

# 基于卷积自编码神经网络的锂离子电池健康状况评估方法研究

侯瑞磊, 范秋华

(青岛大学 电气工程学院, 山东 青岛 266071)

**摘要:** 目前锂离子电池已被广泛用作能量存储系统, 在手机、电动汽车和飞机中均有广泛的应用; 然而锂离子电池在使用过程中存在一定的危险性, 若不能及时对电池健康状态评估 (SOH) 发现危险将会导致十分严重的后果; 因此, 研究了一种基于卷积神经网络的锂离子电池健康状况评估方法, 该方法通过使用卷积自编码神经网络对电池状态数据进行特征提取, 有效提升了评估的准确率, 并且神经网络能够在使用过程中不断进行学习, 具有较高的灵活性, 最后通过使用 NASA 公开的锂电池数据集测试, 评估准确率达到 93.6%, 相比传统方法有较大提升。

**关键词:** 锂电池; SOH; 卷积; 自编码; Softmax

## Health Assessment Method of Lithium Ion Battery Based on Convolutional Self-encoding Neural Network

Hou Ruilei, Fan Qiuhua

(School of Electrical Engineering, Qingdao University, Qingdao 266071, China)

**Abstract:** At present, lithium-ion batteries have been widely used as energy storage systems, and they are widely used in mobile phones, electric vehicles and aircraft. However, there are certain dangers in the use of lithium ion batteries. If the battery health status (SOH) is not found in time, the danger will lead to very serious consequences. Therefore, a method for assessing the health of lithium-ion batteries based on a convolutional neural network is studied. This method uses a convolutional self-encoding neural network to extract the characteristics of the battery state data, effectively improving the accuracy of the evaluation, and the neural network can continuous learning during the use process, has high flexibility. Finally, by using the lithium battery data set published by NASA, the evaluation accuracy rate is 93.6%, which is greatly improved compared with the traditional method.

**Keywords:** lithium battery; SOH; convolution; self-encoding; Softmax

### 0 引言

目前锂离子 (Li-ion) 电池已被广泛用作能量存储系统, 例如手机、数码产品、电动汽车、混合动力汽车、飞机电源等<sup>[1]</sup>。然而, 锂离子电池的性能会因其电化学成分的降解而随时间和使用时间而下降<sup>[2]</sup>, 从而导致容量和功率衰减。这称为电池老化, 这是一种多耦合老化机制的结果, 其机制受不同因素 (例如电池化学和制造以及环境和工作条件) 的影响<sup>[3]</sup>。锂电池由于其高能量密度在很多领域十分受青睐, 但是其危险性也要远高于普通铅酸电池, 例如波音 777 飞机锂电池着火、三星手机电池爆炸和特斯拉电动汽车自燃等事故都是由于锂电池健康状态出问题导致<sup>[4-6]</sup>。因此, 在锂电池的使用过程中对其健康状态进行评估, 及时识别异常状态电池, 对于电池使用安全和延长电池寿命都有着重要意义<sup>[7-8]</sup>。

目前, 电池健康状态评估 (SOH) 技术已经广泛应用于电动汽车等高耗电、大电池在运行中的实际性能评估。

SOH 反映了电池相对于其寿命开始时的当前存储和供应能量/功率的能力, 该能力通过实际电池容量/电阻与其初始值之比计算得出, 对于电动汽车中电池中的可用能量起着至关重要作用<sup>[9]</sup>。这些年来, 已经开发了多种 SOH 估算方法<sup>[10]</sup>。一种常见的方法是使用数学模型来模拟电池衰减过程, 然后使用各种优化算法和滤波器, 例如卡尔曼滤波器和粒子滤波器, 来识别参数和 SOH 状态<sup>[11]</sup>。另一种广泛使用的方法是使用电化学模型, 该模型应用偏微分方程来模拟与老化密切相关的质量和电荷移动力学<sup>[12]</sup>。上述方法虽然具有不错的评估准确度, 但是其应用灵活性受限较大, 模型一旦建立很难根据实际电池生产制造和使用进行调整, 因此在实际应用过程中存在很大误差<sup>[13-15]</sup>。随着机器学习及传感器技术的迅速发展, 基于数据驱动的锂电池健康估计和预测方法由于其灵活性和无模型优势而在学术界和工业界都越来越受到关注。

本文研究了一种基于卷积自编码神经网络的锂电池健康状况评估方法, 该方法通过卷积自编码神经网络对锂电池充放电和健康状况数据进行特征提取, 用 Softmax 对特征提取结果进行分类, 得到电池的健康状态评估。该方法能够在使用过程中不断学习电池数据特征, 对模型进行实

收稿日期: 2019-12-26; 修回日期: 2020-01-16。

作者简介: 侯瑞磊 (1994-), 男, 山东烟台人, 硕士研究生, 主要从事锂离子电池技术方向的研究。

时改变，其应用灵活性和准确率有明显提升。

### 1 卷积自编码神经网络

#### 1.1 卷积神经网络模型

卷积神经网络 (convolutional neural network, CNN) 是多层感知机 (multi-layer perceptron, MLP) 在二维图像处理领域的一种推广，它包含多个阶段的视觉信息处理过程，能够自动地从图像中提取不同层次的特征表示。

从结构上看，卷积神经网络包括卷积层、池化层和分类层 3 个部分，图 1 为一个卷积神经网络的架构示意图。图中输入端是大小为  $32 \times 32$  的图像；中间层是由多个卷积和池化操作组成的特征提取层，卷积层和池化层的大小分别为  $5 \times 5$ 、 $2 \times 2$ 。每个卷积层采用局部连接和全局共享的连接方式提取图像的局部特征，并将这些特征组合起来构成一幅特征映射图，然后经过池化操作简化卷积层的输出，利用图像局部相关性的原理，降低特征的维数，同时保留了有用的信息；输出端为分类层，是一种全连接网络，将前一层的输出通过串行连接的方式展开，展开的所有输出构成特征向量。网络的输出层神经元个数为训练图像集的类型个数，即为类型标签的个数。




图 1 卷积神经网络架构示意图

#### 1.2 卷积自编码神经网络模型

卷积自编码神经网络 (convolutional auto-encoder, CAE) 是在自编码神经网络和卷积神经网络的基础上发展而来，将卷积神经网络中的卷积操作引入到自编码网络中，即形成了卷积自编码网络，图 2 为一个卷积自编码网络的架构示意图。图中输入层和输出层的维度相同，均为  $32 \times 32$  的数据矩阵；中间层由卷积操作和反卷积操作组成，分别用于提取特征和输出重构，图中卷积层和反卷积层的大小为  $5 \times 5$ 。




图 2 卷积自编码神经网络架构示意图

在卷积自编码神经网络的训练学习中，规定网络的期望输出等于网络的输入，即网络的学习目标是使得网络的

输出等于网络的输入，因此卷积自编码神经网络的训练过程属于无监督学习。

### 2 基于卷积自编码网络的特征提取方法

#### 2.1 卷积自编码网络的学习特性

从连接方式上来看，卷积自编码神经网络采用局部连接的方式，每层神经元只与其上一层的部分神经元相连，如图 3 所示，神经元  $S_3$  只与其上一层的  $X_2, X_3, X_4$  三个神经元相连。因此卷积自编码神经网络侧重于输入数据局部信息的学习，有利于局部特征的提取。




图 3 局部连接结构示意图

此外，卷积自编码网络具有权值共享特性。权值共享是指每个特征映射图中的所有神经元都用相同权值的卷积核与输入图像扫描窗口内的像素做卷积 (卷积操作)，如图 4 所示，输入数据矩阵的维度为  $28 \times 28$ ，隐含层神经元与图像中的  $5 \times 5$  局部区域连接，该区域常称为局部感知域，该局部区域对应的  $5 \times 5$  权值参数为卷积核。同一个卷积核在整个图像中按照从左向右、从上至下的顺序滑动，就会在隐含层中得到不同的神经元，构成特征映射图。因此卷积核也称为共享权值，用于提取和检测数据不同位置处的同一个局部特征。由此可见，局部连接特性和权值共享特性使得卷积自编码网络有利于捕捉输入数据中的平移不变特征，即具有平移不变学习特性。




图 4 权值共享示意图

#### 2.2 信号特征分量的自学习过程

本节研究了基于卷积自编码网络的信号特征分量自学习方法，利用卷积自编码网络对数据进行先卷积后反卷积的处理，在卷积的过程中学习信号的特征知识，在反卷积过程中获得信号的多个特征分量，实现信号特征分量的自动学习。

目前卷积自编码网络的处理对象大多为图像，卷积自编码网络的结构以及不同层神经元之间的卷积操作是以二维卷积形式出现的，而在锂电池健康状态评估中，需要处理的数据往往是电池的电压、电流和温度等信号，因此需

要构建适合电池状态信号的卷积自编码网络, 如图 9 所示。图中网络的输入为锂电池在充放电过程中的状态信号, 维度为  $949 \times 6$ ; 网络输出为输入信号的重构; 中间层的构造与基于图像的卷积自编码网络相同, 包括卷积层和反卷积层。图中卷积核的大小为  $95 \times 6$ , 隐含层的每个神经元与输入数据中长度为 95 的局部区域相连; 图中 @3 的含义是指卷积核的个数为 3。




图 5 卷积自编码网络架构示意图

在图 5 所示的网络架构中, 对于给定的输入向量  $x$ , 当采用的激活函数为  $\tanh$  函数时, 网络的输出表达式为:

$$\hat{x} = \tanh\left(\sum_{k=1}^2 h_k * W_k^{(2)} + b^{(2)}\right) \quad (1)$$

式中,  $W^{(2)}$  为卷积核的参数, 即为共享的权值参数;  $h_k$  为隐含层神经元的激活值;  $b^{(2)}$  为卷积核对应的偏置。由  $\tanh$  函数的性质和分块矩阵运算法则可推导:

$$\begin{aligned} \hat{x} &= \tanh\left(\sum_{k=1}^2 h_k * W_k^{(2)} + b^{(2)}\right) \\ &\approx \tanh(h_1 * W_1^{(2)} + h_2 * W_2^{(2)}) \end{aligned} \quad (2)$$

式中,  $W_i^{(2)} = [W_{1i}^{(2)} \ W_{2i}^{(2)} \ W_{3i}^{(2)}]^T$ ——每个卷积核与输出层神经元之间的连接权值。由激活函数满足:

$$\tanh(a+b) = \frac{\tanh(a) + \tanh(b)}{1 + \tanh(ab)} \quad (3)$$

当  $|ab| < 1$  时, 有:

$$\begin{aligned} \hat{x} &\approx \tanh(h_1 * W_1^{(2)}) + \tanh(h_2 * W_2^{(2)}) + \\ &\quad \tanh(h_3 * W_3^{(2)}) = I_1 + I_2 + I_3 \end{aligned} \quad (4)$$

式中,  $I_i = \tanh(h_i * W_i^{(2)})$ 。

由式 (4) 可以看出, 卷积自编码网络的输出可以看作多个分量  $I_i$  的叠加。因此, 对于电池状态信号, 在经过卷积自编码网络的训练后, 该网络模型能够将原始信号分解为多个特征分量, 每个特征分量  $I_i$  都可看作是卷积核  $W_i^{(2)}$  与激活值向量  $h_i$  的卷积。因此将信号输入到卷积自编码网络中的训练过程, 也是该网络模型对信号的特征学习过程, 它能够依赖信号本身分解信号, 得到包含信号特征知识的多个特征分量。

### 3 基于卷积自编码神经网络的 SOH

如图 6 所示, 在锂离子电池健康状况评估方法中, 首先构造电池状态数据矩阵作为无监督学习卷积自编码神经

网络的输入, 卷积自编码神经网络的输出作为 softmax 分类器的输入, 历史数据中的电池健康状态作为有监督学习的 softmax 分类器的输出, 对整个网络进行训练。训练完毕后即可使用该网络进行电池健康状态评估。




图 6 基于卷积自编码神经网络的锂电池 SOH

在训练方法上, 卷积自编码神经网络包含前向算法和误差反向传播算法, 前向算法用于计算网络的输出, 误差反向传播算法则用于调整卷积核的参数值, 从而使得网络的代价函数取得最小值。图 7 为卷积自编码网络的训练流程图。




图 7 卷积自编码网络的训练流程图

卷积自编码网络的不同层之间通过卷积运算连接起来, 其模型参数为  $(W, b) = (W^{(1)}, b^{(1)}, W^{(2)}, b^{(2)})$ 。以图 5 中的卷积自编码网络模型为例, 详细分析网络训练需用到的前向算法和误差反向传播算法。

对于给定的网络模型参数  $(W, b)$  以及网络输入  $x$ , 按照前向算法分别计算隐含层的输出和输出层的输出。其中, 输入层到隐含层的计算公式为:

$$h_1 = \sigma(x * W_1^{(1)} + b_1^{(1)}) \quad (5)$$

$$h_2 = \sigma(x * W_2^{(1)} + b_2^{(1)}) \quad (6)$$

$$h_3 = \sigma(x * W_3^{(1)} + b_3^{(1)}) \quad (7)$$

式中,  $W_i^{(1)}$  为第  $i$  卷积核的参数向量  $95 \times 6$ ,  $i = 1, 2, 3$ ;  $b_i^{(1)}$  为第  $i$  卷积核对应的偏置值;  $\sigma(\cdot)$  为神经元的激活函数, 这里选用  $\tanh$  函数, 其表达式为  $\sigma(x) = (e^x - e^{-x}) / (e^x + e^{-x})$ 。 $h_1, h_2$  为激活值向量 (即卷积后提取的特征向量)。隐含层到输出层之间的计算公式为:

$$h_{w,b}(x) = \sigma\left(\sum_{k=1}^2 h_k * W_k^{(2)} + b^{(2)}\right) \quad (8)$$

式中,  $b^{(2)}$  为共享偏置;  $W_k^{(2)}$  为  $100 \times 1$  的共享权重向量。

式 (5) ~ (7) 中的卷积操作分别为 valid convolution 和 full convolution, 其中, full convolution 是指一个维度为  $m \times 1$  的向量与一个维度为  $n \times 1$  的向量卷积后生成  $(m+n-1) \times 1$  的向量, 而 valid convolution 的卷积结果为  $(m-n+1) \times 1$ 。因此, 卷积自编码神经网络分别经过 valid convolution 和 full convolution 后, 可以在网络的输出层得到原始输入的重构表达。

卷积自编码神经网络的代价函数为网络实际输出与网络输入之间的差别, 假定训练数据包含  $m$  个样本  $\{x^{(1)}, x^{(2)}, \dots, x^{(m)}\}$ , 则其在  $m$  个样本的数据集上的整体代价函数为:

$$J(W, b) = \frac{1}{m} \sum_{i=1}^m \left( \frac{1}{2} \|h_{w,b}(x^{(i)}) - x^{(i)}\|^2 \right) + \frac{\lambda}{2} \sum_{i=1}^2 (W_i)^2 \quad (9)$$

$J(W, b)$  的最小值通过迭代优化算法求解, 网络模型训练之前, 先对卷积核的参数初始化为很小的接近于 0 的随机值, 然后通过迭代优化不断进行更新, 更新公式为:

$$W_i^{(1)} = W_i^{(1)} - \alpha \frac{\partial}{\partial W_i^{(1)}} J(W, b) \quad (10)$$

$$b_i^{(p)} = b_i^{(p)} - \alpha \frac{\partial}{\partial b_i^{(p)}} J(W, b) \quad (11)$$

式 (9)、(10) 中的偏导数通过误差反向传播算法计算得到, 具体计算过程如下:

对于每一个训练样本  $x^{(k)}$  计算得到网络的实际输出  $h_{w,b}(x^{(k)})$  后, 网络输出层的每个输出单元  $i$  的误差为:

$$\delta_i^{out} =$$

$$\frac{\partial}{\partial z_i} \frac{1}{2} \|h_{w,b}(x^{(k)}) - x^{(k)}\|^2 = -(x_i^{(k)} - z_i^{(k)}) f'(z_i) \quad (12)$$

式中,  $z_i$  为输出层神经元  $i$ 。对于隐含层, 其第  $i$  个神经元的误差为:

$$\delta_i^{hid} = \delta_i^{out} * W_i \quad (13)$$

式中卷积操作作为 full convolution。单个样本  $x^{(k)}$  的代价函数的偏导数为:

$$\frac{\partial}{\partial W_i} J(W, b; x^{(k)}) = h_i * \delta_i^{hid} \quad (14)$$

$$\frac{\partial}{\partial b_i} J(W, b; x^{(k)}) = \delta_i^{hid} \quad (15)$$

式 (13) 中的卷积操作作为 valid convolution。整个训练数据集上的代价函数  $J(W, b)$  的偏导数为:

$$\frac{\partial}{\partial W_i} J(W, b) = \left( \frac{1}{m} \sum_{k=1}^m \frac{\partial}{\partial W_i} J(W, b; x^{(k)}) \right) + \lambda W_i \quad (16)$$

$$\frac{\partial}{\partial b_i} J(W, b) = \frac{1}{m} \sum_{k=1}^m \frac{\partial}{\partial b_i} J(W, b; x^{(k)}) \quad (17)$$

通过在迭代运算中利用这两个式子来调整参数  $W, b$  的值, 代价函数  $J(W, b)$  取得最小值时的  $W, b$  就是训练完毕的卷积自编码网络的模型参数。

## 4 试验分析

### 4.1 数据来源

本文使用 NASA 公开的电池数据集作为试验对象, 该试验中共有一组 4 个锂离子电池 (5 号, 6 号, 7 号和 18 号) 在室温下经过 3 种不同的操作曲线 (充电, 放电和阻抗)。以 1.5 A 的恒定电流 (CC) 模式进行充电, 直到电池电压达到 4.2 V, 然后以恒定电压 (CV) 模式继续充电, 直到充电电流降至 20 mA。以 2 A 的恒定电流 (CC) 进行放电, 直到电池 5 号、6 号、7 号和 18 号的电池电压分别降至 2.7 V, 2.5 V, 2.2 V 和 2.5 V。阻抗测量是通过从 0.1 Hz 到 5 kHz 的电化学阻抗谱 (EIS) 频率扫描进行的。重

复的充电和放电循环会导致电池加速老化, 而阻抗测量则可以深入了解随着老化的进行而变化的内部电池参数。当电池达到寿命终止 (EOL) 标准时即终止实验, 该标准是额定容量 (从 2 Ahr 降至 1.4 Ahr) 下降了 30%。每组数据包括了电池的充放电状态、电池阻抗 (可视为电池健康状况) 和 6 个电池状态量, 分别是: 电池终端电压、电流, 环境温度, 充电器电压、电流和记录时间。

### 4.2 结果分析

构造维度为  $789 \times 5$  的训练样本, 并设置卷积核的个数为 5, 维度为  $80 \times 5$ , 然后将训练样本输入到网络模型中进行训练, 如图 8~12 所示, 训练结束后可得到网络权值参数 (即卷积核) 及提取的特征分量; 之后再使用 softmax 分类器对特征分量进行分类, 使用阻抗数据进行有监督学习训练, 如表 1 所示, 相比传统的 BP 神经网络和卡尔曼滤波方法, 本文所提出的基于卷积自编码神经网络的电池健康状况评估准确率有很大提升。




图 8 第一个卷积核及其对应特征分量的波形图




图 9 第二个卷积核及其对应特征分量的波形图




图 10 第三个卷积核及其对应特征分量的波形图




图 11 第四个卷积核及其对应特征分量的波形图




图 12 第五个卷积核及其对应特征分量的波形图

表 1 几种 SOH 方法准确率

SOH 方法	准确率/%
BP 神经网络	86.1
卡尔曼滤波	89.2
卷积自编码	93.6

### 5 结束语

本文所研究的基于卷积自编码神经网络的锂离子电池健康状况评估技术使用了卷积自编码神经网络对电池在充放电过程中的电池电压和电流, 环境温度, 充电器电压和电流信号进行特征提取, 使用 softmax 对提取特征进行分类, 对电池的 SOH 进行评估。

### 参考文献:

[1] 汪秋婷, 戚伟. 基于 D-UKF 的锂离子电池 SOC/SOH 联合估计方法和容量衰减机理研究 [J]. 科技通报, 2018: 238-242.

[2] 修晓青, 唐巍, 李建林. 计及电池健康状态的源储荷协同配置方法 [J]. 高电压技术, 2017 (9): 356-364.

[3] 周颀, 宋显华, 卢文斌. 基于日常片段充电数据的锂电池健康状态实时评估方法研究 [J]. 中国电机工程学报, 2019, 39 (1): 107-113.

[4] 刘中财, 严晓, 余维. 锂离子电池健康状态新型测定方法 [J]. 电源技术, 2019, 43 (1): 80-82.

[5] 尚丽平, 王顺利, 李占锋. 基于灰关联度的锂电池组 SOH 评价方法研究 [J]. 电源技术, 2015, 39 (11): 2381-2383.

[6] 肖伟, 钟卫东, 舒小农. 基于大数据的电池健康状态 (SoH) 的估算及应用 [J]. 汽车安全与节能学报, 2018, 10 (1): 231-238.

[7] Quinn B A. Engage CSEdu computation creativity: an interview with UNL's Elizabeth ingraham and Leen-Kiat Soh [J]. ACM Inroads, 2018, 9 (1): 19-21.

[8] Wolf S, Zwickel H, Kieninger C. Coherent modulation up to 100 GBd 16QAM using silicon-organic hybrid (SOH) devices [J]. Optics Express, 2018, 26 (1): 220-232.

[9] Han J, Hur H, Min B S. Predictive Factors for Lymph Node Metastasis in Submucosal Invasive Colorectal Carcinoma: A New Proposal of Depth of Invasion for Radical Surgery [J]. World Journal of Surgery, 2018, 42 (1): 1-7.

[10] Won S, Jung J, Park E. Identification of genes related to intramuscular fat content of pigs using genome-wide association study [J]. Asian-Australasian Journal of Animal Sciences, 2018, 31 (2): 157-162.

[11] Nazri N S, Fudholi A, Bakhtyar B. Energy economic analysis of photovoltaic-thermal-thermoelectric (PVT-TE) air collectors [J]. Renewable and Sustainable Energy Reviews, 2018: 92.

[12] 王硕, 王培良. 基于一维卷积自编码器-高斯混合模型的间歇过程故障检测 [J]. 信息与控制, 2019, 48 (3): 285-292.

[13] 杜小磊, 陈志刚, 许旭. 基于小波卷积自编码器和 LSTM 网络的轴承故障诊断研究 [J]. 机电工程, 2019 (7): 36-39.

(下转第 275 页)