

基于多模型组合和 EIS 的锂电池 SOH 和 RUL 预测

常 伟, 胡志超, 潘多昭

(南通乐创新能源有限公司, 江苏 南通 200233)

摘要: 电池健康状态(state of health, SOH)和剩余使用寿命(remaining useful life, RUL)是评价电池健康程度和剩余寿命的重要技术指标。SOH 和 RUL 的估计是电池管理系统的重要组成部分,是实现电池管理系统智能监控和科学运营的基础。电池电化学阻抗谱(electrochemical impedance spectroscopy, EIS)是一种用于表征电池内部电化学过程的测试方法,它具备精度高和非侵入性损害等优点。多种研究表明,电池阻抗谱 EIS 与电池的 SOH 和 RUL 存在一些内在的联系,因此成为电化学领域的研究热点。基于 EIS 预测 SOH 和 RUL,传统机器学习方法比较成熟,但预测精度和稳定性仍有局限,难以完全挖掘电池衰减规律。因此,需要与深度学习等方法相结合才能提高预测性能。将降维模型和多种深度学习模型引入 SOH 和 RUL 预测领域,并对模型进行有效组合,取得了很好的效果。将 EIS 所有频率对应的实部和虚部数据依次排列作为频率特征,首先使用主成分分析(principle component analysis, PCA)模型对 EIS 值进行降维,提炼出 10 个精炼的主成分,然后使用卷积神经网络(convolution neural network, CNN)模型提取 EIS 的空间特征,使用双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)模型提取 EIS 时间序列变化规律,使用注意力(attention)机制进一步选取 EIS 数据的时空特征中的重要部分,共同预测 SOH 和 RUL。在测试数据上进行实验表明,SOH 预测的均方误差(root mean square error, RMSE)达到 0.146 8, RUL 预测的均方误差达到 2.614 5,效果均好于传统的方法。

关键词: 阻抗谱; EIS; SOH; RUL; PCA; CNN; BiLSTM

中图分类号: TM912.9 **文献标志码:** A **文章编号:** 1671-1807(2024)02-0192-08

电池电化学阻抗谱(electrochemical impedance spectroscopy, EIS)作为一种无损检测技术,广泛应用于电池健康状态(state of health, SOH)或剩余使用寿命(remaining useful life, RUL)的预测。在特征选取上,可以通过 EIS 的实部和虚部数据直接进行 SOH 或 RUL 的预测^[1-6]。

在特征降维方面,从 EIS 所涵盖的多个频率中,选择具有代表性的频率可以显著降低模型复杂度。然而,代表性频率的选择通常具有主观性,缺乏科学依据^[7]。在模型选择上,传统机器学习模型^[8]对于 SOH 的预测具有良好的效果,但其预测精度有待提升。为了提高预测精度,可以结合深度学习模型。

本文的创新点在于,使用降维模型和多种深度学习模型的组合模型,构建了电池电化学阻抗谱数据 EIS 和电池 SOH 和 RUL 之间的映射关系,较好地预测了 SOH 和 RUL^[9]。本文的实用性在于,提升了 EIS 预测 SOH 和 RUL 的预测精度。

1 数据采集

引采测试和采集电池 EIS 数据需要专业的阻抗谱测试仪器,如电化学工作站 CHI760E 电化学分析测试仪,并且需要覆盖一定的温度和频率范围,温度设置为 25 °C、35 °C 和 45 °C,频率范围为 $10^{-2} \sim 10^5$ Hz,在频率范围中间按一定间隔选取 60 个频率值,如表 1 所示。

表 1 EIS 频率取值一览

序号	频率	序号	频率	序号	频率
1	20 004.4	21	12 516.7	41	7 835.48
2	4 905.29	22	3 070.98	42	1 923.15
3	1 203.84	23	754.275	43	471.963
4	295.472	24	185.059	44	115.778
5	72.517 0	25	45.362 9	45	28.409 0
6	17.796 1	26	11.144 8	46	6.975 45
7	4.369 41	27	2.7354 7	47	1.709 52
8	1.070 79	28	0.670 72	48	0.419 76
9	0.262 61	29	0.164 52	49	0.103 09
10	0.064 43	30	0.040 42	50	0.025 28
11	15 829.1	31	9 909.44	51	6 217.24
12	3 881.27	32	2 430.77	52	1 522.43
13	952.865	33	596.718	53	373.208

收稿日期: 2023-10-20

作者简介: 常伟(1976—),男,湖南长沙人,硕士,研究方向为电池工业;胡志超(1984—),男,湖北黄梅人,硕士,研究方向为电池热失控;潘多昭(1991—),男,壮族,新疆阿勒泰人,硕士,研究方向为储能与能源工程、AI 算法、智慧能源。

使用电化学阻抗谱测试仪测试电池 EIS(电化学阻抗谱)的步骤如下。

(1)连接测试仪与电池:使用封闭饱和电极作为参比电极,碳棒电极作为对电极,连接至电池正负极。

(2)设置测试参数:选择频率扫描范围、扰动幅度、扫描点数等参数。频率范围设置 $10^{-2} \sim 10^5$ Hz,扰动幅度为 10 mV,扫描点数一般选取 5~60 个,选取 60 个作为样例。

(3)开始测试前先开路充电或放电,使电池稳定在目标状态。

(4)启动测试:仪器自动按设置频率顺序扫描,在每个频率点施加正弦交流小信号,记录响应电流。

(5)测试结束后:使用仪器软件绘制阻抗曲线(Nyquist 图和 Bode 图),显示阻抗、相角等参数。

(6)通过曲线拟合分析,可以获取电池内阻、极化电阻、传导性等关键参数。

采集数据时,需要对电池进行多次循环的充放电操作,在此过程中进行 EIS 的测试,采集并记录每个频率对应的阻抗的实部和虚部数据,以及相对应的电池 SOH 和 RUL 数据。

具体的数据采集方法可以查看参考 Zhang 等^[6]的 Data generation 部分。

2 电池 SOH 和 RUL 预测

2.1 电池 SOH 和 RUL 预测流程

基于多模型组合和 EIS 数据预测电池 SOH 和 RUL 的流程如图 1 所示。

首先,需要通过实验的方式采集电池 EIS、SOH 和 RUL 数据;其次,使用主成分分析(principle component analysis,PCA)模型对 EIS 进行降维;然后,使用卷积神经网络(convolution neural network,CNN)模型提取 EIS 的空间特征;再次,使用双向长短期记忆网络(bidirectional long short-term memory,BiLSTM)模型提取 EIS 的时间变化规律,接下来使用注意力机制提取 EIS 时空特征中的重要部分,最后,预测 SOH 和 RUL。




图 1 基于多模型组合和 EIS 数据预测电池 SOH 和 RUL 流程

2.2 构建 SOH 和 RUL 预测模型

使用多模型组合的模型结构如图 2 所示。

由图 2 可知,输入部分 $real1 \sim real60$ 表示从高频至低频对应的阻抗数据的实部数据, $imaginary1 \sim imaginary60$ 表示从高频至低频对应的阻抗数据的虚部数据。

P1~P10 表示 EIS 输入数据经过 PCA 计算之后得到的主成分。

接下来是 2 层的 convolution 结构,激活函数为 relu;需要对卷积计算结果进行最大池化操作;将最大池化计算结果进行 flatten 操作,即平铺展开;平铺层输入到 BiLSTM 结构中,激活函数为 relu;BiLSTM 的输出结果,输入到一个 attention 模型中,进一步学习序列中各个时间步的相对重要性;连接到一个全连接层。

最后,通过线性回归层,分别预测 SOH 或 RUL。

模型损失函数为均方根误差(root mean square error, RMSE)。损失函数是用来估量模型的预测值与真实值不一致程度的。失函数是一个非负实值函数,损失函数越小,模型的鲁棒性就越好。

在回归预测模型中,均方根误差是检验模型优劣的指标之一,是检测样本的真实值与预测值差值的平方求和的平均值的二次开方值,一般用来检测模型的预测值和真实值之间的偏差。均方根误差越小,说明模型拟合的越好,效果也越好。

模型优化方法选取 rmsprop。模型优化方法就是模型参数求解方法,以最小化损失函数为目标,同时要兼顾计算性能和求解精度。

2.2.1 提取 EIS 主成分

由于 EIS 测试数据有 60 个频率,每个频率对应




图 2 预测电池 SOH 和 RUL 的多模型组合的模型结构

一个阻抗值,每个阻抗值分别有实部数据和虚部数据,因此共有120个输入数据。这些输入数据中,大部分频率对于SOH的预测不但无用,还会产生噪声数据,会降低预测精度,需要对输入数据进行降维,提取主要成分。

PCA即主成分分析,是一种线性降维方法。它通过标准正交变换,将高维数据集转换为低维数据集,同时最大限度地保留原始数据集的信息量。PCA的几何解释如图3所示。

由图3可知,圆圈代表的样本点,无论是沿着X轴方向或Y轴方向都具有较大的离散性,其离散的程度可以用观测变量的方差来定量的表示。显然,如果只考虑X或Y中的任何一个,那么包含在原始数据中的经济信息将会有较大的损失。




图3 PCA几何解释示意图

假设对原始的坐标轴进行变换,得到了新的坐标轴,记作 F_1 和 F_2 。当坐标轴 F_1 和椭圆的长轴平行时,则表示长轴的变量描述了数据的主要变化;当坐标轴 F_2 和椭圆的短轴平行时,则表示短轴的变量描述了数据的次要变化。但是,新的坐标轴通常并不和椭圆的长短轴平行。因此,需要寻找椭圆的长短轴,并进行变换,使得新变量和椭圆的长短轴平行。如果长轴变量代表了数据包含的大部分信息,就用该变量代替原先的两个变量(舍去次要的一维),降维就完成了。椭圆的长短轴相差得越大,长轴就越能描述更多的信息,降维效果也越好。

因此,PCA等价于一个坐标旋转变换,它将数据协方差矩阵进行了旋转,并在新的坐标系上进行了投影,然后只选择那些投影度量比较高的分量作为最后的结果。

PCA的主要作用:①降维:保留主要信息的同时压缩数据维度,减少算法的复杂度,加速计算;②去噪:通过投影去掉次主成分对应的噪声分量,提高预测精度;③预处理:PCA可以用作机器学习

算法的数据预处理,提取主要特征。

使用PCA模型对EIS输入数据进行主成分提取,以达到降维和去噪的目的,主成分的个数为10。

通过线性变换,PCA可以将高维特征空间转化为几个互相正交的主成分空间,并根据方差贡献率高低进行排名。每个主成分解释了一部分原始数据的方差,并可以计算出每个主成分所解释的数据方差占原始数据总方差的百分比,如第1主成分解释原始数据方差的20%;第2主成分解释原始数据方差的15%等。

实际使用中,常根据累积解释方差率超过某个阈值(如85%、90%、95%)来决定主成分数量。

提取EIS数据前10个主成分的累积解释方差达到了99%,在降低维度的同时,很大程度上保留了原始信息。

2.2.2 使用CNN模型提取EIS空间特征

CNN可以自动学习输入数据的空间相关性,提取高层抽象特征。

CNN结构包含两个卷积层和一个池化层,卷积层的激活函数均为relu函数,过滤器数量设置为32个,核的尺寸为1,池化层的池化尺寸也为1。




图4 卷积计算示意图

如图4所示,在卷积层中有一个 $1 \times 6 \times 6$ 的矩形作为输入数据,称为输入特征图,它经过一个 3×3 的滤波器(也被称为卷积核)进行卷积运算,即从输入左上角 3×3 的受野区开始计算其张量积,每完成一次计算向右移动,步幅为1,完成此计算后,就会得出一个 $1 \times 4 \times 4$ 的输出特征图,即结果。

池化层(pooling)把输入特征图划分成若干局部区域,通过统计各局部区域数据的特点来缩小特征图的尺寸。

池化层对输入进行非线性下采样,通过取局部邻域内的最大值(max pooling,最大池化)或平均值(avg pooling,平均池化)作为输出。

卷积层的核心是卷积核,而池化层的核心就是

池化核,池化核的尺寸一般为 3×3 或 2×2 ,步长为 1 或 2。在对特征图进行池化过程中,池化核按照池化步长移动。

常用的池化方式有平均池化和最大池化,最大池化用最大值来表征局部区域,使得图像整体特征对比显著,平均池化用平均值来表征局部区域,使得图像整体特征信息更加平滑。

训练模型时,池化层可以提高模型的泛化性和鲁棒性,避免网络过拟合。最大池化和平均池化的计算逻辑如图 5 所示。

其中,池化输入特征图大小为 4×4 ,最大池化和平均池化卷积核大小均为 2×2 ,池化输出特征图大小为 2×2 。每个卷积层可以提取输入数据的高层特征,池化层实现下采样缩小数据维度。最后通过 flatten 层将三维特征映射为一维向量,作为 EIS 的空间特征表达。

2.2.3 使用 BiLSTM 模型提取 EIS 的时间序列变化规律

BiLSTM 由前向 LSTM 和后向 LSTM 组成,首先介绍一下 LSTM。

LSTM 是一种特殊的 RNN,可以学习长期依赖关系,捕捉时间序列数据的动态变化。图 6 为 LSTM 模型图。




图 5 池化计算示意图




图 7 BiLSTM 模型结构




图 6 LSTM 模型结构

LSTM 模型的结构包含以下组成部分。

- (1)输入门:决定当前时刻输入信息中的哪些部分允许进入状态单元。
- (2)遗忘门:决定状态单元中的哪些信息需要被遗忘或者移除。
- (3)状态单元:用于存储历史状态信息的核心组件。
- (4)输出门:决定输出到下一个隐层的信息。
- (5)激活函数(sigmoid、tanh):用于进行非线性转换。
- (6)输出层:与输入数据相对应的 LSTM 输出数据。

LSTM 通过输入门、遗忘门及输出门的开闭,来控制信息进入、保留和输出的流动,实现按时序信息的记忆及处理。相比简单的 RNN,LSTM 更能捕捉时序数据中的长期依赖,处理较长的时间序列,拥有更强大的建模能力。

BiLSTM 由前向 LSTM 和后向 LSTM 组成,包含前向隐状态和后向隐状态。在同一时刻,前向 LSTM 处理正向序列,后向 LSTM 处理反向序列,最后通过拼接或者添加两者的隐状态作为该时刻的输出状态。

图 7 中 X 表示输入量,BiLSTM 由前向 LSTM 与后向 LSTM 组合而成,最终每个时间步 i 输出

测试数据共有 120 个特征,特征序号依次是 1~120,前 60 个特征是频率从高到低对应的阻抗数据的实部数据,后 60 个特征是频率从高到低对应的阻抗数据的虚部数据。

3.1 预测数据展示

3.1.1 SOH 预测数据展示

电池 EIS 预测电池 SOH 数据集合部分样例如表 2 所示。

表 2 中 $f_1 \sim f_{120}$ 表示 EIS 频率特征,这里的 SOH 表示电池最大容量,也反映了电池的健康度。

3.1.2 RUL 预测数据展示

电池 EIS 预测电池 RUL 数据集合部分样例如表 3 所示。

表 3 中, $f_1 \sim f_{120}$ 表示 EIS 频率特征,这里的 RUL 表示电池剩余循环次数。

值得注意的是,用于预测 SOH 和 RUL 的阻抗谱 EIS 数据并不完全相同。

3.2 PCA 提取 EIS 主成分

3.2.1 PCA 提取预测 SOH 的 EIS 主成分

对预测 SOH 的输入数据 EIS 的 120 维度数据进行 PCA 计算,得到 10 个主要成分,部分样例如表 4 所示。其中, $P_1 \sim P_{10}$ 依次表示 10 个主成分。

表 2 电池 EIS 预测电池 SOH 数据集合样例(部分)

f_1	f_2	...	f_{120}	SOH
0.384 70	0.391 56	...	0.327 95	37.20
0.388 86	0.393 43	...	0.323 00	36.22
0.390 38	0.396 0	...	0.329 55	35.59
0.391 94	0.396 43	...	0.336 73	35.11
0.392 25	0.397 60	...	0.325 62	34.77

表 3 电池 EIS 预测电池 RUL 数据集合样例(部分)

f_1	f_2	...	f_{120}	RUL
0.384 70	0.391 56	...	0.327 95	234
0.388 86	0.393 43	...	0.323 00	232
0.390 38	0.396 00	...	0.329 55	230
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
0.751 14	0.757 14	...	0.296 08	4
0.753 21	0.758 79	...	0.298 27	2
0.752 11	0.760 74	...	0.291 80	0

表 4 预测 SOH 的电池 EIS 数据 PCA 计算结果样例(部分)

P_1	P_2	...	P_{10}
-0.825 7	0.497 9	...	0.007 3
-0.766 7	0.480 0	...	0.005 1
-0.739 6	0.471 8	...	-0.008 6
-0.706 2	0.458 5	...	0.007 1
-0.689 5	0.453 8	...	0.005 9

3.2.2 PCA 提取预测 RUL 的 EIS 主成分

对预测 RUL 的输入数据 EIS 的 120 维度数据进行 PCA 计算,得到 10 个主要成分,部分样例如表 5 所示。

其中, $P_1 \sim P_{10}$ 依次表示 10 个主成分。

3.3 预测结果展示

3.3.1 SOH 预测结果展示

使用不同模型预测 SOH,分别是神经网络模型 MLP、CNN-LSTM 模型、PCA-MLP 模型、PCA-CNN-LSTM 模型、PCA-CNN-LSTM-ATTENTION 模型以及 PCA-CNN-BILSTM-ATTENTION 模型,效果对比如表 6 所示。

由表 6 可知,传统的神经网络 MLP 模型的效果最差,均方误差为 0.689 6。

CNN-LSTM 模型的组合比 MLP 模型稍好,但总体效果还是较差,均方误差为 0.589 2。

引入 PCA 降维之后,PCA-MLP 和 PCA-CNN-LSTM 模型的效果均有提升,均方误差分别达到了 0.255 8 和 0.202 5。在 PCA-CNN-LSTM 的基础上加入 attention 机制之后,均方误差提升到了 0.164 0。将 LSTM 模型替换成 BiLSTM 之后,均方误差进一步提升到 0.146 8。

PCA-CNN_BILSTM_ATTENTION 模型预测 SOH 的测试集合的均值为 30.577 3,标准方差为 4.066 1,预测集合的均值为 30.620 1,标准方差为 4.086 0,均方根误差为 0.146 8,这表明预测结果的数据分布与真实数据的数据分布基本一致。SOH 预测结果如表 7 所示。

SOH 预测结果样例如图 9 所示。由图 9 中标注的数字和误差值可以看出,预测效果良好。

表 5 预测 RUL 的电池 EIS 数据 PCA 计算结果样例(部分)

P_1	P_2	...	P_{10}
-0.961 4	0.063 5	...	0.009 0
-0.906 7	0.092 5	...	0.003 4
-0.881 5	0.105 7	...	-0.009 2
-0.851 2	0.125 2	...	0.005 1
-0.835 6	0.133 1	...	0.003 3

表 6 不同模型预测 SOH 效果对比

模型名称	均方误差
MLP	0.689 6
CNN-LSTM	0.589 2
PCA-MLP	0.255 8
PCA-CNN-LSTM	0.202 5
PCA-CNN-LSTM-ATTENTION	0.164 0
PCA-CNN-BILSTM-ATTENTION	0.146 8




图 9 电池 SOH 预测结果样例

表 7 基于多模型组合的使用 EIS 预测 SOH 预测结果样例

真实值	预测值	误差
29.16	29.32	-0.16
24.75	24.84	-0.09
27.31	27.32	-0.01
28.09	28.18	-0.09
31.81	32.00	-0.19
37.78	37.68	0.10
32.79	32.74	0.05
28.48	28.53	-0.05
27.03	27.10	-0.07
26.07	25.94	0.13

3.3.2 RUL 预测结果展示

使用不同模型预测 RUL,分别是神经网络模型 MLP、CNN-LSTM 模型、PCA-MLP 模型、PCA-CNN-LSTM 模型、PCA-CNN-LSTM-ATTENTION 模型以及 PCA-CNN-BILSTM-ATTENTION 模型,效果对比如表 8 所示。

由表 8 可知,传统的神经网络 MLP 模型的效果最差,均方误差为 10.644 9。

CNN-LSTM 模型的组合比 MLP 模型稍好,但总体效果还是较差。

引入 PCA 降维之后,PCA-MLP 和 PCA-CNN-LSTM 模型的效果均有提升,均方误差分别达到了

5.547 7 和 6.478 4。

在 PCA-CNN-LSTM 的基础上加入 attention 机制之后,均方误差提升到了 4.116 2。

将 LSTM 模型替换成 BiLSTM 之后,均方误差进一步提升到 2.614 5。

PCA-CNN_BILSTM_ATTENTION 模型预测 RUL 的测试集合的均值为 147.828 6,标准方差为 103.062 1,预测集合的均值为 147.997 9,标准方差为 104.636 6,均方根误差为 2.614 5,这表明预测结果的数据分布与真实数据的数据分布基本一致,预测结果如表 9 所示,预测结果样例如图 10 所示。由图 10 中标注的数字和误差值可以看出,预测效果良好。

4 结论

本文使用 PCA 去除 EIS 数据的噪声,CNN 和 BiLSTM 的组合可以自动学习 EIS 和 SOH 之间的复杂的时空映射关系,注意力机制强化模型对序列上下文的理解。基于四种模型的组合,使用电池 EIS 数据预测 SOH 和 RUL,均方误差分别为 0.146 8 和 2.614 5。将降维模型和多种深度学习模型进行

表 8 不同模型预测 RUL 效果对比

模型名称	均方误差
MLP	10.644 9
CNN-LSTM	9.297 8
PCA-MLP	5.547 7
PCA-CNN-LSTM	6.478 4
PCA-CNN-LSTM-ATTENTION	4.116 2
PCA-CNN-BILSTM-ATTENTION	2.614 5

表 9 基于多模型组合的使用 EIS 预测 RUL 预测结果样例

真实值	预测值	误差
30	32	-2
204	211	-7
136	134	2
124	123	1
258	260	-2
38	40	-2
8	8	0
318	320	-2
242	242	0
80	81	-1




图 10 电池 RUL 预测结果样例

组合,使用 EIS 数据预测了 SOH 和 RUL,效果良好,具有一定的应用价值。

参考文献

- [1] 贺伟,马鸿雁,张英达,等. 基于改进门控循环单元神经网络的锂电池组荷电状态预测[J]. 科学技术与工程, 2023, 23(12): 5102-5109.
- [2] 郝可青,吕志刚,邸若海,等. 基于鲸鱼算法优化长短时记忆神经网络的锂电池剩余寿命预测[J]. 科学技术与工程, 2022, 22(29): 12900-12908.
- [3] 郑永飞,文怀兴,韩昉,等. 基于电池外特征的粒子群神经网络电池健康状态预测[J]. 科学技术与工程, 2019, 19(36): 184-189.
- [4] 李伟,牛东晓. 基于灰色神经网络的短期电力负荷预测分析[J]. 科技和产业, 2008(10): 57-60.
- [5] 周雅夫,万伟东,董启超. 基于改进多频正弦激励的燃料电池电化学阻抗谱测量[J]. 科学技术与工程, 2022, 22(22): 9679-9685.
- [6] ZHANG Y, TANG Q, ZHANG Y, et al. Identifying degradation patterns of lithiumion batteries from impedance spectroscopy using machine learning[J]. Nat Commun, 2020, 11: 1706.
- [7] 耿萌萌,范茂松,杨凯,等. 基于 EIS 和神经网络的退役电池 SOH 快速估计[J]. 储能科学与技术, 2022, 11(2): 673-678.
- [8] 刘伟霞,田勋,肖家勇,等. 基于混合模型及 LSTM 的锂电池 SOH 与剩余寿命预测[J]. 储能科学与技术, 2021, 10(2): 689-694.
- [9] VIVIER V, ORAZEM M E. Impedance analysis of electrochemical systems[J]. Chemical Reviews, 2022(12): 122.

Prediction of SOH and RUL for Lithium Battery Based on Multiple Model Combination and EIS

CHANG Wei, HU Zhichao, PAN Duo Zhao

(Nantong Le Chuangxin Energy Co. Ltd., Nantong 200233, Jiangsu, China)

Abstract: The State of Health (SOH) and Remaining Useful Life (RUL) of batteries are important technical indicators for evaluating the health level and remaining lifespan of batteries. The estimation of SOH and RUL is an important component of the battery management system and the foundation for achieving intelligent monitoring and scientific operation of the battery management system. Electrochemical Impedance Spectroscopy (EIS) is a testing method used to characterize the internal electrochemical processes of batteries, which has the advantages of high accuracy and non-invasive damage. Various studies have shown that there are some inherent connections between battery impedance spectroscopy (EIS) and the SOH and RUL of batteries, making it a research hotspot in the field of electrochemistry. Based on EIS to predict SOH and RUL, traditional machine learning methods are relatively mature, but there are still limitations in prediction accuracy and stability, making it difficult to fully explore the decay patterns of batteries. Therefore, it is necessary to combine with methods such as deep learning to improve prediction performance. Dimensionality reduction models and various deep learning models were introduced into the fields of SOH and RUL prediction, and the models were effectively combined, achieving good results. The real and imaginary data was arranged corresponding to all frequencies of the EIS as frequency features. Firstly, the Principal Component Analysis (PCA) model was used to reduce the dimensionality of the EIS values, 10 refined principal components were extracted, and then the Convolutional Neural Network (CNN) model was used to extract the spatial features of the EIS, Using the Bidirectional Long Short Term Memory (BiLSTM) model to extract the variation patterns of EIS time series, using the Attention mechanism to further select important parts of the spatiotemporal features of EIS data, and SOH and RUL were jointly predicted. Experiments on test data show that the Root Mean Square Error (RMSE) of SOH prediction reaches 0.1468, and the mean square error of RUL prediction reaches 2.6145, both of which are better than traditional methods.

Keywords: impedance spectrum; EIS; SOH; RUL; PCA; CNN; BiLSTM