

本文引用格式：黄晓智,张华明,黄艺航,等.基于 Bi-LSTM-Dropout 的蓄电池剩余使用寿命预测方法[J].自动化与信息工程, 2024,45(1):42-46;60.

HUANG Xiaozhi, ZHANG Huaming, HUANG Yihang, et al. Prediction method of battery remaining useful life based on Bi-LSTM-dropout[J]. Automation & Information Engineering, 2024,45(1):42-46;60.

基于 Bi-LSTM-Dropout 的蓄电池剩余使用寿命预测方法

黄晓智¹ 张华明² 黄艺航¹ 许志杰¹

(1.广东工业大学机电工程学院, 广东 广州 510006

2.广东工业大学先进制造学院, 广东 揭阳 522000)

摘要: 蓄电池剩余使用寿命预测对能源的安全性和可持续发展至关重要。该文提出一种蓄电池剩余使用寿命的预测方法, 利用蓄电池的历史运行数据和充放电周期, 构建 Bi-LSTM-Dropout 网络模型。利用 Bi-LSTM 提取时间序列中蓄电池长期依赖的特征, 采用 Dropout 优化算法降低 Bi-LSTM 网络模型的复杂度, 提高模型的泛化能力。实验结果表明, 该方法在测试集上的准确率达 96.2%, 实现了蓄电池剩余使用寿命的精确预测。

关键词: 蓄电池; 剩余使用寿命预测; Bi-LSTM; Dropout 优化算法

中图分类号: TM912

文献标志码: A

文章编号: 1674-2605(2024)01-0007-06

DOI: 10.3969/j.issn.1674-2605.2024.01.007

Prediction Method of Battery Remaining Useful Life Based on Bi-LSTM-Dropout

HUANG Xiaozhi¹ ZHANG Huaming² HUANG Yihang¹ XU Zhijie¹

(1.School of Electromechanical Engineering, Guangdong University of Technology, Guangzhou 510006, China

2.School of Advanced Manufacturing Guangdong University of Technology, Jieyang 522000, China)

Abstract: The prediction of the remaining useful life of battery is crucial for the safety and sustainable development of energy. This article proposes a prediction method for the remaining useful life of battery, using historical operating data and charging and discharging cycles of battery to construct a Bi-LSTM-Dropout network model. Using Bi-LSTM to extract long-term dependent features of battery in time series, using Dropout optimization algorithm to reduce the complexity of Bi LSTM network model and improve its generalization ability. The experimental results show that the accuracy of this method on the test set reaches 96.2%, achieving accurate prediction of the remaining useful life of the battery.

Keywords: battery; remaining useful life; Bi-LSTM; dropout optimization algorithm

0 引言

蓄电池组作为变电站直流电源系统的关键设备, 在交流电源发生断电时, 能为重要负载设备提供不间断的直流供电保障^[1]。目前, 变电站的通信用蓄电池每年都要进行充放电核容和激活, 需要耗费 2 人 3 日的工作量^[2]。且仅依赖人工使用放电仪表进行核容, 无法准确地掌握蓄电池的健康情况^[3]。

近年来, 国内外学者对蓄电池剩余使用寿命 (re-

maining useful life, RUL) 预测进行了大量的研究, 主要方法包括基于物理模型法和基于数据驱动法^[4]。基于物理模型法通过研究电池的内部状态, 结合相关算法预测电池 RUL^[5]。文献[6]利用简化的电化模型和双非线性滤波器, 结合电池的荷电状态 (state of charge, SOC) 和健康状态 (state of health, SOH) 估计算法, 实现电池 RUL 的预测。文献[7]基于固体电解质界面副反应建立电化学-热耦合模型, 能有效地模拟固体

电解质界面副反应对锂电池容量衰减的影响。但基于物理模型法预测蓄电池 RUL 存在建模过程复杂、成本高等问题。基于数据驱动法通过蓄电池的历史运行数据来学习规律,以适应不同条件的电池工况,能够快速、准确地预测蓄电池 RUL。基于数据驱动法主要包括深度学习、支持向量机和机器学习等方法。QU^[8]等利用长短时记忆网络和注意力机制建模,同时引入粒子群优化算法,对锂电池 RUL 进行预测,SOH 进行监测,该模型的均方根误差为 3.62%,实现了锂电池 RUL 的准确预测。REN 等^[9]结合卷积神经网络和长短时记忆网络来预测锂电池 RUL,采集锂电池实际运行数据进行训练,预测结果的均方根误差为 4.80%。但基于数据驱动法存在数据样本较少的问题,导致模型容易出现过拟合现象,降低网络模型性能。

本文采用基于数据驱动法来预测蓄电池 RUL,提出一种融合双向长短时记忆 (bi-directional long short-term memory, Bi-LSTM) 网络与 Dropout 优化算法的蓄电池 RUL 预测方法。通过蓄电池历史运行数据和充放电周期,建立 Bi-LSTM-Dropout 网络模型,利用 Bi-LSTM 提取时间序列中蓄电池长期依赖的特征,同时引入 Dropout 优化算法提高 Bi-LSTM 网络模型的泛化能力,实现蓄电池 RUL 的精确预测。

1 模型原理

1.1 Bi-LSTM 网络

Bi-LSTM 网络包含 2 个 LSTM 单元:一个 LSTM 单元按时间序列的正向顺序处理输入数据;另一个 LSTM 单元按时间序列的逆序处理输入数据。Bi-LSTM 网络结构如图 1 所示。

这种双向处理数据的方式使 Bi-LSTM 网络能够同时利用过去和未来的数据,提高了对长时间序列数据的学习能力^[10]。

LSTM 单元主要由遗忘门、记忆门和输出门组成,结构图如图 2 所示。通过这些门的配合,LSTM 能选择性地遗忘历史信息、保留输入信息,输出需要的信息^[11]。

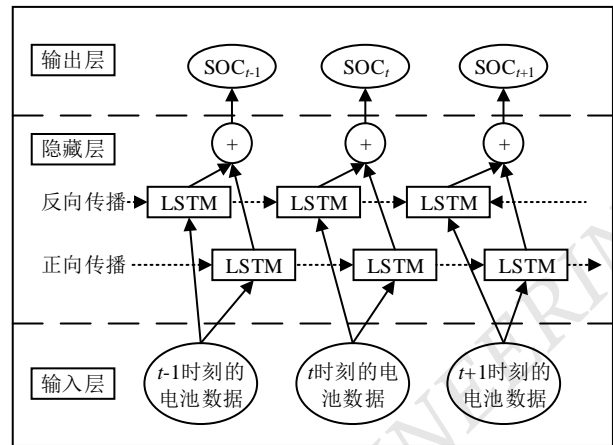


图 1 Bi-LSTM 网络结构图

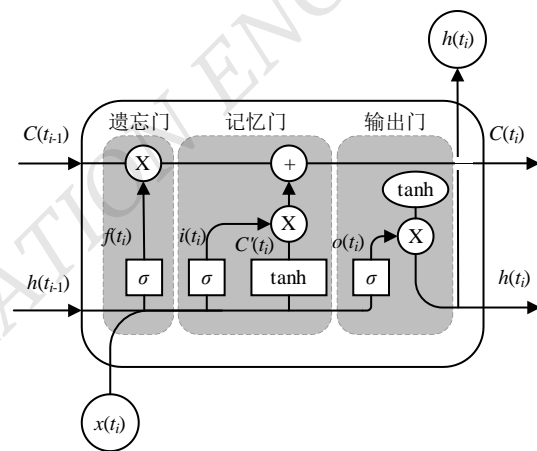


图 2 LSTM 单元结构图

1.2 Dropout 优化算法

Bi-LSTM 网络随着网络层数增加,网络结构也更加复杂。此外,变电站蓄电池组长期处于浮充状态,运行周期长,可获得的蓄电池样本数据较少^[12],导致 Bi-LSTM 网络模型易产生过拟合现象。为此,本文引入 Dropout 优化算法,提升 Bi-LSTM 网络模型的泛化性能。Dropout 优化算法示意图如图 3 所示。

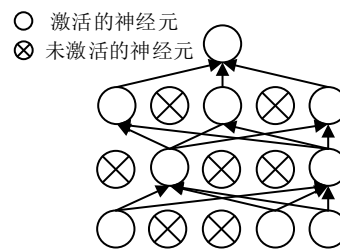


图 3 Dropout 优化算法示意图

Dropout 优化算法在网络训练过程中,按丢弃概率屏蔽部分神经元的输出,减少模型的复杂度,避免陷入局部最优解,从而防止模型过拟合。

定义神经元 i 在第 t 时刻的连接强度 $S_i(t)$ 的计算公式为

$$S_i(t) = \sum_j W_{ij}(t)A_j(t) \quad (1)$$

式中: $W_{ij}(t)$ 为神经元 i 与神经元 j 的权重, $A_j(t)$ 为神经元 j 在第 t 次迭代的激活状态, 激活状态更新公式为

$$A_i(t+1) = \begin{cases} 0, & \text{if } p \geq \lambda \\ \frac{x}{1-p}, & \text{其他} \end{cases} \quad (2)$$

式中: p 为丢弃概率, x 为神经元输入, λ 为概率阈值。

当 p 大于概率阈值 λ 时, 该神经元在本次迭代中不激活, 否则该神经元以输入 $x/(1-p)$ 作为激活状态。

2 Bi-LSTM-Dropout 网络模型

2.1 模型结构

Bi-LSTM-Dropout 网络模型采用基于序列模型端到端的架构, 主要由输入层、隐藏层、全连接层和输出层组成, 结构如图 4 所示。

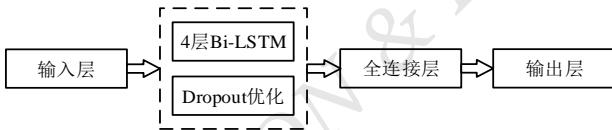


图 4 Bi-LSTM-Dropout 网络模型结构

第一层为输入层, 以蓄电池历史使用数据和充放电周期为输入序列, 输入维度为 input_size , 表示每个时间步的输入特征维度。

第二层由 4 层 Bi-LSTM-Dropout 层组成, 利用该网络层对第一层的输入序列分别进行前向和后向的特征提取, 得到前向和后向 LSTM 的特征输出, 包括蓄电池的电压、电流、温度、充放电周期等数据。将两个方向 LSTM 学习到的特征表示进行拼接, 融合前向、后向的上下文信息。在每层 Bi-LSTM 之间引入

Dropout, 按照丢弃概率使网络层中一些神经元的输出为 0, 防止模型过拟合。

第三层为全连接层, 其将 Bi-LSTM-Dropout 层的神经元输出连接到本层的每个神经元, 作为回归分类器, 用于预测连续的蓄电池 RUL。

最后一层为输出层, 输出经过全连接层处理后的蓄电池 RUL 预测值, 其维度为 1。

2.2 网络建模过程

Bi-LSTM-Dropout 网络模型建模过程如图 5 所示。

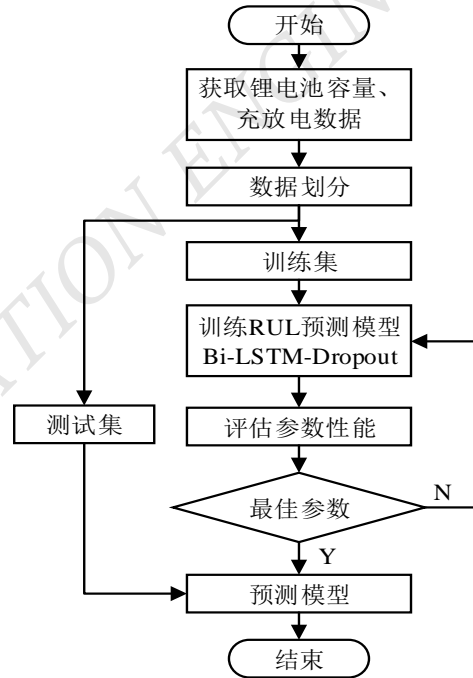


图 5 Bi-LSTM-Dropout 网络模型建模过程

Bi-LSTM-Dropout 网络模型建模步骤如下:

- 1) 获取数据样本, 在公开数据集 (NASA 锂电池数据集) 中提取蓄电池的历史运行数据 (包括充放电的电压、电流和温度) 和充放电周期等数据;
- 2) 划分数据集, 将获取的数据划分为训练集和测试集;
- 3) 训练 Bi-LSTM-Dropout 网络模型, 通过调整模型参数, 使模型对训练集数据的拟合度不断提高, 从而减小训练集的损失函数值; 设置 Dropout 丢弃概率, 丢弃部分神经元, 减小过拟合现象;
- 4) 调整模型参数: 通过损失函数、准确率等判断 Bi-LSTM-Dropout 网络模型的性能是否达到最优,

如果是则进入下一步，否则更新 Bi-LSTM-Dropout 网络模型中的神经元状态和参数，重新训练模型；

5) 模型预测效果：通过均方根误差、平均绝对误差和准确率在测试集上对 Bi-LSTM-Dropout 网络模型效果进行测试，评估模型的预测能力。

通过循环迭代训练、调参等步骤，可获得性能最优的 Bi-LSTM-Dropout 的网络模型。

3 实验结果与分析

3.1 实验数据

本文实验数据主要来自 NASA Ames Prognostics 数据中心的锂电池数据集，选择数据集中的 B0005、B0006、B0007 和 B0018 号 4 个锂电池作为研究对象。在室温 24 °C 下测量锂电池的充放电的电压、电流、温度等数据。当锂电池的剩余容量降至额定容量的 70% 时，定义该锂电池达到失效阈值。将该数据集前 95 个循环次数的数据作为训练集，其余循环次数数据作为测试集，用该数据集验证 Bi-LSTM-Dropout 网络模型预测锂电池 RUL 的效果。

B0005、B0006、B0007 和 B0018 号锂电池的容量变化趋势如图 6 所示。

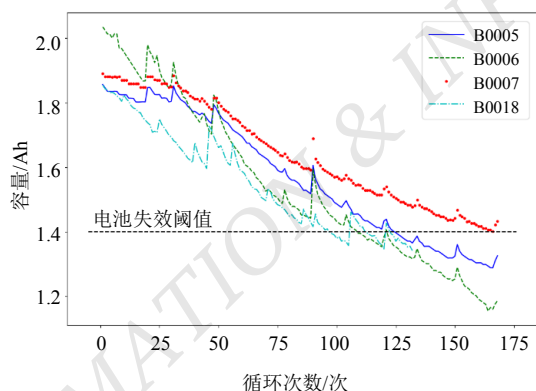


图 6 锂电池容量变化趋势

锂电池历史运行数据（包括充放电的电压、电流和温度）和充放电周期（循环次数）作为 Bi-LSTM-Dropout 网络模型的输入，锂电池实际容量作为模型输出。

3.2 实验平台及参数设置

实验平台配置如下：操作系统为 Window 11 专

业版，处理器为 intel i7-12700KF，独立显卡为 RTX 3080 12 GB 图形处理器，内存为 64 GB DDR5 3600 MHz，算力为 29.77 TFLOPS。在 Jupyter notebook 中基于 TensorFlow 框架构建 Bi-LSTM-Dropout 网络模型，并进行模型训练。Bi-LSTM-Dropout 网络模型参数设置如表 1 所示。

表 1 Bi-LSTM-Dropout 网络模型参数设置

模型参数	值
输入层节点数	5
隐藏层节点数	700
输出层节点数	1
学习率	0.001
epoch	500
批大小	25
Dropout 丢弃率	0.3
优化器	Adam

由表 1 可知：输入层节点数 5 表示输入的时间步数；隐藏层包含 4 层 Bi-LSTM 和 1 个全连接层，其中 Bi-LSTM 节点数为 650 个，全连接层节点数为 50 个；输出层输出锂电池的实际容量，节点数为 1 个；设置学习率为 0.001，迭代次数为 500 次(epoch=500)，批大小为 25；为防止过拟合，Dropout 的丢弃概率为 0.3；选择 Adam 优化器来调整模型参数。

3.3 实验结果分析

本实验选取均方根误差（root mean square error, RMSE）、平均绝对误差（mean absolute error, MAE）和准确率（accuracy, ACC）作为评价指标。其中，RMSE 反映电池预测 RUL 与真实 RUL 偏差的程度；MAE 反映电池预测 RUL 与真实 RUL 差值的平均值；ACC 反映模型正确预测电池 RUL 样本数量占总样本数量的比例。RMSE 和 MAE 的值越小，表示预测精度越高；ACC 越高，则表示与真实值越接近。计算公式为

$$R_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$M_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

式中： y_i 为样本 i 的实际 RUL, \hat{y}_i 为样本 i 的预测 RUL, n 为样本总数。

$$A_{\text{ACC}} = \frac{TP + TN}{S} \quad (5)$$

式中： TP 为正确预测电池 RUL 的正样本数量, TN 为正确预测电池 RUL 的负样本数量, S 为总样本数。

为验证 Bi-LSTM-Dropout 网络模型预测锂电池 RUL 的效果, 利用 RNN、LSTM、Bi-LSTM 网络模型在测试集上进行对比实验, 实验结果如表 2 所示。

表 2 对比实验结果

网络模型	ACC%	RMSE	MAE
RNN	82.3	0.095	0.089
LSTM	93.7	0.036	0.027
Bi-LSTM	87.3	0.048	0.038
Bi-LSTM-Dropout	96.2	0.029	0.018

由表 2 可知: Bi-LSTM-Dropout 网络模型的 RMSE 和 MAE 值最小, 且准确率最高; 相对于 Bi-LSTM 网络模型, RMSE 从 4.8% 下降到 2.9%; 相对于 LSTM 网络模型, 准确率提高了 2.5%。

RNN、LSTM、Bi-LSTM、Bi-LSTM-Dropout 4 种网络模型在 B0006 号锂电池测试集上的预测效果如图 7 所示。

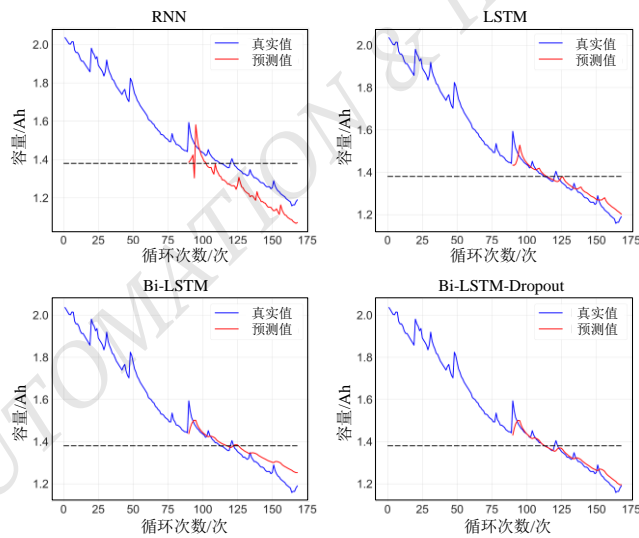


图 7 B0006 号锂电池在测试集上的预测效果

由图 7 可知, Bi-LSTM-Dropout 网络模型的拟合

效果最好。

4 结论

本文提出一种基于 Bi-LSTM-Dropout 的蓄电池 RUL 预测方法。通过提取蓄电池历史运行数据的特征, 构建 Bi-LSTM 模型, 并采用 Dropout 算法进行模型优化, 能够有效提高蓄电池 RUL 预测的精度。实验结果表明, 相比 LSTM 网络模型, 本文提出的 Bi-LSTM-Dropout 网络模型可以降低 RUL 预测的 RMSE 和 MAE, 在测试集上的准确率达 96.2%。该方法基于数据驱动的方法实现蓄电池使用寿命的预测, 可辅助电站蓄电池的状态监测和运行维护。

参考文献

- [1] 刘灏,黎明,向青海.直流系统蓄电池组全生命周期智能管理系统研究与实施[J].电气技术与经济,2023(10):399-403.
- [2] 谭子毅,刘忠祥.一种蓄电池组自动开路测试技术[J].电世界,2020,61(11):40-41.
- [3] 汪昌元,罗群,徐晓峰.一种铅酸蓄电池剩余容量的预测方法[J].广西电力,2020,43(4):60-62.
- [4] 蔡明扬,赵春宇,李爱.基于组合脉冲放电法的电池容量估计算法[J].中国新通信,2022,24(16):53-58.
- [5] 罗杰,王海瑞,朱贵富.基于数据预处理和集成机器学习的锂离子电池剩余使用寿命预测[J].陕西理工大学学报(自然科学版),2023,39(6):62-70.
- [6] GAO Y, LIU K, ZHU C, et al. Co-estimation of state-of-charge and state-of-health for lithium-ion batteries using an enhanced electrochemical model[J]. IEEE Transactions on Industrial Electronics, 2021,69(3):2684-2696.
- [7] 田建辉,张成,韩兴本,等.基于电化学-热耦合模型的锂离子电池容量衰减研究[J].现代机械,2023(5):10-15.
- [8] QU J, LIU F, MA Y, et al. A neural-network-based method for RUL prediction and SOH monitoring of lithium-ion battery[J]. IEEE Access, 2019,7:87178-87191.
- [9] REN L, DONG J, WANG X, et al. A data-driven auto-CNN-LSTM prediction model for lithium-ion battery remaining useful life[J]. IEEE Transactions on Industrial Informatics, 2020(99):1-1.
- [10] 刘建伟,王园方,罗雄麟.深度记忆网络研究进展[J].计算机学报,2021,44(8):1549-1589.

(下转第 60 页)