

DOI:10.19651/j.cnki.emt.2211771

基于主成分分析与 ILM-DGRBF 网络的 SOH 估算^{*}

李亚飞 王泰华 张润雨 张家乐
(河南理工大学电气工程与自动化学院 焦作 454003)

摘要: 针对锂离子电池健康状态(SOH)估算精度低的问题,提出一种基于主成分分析(PCA)与改进 LM 算法-双高斯核 RBF(ILM-DGRBF)神经网络的方法,实现了 SOH 的准确估算。首先,提取与锂离子电池容量衰退高度相关的健康因子(HI),采用 PCA 方法进行降维处理,减少 HI 之间冗余度。其次,创建双高斯核 RBF 神经网络,利用改进 LM 算法实现网络参数在线学习,建立 ILM-DGRBF 神经网络。再次,利用数据增强的电池测试数据训练 ILM-DGRBF 实现 SOH 估算。验证表明,经 PCA 降维得到的主成分 1 能够有效地反应锂离子电池的老化趋势,可用于 SOH 的估算;与其他模型相比,所建 ILM-DGRBF 模型具有更高的估算精度和更好的鲁棒性,估算结果的误差控制在 1.5% 以内。最后,基于该方法构建一种新的 SOH 智能估算系统,为电池安全管理提供参考依据。

关键词: 锂离子电池;健康状态;主成分分析;RBF 神经网络;高斯核函数;LM 算法

中图分类号: TM912 文献标识码: A 国家标准学科分类代码: 510.40

SOH estimation based on principal component analysis and ILM-DGRBF network

Li Yafei Wang Taihua Zhang Runyu Zhang Jiale
(School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China)

Abstract: Aiming at the problem of low estimation accuracy of Li-ion battery state of health (SOH), a method based on principal component analysis (PCA) and improved Levenberg-Marquardt algorithm-double Gaussian kernel RBF (ILM-DGRBF) neural network was proposed, which realized the accurate estimation of SOH. Firstly, the health indicator (HI) highly related to the capacity decline was extracted, and PCA method was used for dimensional reduction processing to reduce the redundancy between HI. Secondly, a double Gaussian kernel RBF neural network was created, and improved LM algorithm was used to realize the online learning of neural network parameters to establish ILM-DGRBF neural network. Thirdly, ILM-DGRBF was trained with the enhanced battery test data to realize SOH estimation. The verification shows that the principal component 1 obtained by PCA dimensionality reduction can effectively reflect the aging trend of Li-ion battery, and can be used for SOH estimation; Compared with other models, the established ILM-DGRBF model has higher estimation accuracy and better robustness, and the error of the estimation results is controlled within 1.5%. Finally, based on this method, a new SOH intelligent estimation system was constructed to provide a reference basis for battery safety management.

Keywords: Li-ion battery; state of health; principal component analysis; RBF neural network; Gaussian kernel function; LM algorithm

0 引言

锂离子电池具有使用寿命长、自放电倍率低等特点,已经逐步向现代电动汽车、航空航天等领域拓展^[1]。健康状态(state of health, SOH)是衡量锂离子电池老化程度的关键指标,通常被定义为电池当前最大可用容量与标称容量

之比^[2],准确的 SOH 估算 是确保锂离子电池正常工作的关键。

目前 SOH 的估算研究主要包括基于模型的方法和基于数据驱动的方法。前者利用电路元件模拟电池内部工作状态估算电池 SOH^[3-4],但该方法对电池模型精度要求较高,且局限性较大。后者可以越过电池内部结构,利用神经

收稿日期:2022-10-21

* 基金项目:国家自然科学基金(51974326)项目资助

网络、支持向量回归、高斯过程回归等智能算法对 SOH 进行估算, 减少因电池模型参数辨识不准确所带来的负面影响。文献[5]从充放电循环中提取电压、电流、温度和容量历史数据, 利用长短期记忆网络建立 SOH 估算模型, 实验结果表明所建模型准确率较高。文献[6]将单次放电数据中提取的平均电压和温度作为电池样品特征, 并采用布谷鸟搜索算法优化模型参数以提高 SOH 估算精度。文献[7]从充电曲线中提取 4 个能够从不同角度反应电老化的特征参数, 并使用改进的高斯过程回归算法建立 SOH 估算模型, 验证表明该方法具有较高的估算精度和鲁棒性。文献[8]借助容量增量法和微分电压法, 利用神经网络实现 SOH 估算。从以上分析可以看出, 数据驱动法可以较为准确地估算 SOH, 但上述方法存在以下问题: 1) 所选特征参数之间存在耦合关系, 使得计算复杂度变大; 2) 缺少具有较强拟合能力且结构简单数据驱动模型; 3) 只是在理论方面进行验证, 并未取得实际工程应用。

神经网络可以很好地描述电池高度非线性的特点, 尤其是 RBF 神经网络, 具有结构简洁和学习能力强等特点, 在 SOH 估算中得到广泛应用^[9-10], 但传统 RBF 神经网络激活函数和参数学习算法无法获得理想效果。基于上述, 本文考虑 RBF 网络的较强非线性映射能力, LM 算法的高收敛速度和最优逼近特性, 提出一种基于主成分分析(principal component analysis, PCA)与改进 LM 算法-双高斯核 RBF(improved Levenberg-Marquardt algorithm-double Gaussian kernel RBF, ILM-DGRBF)神经网络的 SOH 估算方法。采用 PCA 对所选健康因子(health indicator, HI)进行降维处理, 减少计算复杂度。建立一种由两个高斯核函数线性组合的 RBF 神经网络, 改进 LM 算法的控制参数并引入滑动窗口提高网络参数的学习性能。利用电池实验数据对所提方法的精度进行论证, 并基于该方法利用集成开发工具建立 SOH 智能估算系统, 实现所提方法的实际工程应用。

1 基础算法原理

1.1 PCA 方法

PCA 方法可把多个指标参数优化为线性无关的低维度变量, 在不丢失主要影响因子的同时提升数据处理速度。经 PCA 降维后的主成分为原始指标参数的线性组合, 可以充分表征原始变量的绝大部分信息。采用 PCA 对本文所选 HI 进行降维处理, 具体步骤如下。

1) 创建由所选 HI 构成的 $c \times d$ 维矩阵 \mathbf{D} , c 为样本个数, d 为指标数量。将 \mathbf{D} 去中心化处理后得到 \mathbf{D}^* , 并求取对应的协方差矩阵 \mathbf{C} :

$$\mathbf{C} = \frac{1}{c} \mathbf{D}^{*T} \mathbf{D}^* \quad (1)$$

2) 求 \mathbf{C} 的特征向量 \mathbf{v}_e 和对应的特征值 λ_e ($0 < e \leq d$), 计算公式为:

$$\mathbf{C}\mathbf{v}_e = \lambda_e \mathbf{v}_e \quad (2)$$

式中: \mathbf{v}_e 为 $d \times 1$ 维向量; λ_e 为标量。

3) 计算各主成分的贡献率:

$$M_e = \lambda_e / \sum_{e=1}^d \lambda_e \times 100\% \quad (3)$$

4) 求取降维后的主成分 \mathbf{F} :

$$\mathbf{F} = \mathbf{D}^* \times [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_f] \quad (4)$$

式中: f ($f \leq d$) 为经降维后选定的主成分个数, 此时 f 需满足 $\sum_{e=1}^f \lambda_e / \sum_{e=1}^d \lambda_e \geq 0.8$ (经验参数)。

1.2 RBF 神经网络

RBF 神经网络是由输入层、隐含层和输出层构成的 3 层前馈网络, 其结构如图 1 所示。

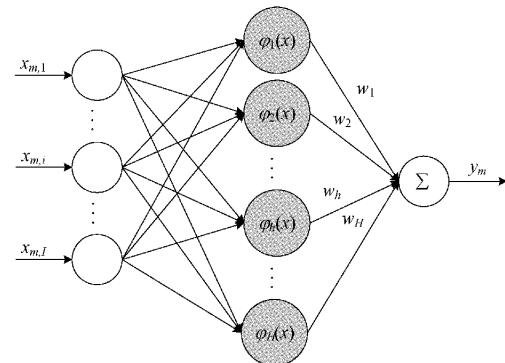


图 1 RBF 神经网络结构

假设第 m 个 I 维输入样本为 $\mathbf{x}_m = [x_{m,1}, x_{m,2}, \dots, x_{m,I}]$, 则第 h 个隐节点的输出为:

$$\varphi_h = (\|\mathbf{x}_m - c_h\|) = \exp\left(-\frac{\|\mathbf{x}_m - c_h\|^2}{\sigma_h^2}\right) \quad (5)$$

式中: c_h 、 σ_h 分别为第 h 个隐节点的高斯核函数中心和宽度; $\|\cdot\|$ 为欧氏范数。对应的网络输出为:

$$y_m = \sum_{h=1}^H w_h \varphi_h (\|\mathbf{x}_m - c_h\|) \quad (6)$$

式中: w_h 为第 h 个隐节点与输出节点的连接权值。

2 SOH 估算

2.1 整体框架

本文所提基于 PCA 与 ILM-DGRBF 神经网络的 SOH 估算模型整体框架如图 2 所示。从充电数据中提取与 SOH 高度相关的 HI, 采用 PCA 进行降维处理, 将得到的间接健康因子作为 DGRBF 神经网络的输入, SOH 为输出, 并利用 ILM 算法实现网络参数在线学习, 建立 ILM-DGRBF 的 SOH 估算模型。

2.2 数据预处理

1) 低温充电

与常温充电相比, 锂离子电池低温充电会加大负极的析锂现象, 导致电池容量衰减速率变快, 且充电温度越低电池容量衰减越明显。为了进一步探究低温充电对锂离子电

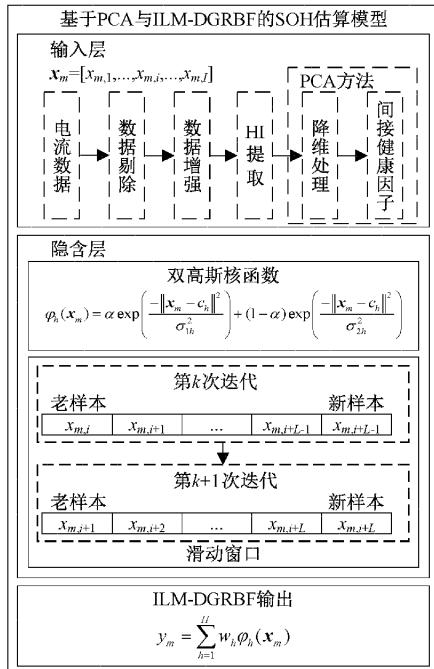


图 2 SOH 估算模型框架

池 SOH 的影响规律,本文选用标称容量为 2.8 Ah 的全新锂离子电池,利用 C17011000134 电池芯充放电测试系统(台湾省产)和 GH-80 恒温恒湿试验箱(东莞产)等设备,进行了如表 1 所示的循环充放电实验。其中,充电预设温度包括 0 ℃、−5 ℃、−10 ℃、−15 ℃,放电采用标准的放电流程,即 25 ℃下以恒流 0.50 C 倍率完全放电至 2.50 V。考虑到电池在充、放电前后环境温差较大,需先将电池在对应温度下静置 3 h,使得电池内外温度达到目标值。每种温度下选用同一批次的 5 块全新锂离子电池进行循环老化测试,并以容量定义法估算 SOH^[11]。

表 1 充放电实验步骤

操作	倍率/C	结束条件	温度/℃
静置	—	3 h	预设温度
恒流-恒压充电	0.50	倍率降至 0.05 C	预设温度
静置	—	3 h	25
恒流放电	0.50	电压降至 2.50 V	25
静置	—	3 h	25

2) 数据增强

上述数据集除去人工剔除的异常数据外,0 ℃、−5 ℃、−10 ℃、−15 ℃下的电池共有 358、219、105、74 组循环数据可供研究,则样本数据难以支撑网络进行足够的训练。因此,本文采用数据增强方法对样本数据进行扩充,从而提高模型的泛化性和鲁棒性。具体为,参考文献[12]思想在样本数据中引入最大幅值为样本幅值 2%且平均值为 0 的高斯白噪声,并添加±5 mA 的电流采样误差,将样本数据

扩充两倍,以 0 ℃第 60 次充电电流曲线为例,使用数据增强前后的对比结果如图 3 所示。值得注意的是,本文从充电电流曲线中提取与 SOH 高度相关的健康因子,故只对充电电流数据进行数据增强。

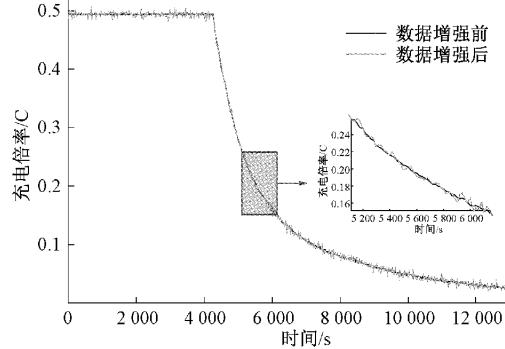


图 3 数据增强前后电流曲线

3) HI 选取与降维

随着电池的老化,固体电解质界面的积累和重复生长导致电池内阻增大,从而降低电池恒流充电时间和电量。基于上述分析,本文从充电曲线中提取 3 个 HI:恒流充电时间(L_1)、恒流充电电量(L_2)和恒流充电电量占比(L_3)。

Pearson 和 Spearman 相关系数可用来评估两个参数之间的相关度,其绝对值越接近 1 表明相关性越强。当变量满足连续型、正态分布和相互独立时,可使用 Pearson 相关系数,若未能符合以上任一条件时,Spearman 相关系数的可信度更高^[13],故本文采用两者衡量所提取 HI 与 SOH 之间的相关度,计算公式分别为:

$$Pearson = \frac{E(\mathbf{XY}) - E(\mathbf{X})E(\mathbf{Y})}{\sqrt{E(\mathbf{X}^2) - (E(\mathbf{X}))^2} \sqrt{E(\mathbf{Y}^2) - (E(\mathbf{Y}))^2}} \quad (7)$$

$$Spearman = \frac{\sum_{a=1}^A (x_a - \bar{x})(y_a - \bar{y})}{\sqrt{\sum_{a=1}^A (x_a - \bar{x})^2 \sum_{a=1}^A (y_a - \bar{y})^2}} \quad (8)$$

式中: \mathbf{X} 和 \mathbf{Y} 分别为 HI 和 SOH 样本总体; x_a 和 y_a 分别为样本个体;和分别为样本均值。同时,为判断所提取 HI 的有效性和泛化性,选取 4 种温度下的电池数据进行相关性分析,表 2 为所提取 HI 与 SOH 的相关系数。从表中可以看出,各温度对应的 HI 与 SOH 之间的 Pearson 和 Spearman 相关系数均在 0.85 以上,相关性较强,表明所提取 3 个 HI 可以在很大程度上表征 SOH。

降维处理可以去除各指标之间的重叠信息并提取能够最大化反应原始数据的主要特征。为此,采用 PCA 对所提取 HI 进行降维处理,减少模型的输入参数和计算复杂度,0 ℃、−5 ℃、−10 ℃、−15 ℃下的 HI 经过 PCA 降维后得到的主成分贡献率如表 3 所示,且各温度下的主成分 1、2、3 的具体表达式如式(9)~(12)所示。

表 2 HI 的 Pearson 和 Spearman 相关系数

温度/°C	Person			Spearman		
	L_1	L_2	L_3	L_1	L_2	L_3
0	0.998	0.961	0.992	0.958	0.929	0.916
-5	0.958	0.956	0.929	0.967	0.948	0.938
-10	0.856	0.862	0.853	0.897	0.899	0.874
-15	0.934	0.886	0.864	0.968	0.945	0.861

$$\begin{cases} F_1^1 = 0.577L_1^* + 0.576L_2^* + 0.579L_3^* \\ F_1^2 = -0.613L_1^* + 0.769L_2^* - 0.156L_3^* \end{cases} \quad (9)$$

$$\begin{cases} F_2^1 = 0.533L_1^* + 0.267L_2^* - 0.803L_3^* \\ F_2^2 = 0.577L_1^* + 0.576L_2^* + 0.579L_3^* \end{cases} \quad (10)$$

$$\begin{cases} F_2^3 = 0.495L_1^* + 0.354L_2^* - 0.794L_3^* \\ F_3^1 = 0.597L_1^* + 0.536L_2^* + 0.596L_3^* \end{cases} \quad (11)$$

$$\begin{cases} F_3^2 = -0.376L_1^* + 0.834L_2^* - 0.404L_3^* \\ F_3^3 = -0.690L_1^* + 0.219L_2^* + 0.690L_3^* \end{cases} \quad (12)$$

$$\begin{cases} F_4^1 = 0.579L_1^* + 0.572L_2^* + 0.582L_3^* \\ F_4^2 = -0.506L_1^* + 0.813L_2^* - 0.291L_3^* \\ F_4^3 = 0.642L_1^* + 0.127L_2^* - 0.756L_3^* \end{cases} \quad (13)$$

式中: L_1^* 、 L_2^* 和 L_3^* 分别为健康因子 L_1 、 L_2 和 L_3 的标准化变量。从表 3 中可以看出, 各温度下的主成分 1 的贡献率均超过 94%。故本文将优化处理后的主成分 1(F_1^1 、 F_2^1 、 F_3^1 、 F_4^1)作为间接健康因子, 并将其作为神经网络的输入实现锂离子电池 SOH 估算。

表 3 主成分贡献率

温度/°C	主成分 1	主成分 2	主成分 3
0	0.986 43	0.009 95	0.003 62
-5	0.986 39	0.011 85	0.001 76
-10	0.942 96	0.037 01	0.020 03
-15	0.977 21	0.021 04	0.001 75

2.3 基于 ILM 算法的双高斯核 RBF 神经网络

RBF 神经网络适用于小样本估算问题, 前提是用于训练的样本数据具有全局代表性^[14]。在本文中, 经 PCA 降维后的间接健康因子去除了冗余信息, 可以充分表征锂离子电池老化现象, 且不同温度下的间接健康因子不会发生巨大变化。因此利用某一批次的几块电池数据, 使用 RBF 神经网络便可对 SOH 进行估算。但其核函数的表达和自适应能力较低, 且网络参数学习无法在线进行。为解决该问题, 本文将双高斯核函数作为隐含层神经元激活函数, 并采用 ILM 算法在线训练网络参数。

1) DGRBF 神经网络

核函数是确定神经网络输出的数学方程式, 增加核函

数数量可以提高网络的准确性, 但会增加计算成本, 在大多数情况下, DGRBF 神经网络能够以合理的准确性和计算成本处理大量数据^[15]。因此, 本文提出将两个高斯核函数线性组合的双高斯核函数作为新的隐含层神经元激活函数, 表达式如式(13)所示。

$$\varphi_h(\mathbf{x}_m) = \alpha \exp\left(-\frac{\|\mathbf{x}_m - c_h\|^2}{\sigma_{1h}^2}\right) + (1 - \alpha) \exp\left(-\frac{\|\mathbf{x}_m - c_h\|^2}{\sigma_{2h}^2}\right) \quad (13)$$

式中: α 为高斯核函数的融合权重。为进一步说明式(13), 图 4 绘制了高斯核函数与双高斯核函数之间的变化曲线。

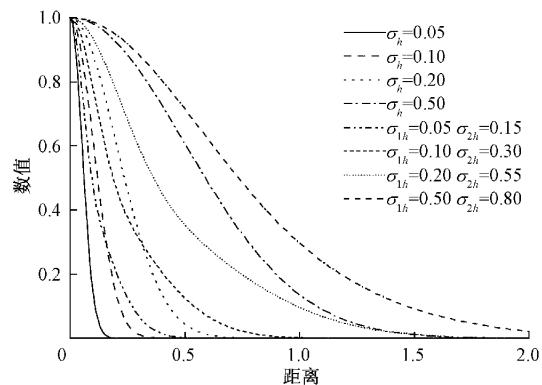


图 4 不同宽度下核函数曲线

从图 4 可以看出, 当 σ_h 等于 0.05 或 0.10 时, 高斯核函数在 $[-2.0, -0.4]$ 和 $[0.4, 2.0]$ 区间内的斜率接近于 0, 函数处于饱和状态, 使得参数难以继续更新, 而双高斯核函数的斜率仍存在, 说明双高斯核函数可以在一定程度上减少饱和现象, 提高网络的学习效率和泛化能力。

2) ILM 算法

LM 算法是一种信赖域算法, 其综合了高斯-牛顿法和梯度下降法的优点, 具有较快的运算速率。使用 LM 算法训练 DGRBF 神经网络时, 参数更新规则为:

$$Z(k+1) = Z(k) - [\mathbf{J}_m^T \mathbf{J}_m + \mu(k) \mathbf{I}]^{-1} \mathbf{J}_m^T e_m \quad (14)$$

式中: $Z(\cdot)$ 为 DGRBF 网络中的可调参数(包括连接权值 ω 、核函数中心 c 、宽度 σ_1 和 σ_2 以及融合权重 α); k 为迭代步数; \mathbf{J} 为 Jacobian 矩阵; $\mu(k)$ 为组合系数; \mathbf{I} 为单位矩阵。

DGRBF 神经网络的训练误差为:

$$e_m = o_m - y_m \quad (15)$$

式中: o_m 为网络理想输出; y_m 为网络实际输出。

当存在 m 个训练样本时, 考虑 DGRBF 网络中可调参数 w_h 、 $c_{h,i}$ 、 σ_{1h} 、 σ_{2h} 、 α , 则 Jacobian 矩阵中的行元素值为:

$$\begin{aligned} \mathbf{j}_m = & [\frac{\partial e_m}{\partial w_1} \dots \frac{\partial e_m}{\partial w_h} \dots \frac{\partial e_m}{\partial w_H}, \frac{\partial e_m}{\partial c_{1,1}} \dots \frac{\partial e_m}{\partial c_{1,i}} \dots \frac{\partial e_m}{\partial c_{1,T}} \dots \\ & \frac{\partial e_m}{\partial c_{h,1}} \dots \frac{\partial e_m}{\partial c_{h,i}} \dots \frac{\partial e_m}{\partial c_{h,T}} \dots \frac{\partial e_m}{\partial c_{H,1}} \dots \frac{\partial e_m}{\partial c_{H,i}} \dots \frac{\partial e_m}{\partial c_{H,T}}, \frac{\partial e_m}{\partial \sigma_{11}} \dots \frac{\partial e_m}{\partial \sigma_{1h}} \dots \\ & \frac{\partial e_m}{\partial \sigma_{21}} \dots \frac{\partial e_m}{\partial \sigma_{2h}} \dots \frac{\partial e_m}{\partial \sigma_{2T}} \dots \frac{\partial e_m}{\partial \alpha}] \end{aligned} \quad (16)$$

根据式(16),利用所有学习样本求得 Jacobian 矩阵,进而通过式(14)调节 DGRBF 网络中的 5 个参数。

在 LM 算法中,系数 μ 的值影响网络参数学习效率,若 μ 较大近似于梯度下降法,降低算法收敛速率;反之,类似于高斯-牛顿法,易使 $\mathbf{J}_m^T \mathbf{J}_m + \mu(k) \mathbf{I}$ 不可逆。在接近目标误差时,应加快算法收敛速度。为此,本文提出一种使组合系数 μ 随迭代步数非线性增大的方法,具体策略为:

$$\mu = \mu_2 - (\mu_2 - \mu_1) \left(1 - \frac{k}{\text{MaxItr}}\right)^5 \quad (17)$$

式中: μ_1 和 μ_2 分别为 μ 的初始值和终止值;MaxItr 和 k 分别为最大迭代步数和当前迭代步数。

与其他神经网络训练方法相比,LM 算法的效果较理想,但其离线式设计难以应对非线性动态系统。比较合理的在线建模方法是在学习过程中使用多个最新的样本动态调整网络参数^[16]。为此,本文使用滑动窗口实现在线样本存储,其所有样本均为 DGRBF 神经网络训练样本。设窗口是一个长度为 L 的“先进先出”队列,队列中的元素按进入窗口的时间顺序排列,新输入的样本为窗口最新样本,而位于队首的样本滑出窗口。

基于上述,DGRBF 神经网络的学习目标函数为:

$$e_L = \beta_i (o_i - y_i)^2 \quad (18)$$

窗口中第 i 个样本的理想输出和实际输出分别为 o_i 和 y_i ; β_i 表示遗忘因子,表达式为:

$$\beta_i = \frac{2i}{L(L+1)}, \sum_i \beta_i = 1 \quad (19)$$

对于在线学习,最新的样本所含信息较多,故式(19)中最新的样本具有较大的加权系数,而较老样本的加权系数较小。

3 结果分析及工程应用

3.1 SOH 估算结果

选取各温度下经过数据增强的样本数据作为训练集,余下的数据作为测试集,即 0 ℃、-5 ℃、-10 ℃、-15 ℃ 有 566、352、170、122 组数据用于模型训练,75、43、20、13 组数据用于模型测试。同时,在模型训练之前将样本进行归一化处理,使指标参数压缩在 0~1。神经网络的初始参数设置如下:网络隐节点个数 $H=15$;窗口长度 $L=10$;组合系数初值 $\mu_1=0.1$,终值 $\mu_2=1$;高斯核函数的融合权重 $\alpha=0.5$ 。所有仿真实验均在 MATLAB 2020a 上完成,并选用平均绝对误差(mean absolute error, MAE)和均方根误差(root mean squared error, RMSE)作为 SOH 估算模型精度的评价指标,计算公式分别为:

$$MAE = \frac{1}{T} \sum_{t=1}^T |SOH_t - SOH'_t| \quad (20)$$

$$RMSE = \sqrt{\frac{1}{T} \left(\sum_{t=1}^T (SOH_t - SOH'_t)^2 \right)} \quad (21)$$

式中: SOH'_t 和 SOH_t 分别为第 t 次循环的 SOH 估算值与

参考值; T 为循环次数。

基于测试集所得到的不同温度下的 SOH 估算结果和相对误差如图 5(a)~(d) 所示。估算模型包括采用同样样本数据训练得到的 ILM-DGRBF 模型、LM-DGRBF 模型和 LM-RBF 模型。

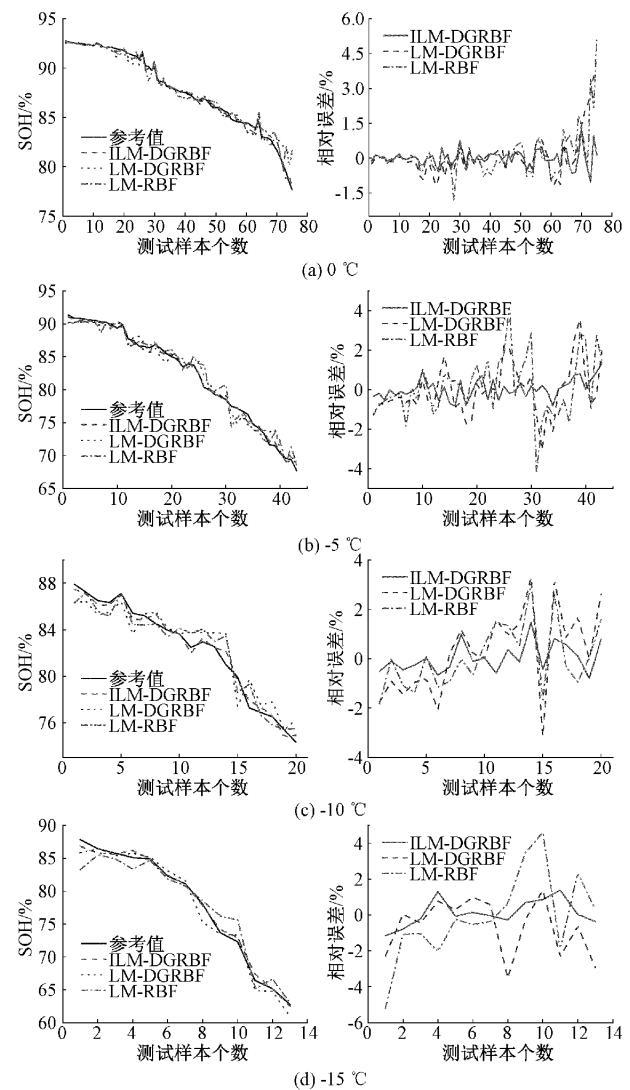


图 5 不同温度下的 SOH 估算结果和相对误差

从图 5 中可以看出,对于不同的环境温度,3 个模型均可有效地估算 SOH,表明所选间接健康因子能够充分表征锂离子电池老化。但与其他两种模型相比,ILM-DGRBF 模型的相对误差波动范围较小,0 ℃、-5 ℃、-10 ℃、-15 ℃ 的 RPE 最大值分别在 1.3%、1.4%、1.5%、1.4% 以内。此外,ILM-DGRBF 模型能够更好地描述电池老化过程中的容量再生现象,并能够适应环境温度和工况带来的 SOH 衰减趋势差异,在样本数据较少时也可较为准确地估算 SOH。

各模型 SOH 估算结果的 MAE 和 RMSE 如图 6 所示。从图中可以看出,本文所建 ILM-DGRBF 模型估算

SOH 的 MAE 和 RMSE 分别小于其他两种模型, 与 LM-DGRBF 模型相比, MAE 和 RMSE 最大值分别减少了 61.89% 和 58.50%, 与 LM-RBF 模型相比, MAE 和 RMSE 最大值分别减少了 69.02% 和 69.75%。由此可得, 本文所创建模型的估算精度较高, 且具有较强的泛化能力和较广的适用范围。

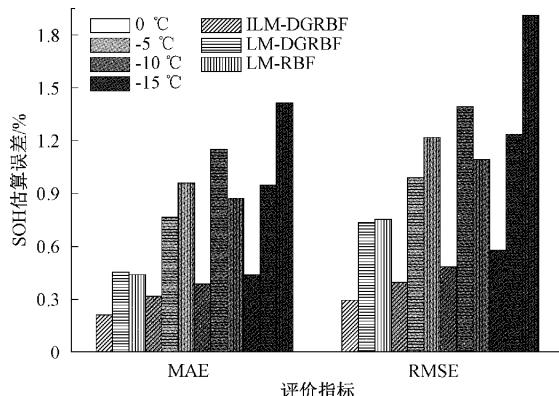


图 6 不同温度下的误差柱状图

为探究数据增强与 ILM-DGRBF 神经网络对估算结果的影响, 将训练集和测试集当作一个总体加以对比分析, 结果如表 4 所示。从表中可以看出, 数据增强后的 ILM-DGRBF 模型精度相对更高, 表明所提方法具有较强的泛化性且数据增强可以在一定程度上提高估算精度。

表 4 不同估算策略的整体结果对比

估算类型	MAE / %	RMSE / %
ILM-DGRBF	数据增强	0.50
	未数据增强	1.02
LM-DGRBF	数据增强	0.75
	未数据增强	1.48
LM-RBF	数据增强	1.27
	未数据增强	1.92

3.2 工程应用

为将所提方法应用于实际工程当中, 减少锂离子电池使用过程中的安全隐患, 本文采用集成开发工具 Android studio 设计了一款如图 7 所示的锂离子电池 SOH 智能估算系统, 该系统的计算流程如图 8 所示。

该系统在导入充电过程中的时间和电流两项参数后点击计算结果按钮, 即可调用已训练好的模型计算出该工况下的锂离子电池 SOH。同时具备网络更新功能, 通过导入相应的电池历史运行数据对模型进行更新, 提高该模型的精确度和适用范围。经验证, 该系统的 SOH 估算精度较高, 可为锂离子电池充电、使用和维护提供指导, 具有较强的实际应用价值。

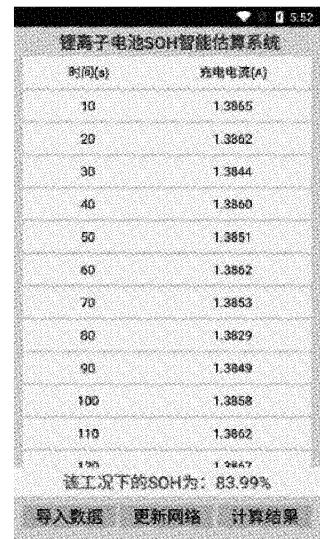


图 7 系统界面

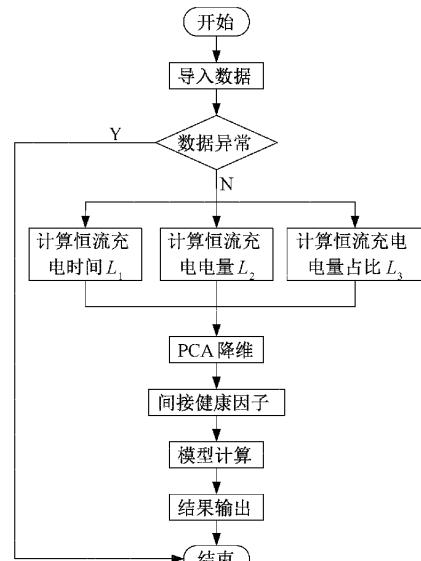


图 8 SOH 智能估算系统计算流程

4 结 论

本文提出一种基于 PCA 与 ILM-DGRBF 神经网络的锂离子电池 SOH 估算方法, 并在此基础上提出一种新的 SOH 智能估算系统。仿真结果表明, 经 PCA 降维获得的间接健康因子可以充分表征电池 SOH, 所提 ILM-DGRBF 模型的估算精度高、泛化性能好且能够适应电池老化的差异特性, 估算结果的平均绝对误差和均方根误差分别在 1.2% 和 1.4% 以内。此外, 所创建的 SOH 智能估算系统可为电池安全管理提供参考依据。然而, 本文只提取了 3 个 HI 训练估算模型, 故下一步尝试寻找能够最优秀表征 SOH 的 HI 组合。

参考文献

- [1] 赵沁峰, 蔡艳平, 王新军. 基于 WOA-ELM 的锂离子电

- 池剩余寿命间接预测[J]. 中国测试, 2021, 47(9): 138-145.
- [2] 刘运鑫, 姚良忠, 周金辉, 等. 基于 LSTM 的锂电池储能装置 SOC 与 SOH 联合预测[J]. 全球能源互联网, 2022, 5(1): 37-45.
- [3] 颜湘武, 邓浩然, 郭琪, 等. 基于自适应无迹卡尔曼滤波的动力电池健康状态检测及梯次利用研究[J]. 电工技术学报, 2019, 34(18): 3937-3948.
- [4] 赵月荷, 庞宗强. 基于无迹卡尔曼滤波的动力电池健康状态估计[J]. 国外电子测量技术, 2022, 41(10): 136-141.
- [5] 张岸, 杨春德. 基于 GAN-CNN-LSTM 的锂电池 SOH 估计[J]. 电源技术, 2021, 45(7): 902-906.
- [6] 徐宏东, 高海波, 林治国, 等. 基于 CS-SVR 模型的锂离子电池 SOH 预测[J]. 电池, 2020, 50(5): 424-427.
- [7] YANG D, ZHANG X, PAN R, et al. A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve[J]. Journal of Power Sources, 2018, 384: 387-395.
- [8] 王振新, 秦鹏, 康健强, 等. 基于衰退机理的三元锂离子电池 SOH 的诊断与估算[J]. 电子测量技术, 2020, 43(10): 7-13.
- [9] 陈峥, 顾青峰, 沈世全, 等. 基于健康特征提取和 PSO-RBF 神经网络的锂离子电池健康状态预测[J]. 昆明理工大学学报(自然科学版), 2020, 45(6): 92-103.
- [10] 张任, 胥芳, 陈教料, 等. 基于 PSO-RBF 神经网络的锂离子电池健康状态预测[J]. 中国机械工程, 2016, 27(21): 2975-2981.
- [11] 魏业文, 解园琳, 李梅, 等. 基于多指标最优权值融合的锂电池 SOH 估计[J]. 电子测量技术, 2021, 44(15): 23-29.
- [12] 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.
- [13] 王萍, 弓清瑞, 张吉昂, 等. 一种基于数据驱动与经验模型组合的锂电池在线健康状态预测方法[J]. 电工技术学报, 2021, 36(24): 5201-5212.
- [14] CAI P L, WANG Y P, LU G Q. Tunable and transferable RBF model for short-term traffic forecasting [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20(11): 4134-4144.
- [15] LIU S H, XU C R, ZHANG Y S, et al. Feature selection of gene expression data for cancer classification using double RBF-kernels [J]. BMC bioinformatics, 2018, 19(1): 1-14.
- [16] 张昭昭, 乔俊飞, 余文. 基于 LM 算法的在线自适应 RBF 网结构优化算法[J]. 控制与决策, 2017, 32(7): 1247-1252.

作者简介

李亚飞(通信作者),硕士研究生,主要研究方向为锂离子电池健康状态估算。

E-mail: 593780130@qq.com

王泰华,副教授,主要研究方向为工业过程控制。

E-mail: 9567551@qq.com

张润雨,硕士研究生,主要研究方向为网络化控制。

E-mail: 1498130337@qq.com

张家乐,硕士研究生,主要研究方向为工业过程控制。

E-mail: 1670029870@qq.com