciences Edition), 2023,43(2):34-38.)
- [5] 钟建翔,余少锋,廖崇阳,等. 基于云计算的电力设备智能监测系统[J]. 云南师范大学学报(自然科学版), 2022,42(3):37-41. (ZHONG Jianxu,YU Shaofeng,LIAO Chongyang,et al. Research on power equipment condition monitoring system based on cloud computing[J]. Journal of Yunan Normal University(Natural Sciences Edition), 2022,42(3):37-41.)
- [6] 武剑,薛玉石,山春风,等. 基于相电流工频变化量极性的微电网纵联保护方案[J]. 微型电脑应用, 2022,38(9):117-120. (WU Jian,XUE Yushi,SHAN Chunfeng,et al. Pilot protection scheme for microgrid based on the polarity of the power frequency variation of phase current[J]. Microcomputer Applications, 2022,38(9):117-120.) doi:10.3969/j.issn. 1007-757X.2022.09.034.
- [7] 朱成杰,王鸣雁,吴章玉. 基于主成分分析的锂离子电池 RUL 间接预测[J]. 廊坊师范学院学报(自然科学版), 2022,22(1):30-36. (ZHU Chengjie,WANG Mingyan,WU Zhangyu. Indirect prediction of RUL for Li-ion batteries based on principal component analysis[J]. Journal of Langfang Normal University(Natural Science Edition), 2022,22(1):30-36.)
- [8] 朱梦雨,陈富安. 基于 SAM-BiGRU 网络的锂电池 RUL 预测[J]. 电源技术, 2023,47(2):199-203. (ZHU Mengyu,CHEN Fu'an. RUL prediction of lithium battery based on SAM-BiGRU network[J]. Chinese Journal of Power Sources, 2023,47(2):199-203.) doi:10.3969/j.issn.1002-087X.2023.02.015.
- [9] GUO Runxia,WANG Yu,ZHANG Haochi,et al. Remaining useful life prediction for rolling bearings using EMD-RISI-LSTM[J]. IEEE Transactions on Instrumentation and Measurement, 2021(70):1-12. doi:10.1109/TIM.2021.3051717.
- [10] ZHOU Li,FAN Qinwei,HUANG Xiaodi,et al. Weak and strong convergence analysis of Elman neural networks via weight decay regularization[J]. Optimization, 2023,72(9):2287-2309.
- [11] SUN Hanlei, SUN Jianrui, ZHAO Kun, et al. Data-driven ICA-Bi-LSTM-combined lithium battery SOH estimation[J]. Mathematical Problems in Engineering, 2022,2022(1):9645892.

#### 作者简介:

范晋衡(1988-), 男, 本科, 工程师, 主要研究方向为新能源和电力市场, email:clx3112608@163.com

马力(1984-), 男, 硕士, 高级工程师, 主要研究方向为新能源。

刘琦颖(1992-), 女, 本科, 工程师, 主要研究方向为新能源。

刘力豪(1988-), 男, 本科, 工程师, 主要研究方向为咨询服务、新能源等。