

基于 GA-LM-BP 神经网络的锂离子电池预测研究

刘爱军, 尹明

(海军工程大学 电子工程学院, 武汉 430033)

摘要: 针对 BP 神经网络训练学习速度慢、容易陷入局部极小值的缺陷, 利用 LM 算法融合高斯-牛顿法和梯度下降法优点的快速性, 充分利用遗传算法全局随机搜索强的优势, 构建了三层 5-6-1 型的 GA-LM-BP 神经网络结构, 优化 BP 神经网络的初始权值和阈值, 减少了 BP 神经网络陷入局部极小值的几率; 通过对锂离子电池数据进行了实验, 结果表明了该方法预测的有效性。

关键词: BP 神经网络; 锂离子电池; 预测;

Research of Li-Ion Battery Prediction Based on GA-LM-BP Neural Network

Liu Aijun, Yin Ming

(College of Electronic Engineering, Naval University of Engineering, Wuhan 430033, China)

Abstract: The training learning speed of BP neural network is slow, and is easy to fall into local minimum value, the paper uses LM algorithm fusion Gauss-Newton method and the quickness of gradient descent method advantages. It is global random search strong advantage by making full use of the genetic algorithm, to build the three layers of the type 5-6-1-LM-structure of BP neural network. The GA optimizes the BP neural network's initial weights and thresholds, reduces the risk of BP neural network into a local minimum value. The results show the validity of the proposed method.

Keywords: BP neural network; Li-ion Batteries; Predict

0 引言

锂离子电池具有效率高、放电量少以及自适应性强等优势, 目前在电动汽车、新能源发电和储能电站等领域得到了广泛的应用, 如何对锂离子电池进行预测已经成为当前电子设备 PHM 的关键方面。通过分析锂离子电池的状态退化的机理, 得到对锂离子电池进行预测的依据。本文针对传统 BP 算法的不足, 本文采用遗传算法优化网络初始的权值阈值及 LM 算法的改进型 BP 神经网络, 并应用于锂离子电池的预测研究中。

1 锂离子电池状态退化机理

锂离子电池在结构上可以分为正极、负极和电解质。其中, 电解液通常是有机碳酸酯, 负极材料是石墨, 正极材料是锂铁磷酸盐。锂离子电池的正负极在充放电的过程中进行接收和释放锂离子, 并完成相应的能量转换。锂离子的充放电化学反应公式是:

充电过程: 正极反应公式: $LiFePO_4 \rightarrow Li_{1-x}FePO_4 +$

$xLi^+ + xe^-$

负极反应公式: $xLi^+ + xe^- + 6C \rightarrow Li_xC_6$

放电过程: 正极反应公式: $Li_{1-x}FePO_4 + xLi^+ + xe^- \rightarrow LiFePO_4$

负极反应公式: $Li_xC_6 \rightarrow xLi^+ + xe^- + 6C$

充电时, 电池是将电能转换成化学能, 而放电时将化学能转换成电能^[1]。在锂离子电池的充放电过程中, 内部发生了不可逆的化学反应, 从而导致电极上的 Li^+ 的流失, 使内部电阻提高。这些内部电阻的变化就是反映电池性能退化的主要参数。

实现锂离子电池 RUL 预测的重要环节就是建立其寿命退化模型。但是在实际应用中能够比较准确的建立电池退化的物理模型是困难的。NASA 的 PCoE 研究中心依据大量的实验数据^[2], 提出了一个简单可行的电池等效模型, 并以此来估计锂离子电池的 RUL, 等效模型如图 1 所示。




图 1 等效模型

其中: C_{DL} 表示双电层电容, R_{CT} 表示电荷转移电阻, R_W 表示 Warburg 阻抗和 R_E 表示电解质电阻。NASA 的研

收稿日期: 2017-11-30; 修回日期: 2017-12-18。

基金项目: 国防预先研究基金项目(9140A27020113JB11393, 9140A27020314JB11438)。

作者简介: 刘爱军(1977-), 女, 山东潍坊人, 硕士, 讲师, 主要从事于 EDA 技术应用、人工智能、神经网络等方向的研究。

究人员对数据分析后发现, R_w 和 C_{DL} 对寿命退化所起的作用微不足道, 可以忽略, 而与 $R_{CT} + R_E$ 成高度的线性关系, 并验证了锂离子电池容量和阻抗参数之间成高度的线性相关性。Saha 等人提出了如下的经验模型来描述锂离子电池^[3]。

$$C_{k+1} = \eta_c C_k + \beta_1 \exp(-\beta_2 / \Delta t_k) \quad (1)$$

其中: C_k 是第 k 个循环周期的锂离子电池容量, Δt_k 是两个相邻充放电周期之间的休息时间, β_1 和 β_2 是电池经验模型的特定参数。 η_c 是库仑效率, 用来表示电池释放的电荷总量与冲入电荷总量之间的百分比。在锂离子电池中, 充放电后增加电池的休息时间, 就能够使下一次充电周期的电池容量有所增加。

由以上分析不难看出, 电池容量会随着锂离子电池的老化而逐渐降低, 每次充电的电池容量基本上是逐步远离标称容量的, 所以可以利用锂离子电池容量退化来预测剩余寿命。

实验数据来源于美国马里兰大学 CACLE 开展的锂离子电池退化实验。在实验中, 采用的是 Arbin BT2000 的锂电池实验系统, 并以 Excel 格式保存电池退化的数据, 共有两组锂离子电池数据, 标准容量分别是 1.35 Ah 和 1.1 Ah。本文采用容量是 1.1 Ah 的测试数据。整个实验数据在构成上主要是由充电、放电和电池容量等部分, 其中充电实验数据包含阻抗数据、充电电压数据和充电电流数据, 放电实验数据包含阻抗数据、放电电压数据和放电电流数据, 以及相应的环境温度、测试时间等信息。

针对传统 BP 算法的不足, 采用遗传算法优化网络初始的权值阈值及 LM 算法的改进型 BP 神经网络, 并应用于锂离子电池的预测研究中。

2 GA-LM-BP 神经网络建模

BP 神经网络的误差后向传播过程是通过一个目标函数最小化完成的, 而目标函数是:

$$E = \frac{1}{2} \sum (t_k - O_k)^2 \quad (2)$$

传统上是根据如式 (2) 的梯度下降法来调整权重系数的。

$$\Delta \omega_{kj} = -\eta \frac{\partial E}{\partial \omega_{kj}} \quad (3)$$

权值会顺着与误差梯度相反的方向变化, 直到误差达到最小值。这种 BP 神经网络的训练时间较长, 迭代次数也比较多, 具有陷入局部最小值的缺点^[4]。针对上述问题, 本文采用 LM 算法对网络进行训练, 并克服这些缺陷。

2.1 LM-BP 神经网络建模

LM (Levenberg Marquardt, LM) 算法是融合了高斯-牛顿法和梯度下降法优点的快速算法, 既具有快速收敛特性, 又具有全局搜索的优势^[5]。假设使用 $\omega^{(k)}$ 表示第 k 次迭代的权值形成的向量, 那么新的向量 $\omega^{(k+1)}$ 由下式可以得到:

$$\omega^{(k+1)} = \omega^{(k)} + \Delta \omega \quad (4)$$

神经网络的输入误差指标函数 $E(\omega)$ 表示如下,

$$E(\omega) = \frac{1}{2} \sum_{k=1}^N (d_k - y_k)^2 = \frac{1}{2} \sum_{k=1}^N e_k^2(\omega) \quad (5)$$

接着, 通过最小二乘法求解 BP 神经网络的误差函数得到调整规则是:

$$\Delta(\omega) = -[\nabla^2 E(\omega)]^{-1} \nabla(\omega) \quad (6)$$

$\nabla^2 E(\omega)$ 是输入误差 $E(\omega)$ 的 Hessian 矩阵, $E(\omega)$ 是梯度, 针对 $\nabla^2 E(\omega)$ 进行近似推导, 可以得到,

$$\nabla(\omega) = \mathbf{J}^T(n) e(n) \quad (7)$$

$$\nabla^2 E^2(\omega) = \mathbf{J}^T(n) e(n) + \mathbf{S}(n) \quad (8)$$

其中: $\mathbf{J}(n)$ 是 $e_k(\omega)$ 的 Jacobian 矩阵, $\mathbf{S}(n)$ 是误差矩阵,

$$\mathbf{J}(n) = \begin{bmatrix} \frac{\partial e(1)}{\partial \omega_1} & \frac{\partial e(1)}{\partial \omega_2} & \dots & \frac{\partial e(1)}{\partial \omega_m} \\ \frac{\partial e(2)}{\partial \omega_1} & \frac{\partial e(2)}{\partial \omega_2} & \dots & \frac{\partial e(2)}{\partial \omega_m} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{\partial e(n)}{\partial \omega_1} & \frac{\partial e(n)}{\partial \omega_2} & \dots & \frac{\partial e(n)}{\partial \omega_m} \end{bmatrix} \quad (9)$$

$$\mathbf{S}(n) = \sum_{\omega=1}^n e_k(\omega) \nabla^2 e_k(\omega) \quad (10)$$

其中, 修正为高斯-牛顿法是:

$$\Delta(\omega) = -[\mathbf{J}^T(n) \mathbf{J}(n)]^{-1} \mathbf{J}(n) e(n) \quad (11)$$

LM 算法可以将高斯-牛顿法改进如下,

$$\Delta(\omega) = -[\mathbf{J}^T(n) \mathbf{J}(n) + \mu \mathbf{I}]^{-1} \mathbf{J}(n) e(n) \quad (12)$$

其中: \mathbf{I} 是单位矩阵, μ 是比例系数, 而且大于零。当距离一个解值比较近时, μ 值是逐渐递减的, 权值调整与高斯-牛顿法相似; 当距离一个解值比较远时, μ 值是逐渐增加的, 权值调整与梯度下降法相似。其的下降速度比梯度法要快很多, 并且经实验证明, 下降速度比梯度法提高了几十到一百倍, 极大地改善了神经网络的性能^[6]。

LM-BP 神经网络的模型实现步骤如下:

- 1) 首先是确定 LM-BP 神经网络的训练误差允许值 ε , 系数 β , 初始权值 μ 和阈值 $\omega^{(0)}$, 并令, $\mu = \mu_0, k = 0$;
- 2) 对 LM-BP 神经网络的输出进行计算;
- 3) 按照式 (8) 计算 $e_k(\omega)$ 的 Jacobian 矩阵 $\mathbf{J}(n)$;
- 4) 按照式 (11) 和式 (4) 计算 $\Delta \omega$ 和 $E(\omega^{(k)})$;
- 5) 如果 $E(\omega^{(k)}) > \varepsilon$, 按 $\omega^{(k+1)}$ 作为权值和阈值计算误差函数 $E(\omega^{(k+1)})$; 否则结束计算。
- 6) 如果 $E(\omega^{(k+1)}) < E(\omega^{(k)})$, 则令 $\mu = \mu/\beta, k = k+1$, 并跳到步骤 2); 否则不更新权值和阈值, 令 $E(\omega^{(k+1)}) = E(\omega^{(k)})$, $\mu = \mu/\beta$, 并跳到步骤 4);
- 7) 结束计算。

2.2 GA 优化 LM-BP 神经网络建模

BP 神经网络的权值和阈值一般是在 $[-0.5 \ 0.5]$ 之间的随机数, 但是这些参数对神经网络的训练效果影响很大, 而且是无法准确获取^[7]。针对这个问题, 本文采用 GA 优化来得到最佳的初始权值和阈值。GA 是利用自然界中适者生存的选择原理, 是一种面向全局的优化搜索人工智能

算法，且具有鲁棒性强的优势^[8]。

GA 优化 LM-BP 网络主要分为三部分：网络拓扑结构的确定、GA 优化初始权值和阈值、更新权值和阈值后的网络进行预测。具体的实现流程如图 2 所示。

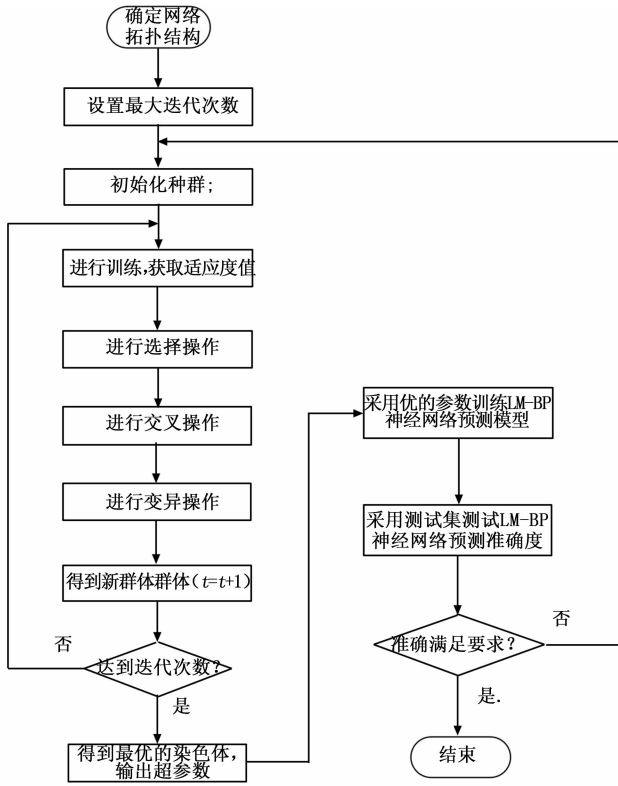


图 2 GA 优化 LM-BP 神经网络流程

步骤 1：确定 LM-BP 神经网络拓扑结构。一旦确定 LM-BP 神经网络的拓扑结构（三层网络结构应用的比较多），初始权值和阈值也就确定了。

步骤 2：种群初始化。任意产生 LM-BP 神经网络的初始权值和阈值 $X_i = (\omega_m, \omega_p, a_i, b_p)$ ，其中 m, i, p 分别是三层网络的节点数，创建初始种群 $P_x = \{X_1, X_2, \dots, X_n\}$ ， n 是种群大小，然后使用实数对种群个体进行编码。

步骤 3：将 LM-BP 神经网络训练的误差定义为适应度函数 F ，染色体的适应度越小，其成为下一代的概率就越大。

$$F = k \left(\sum_{p=1}^p abs(d_p - y_p) \right) \quad (13)$$

其中： d_p 是 GA-LM-BP 在 p 节点的理想值； y_p 是 GA-LM-BP 在 p 节点的预测值； k 表示系数，取值区间是 $[0, 1]$ 。

步骤 4：选择操作。利用轮盘赌法形成“交配池”。这样，个体被选择的概率和适应度大小就是成正比的，形式如下：

$$f(X_i) = \frac{k}{F(X_i)}, P_x = \frac{f(X_i)}{\sum_{i=1}^n f(X_i)} \quad (14)$$

步骤 5：从上面的“交配池”中选择任意两个染色体进

行交叉操作。通过比较父、子染色体适应度函数的大小。如果求得的适应度是减少的，则继续保留父染色体，否则就用子染色体替换父染色体。

步骤 6：从“交配池”中以相应的概率任意选择一个染色体进行变异操作，生成子染色体。如果子染色体的适应度大于父染色体，则保留子染色体。否则就是保留父染色体。

步骤 7：一旦迭代次数达到最大值，就得到最优权值和阈值，否则跳转到步骤 3，继续进行优化。

步骤 8：采用上面 GA 优化得到权值和阈值参数对网络的训练样本进行学习，从而得到 LM-BP 神经网络预测模型。

步骤 9：将测试样本集输入到 LM-BP 神经网络预测模型，对预测准确率进行验证，预测准确率达到要求就结束，否则跳到步骤 1 进行重复执行。

3 基于 GA-LM-BP 神经网络的锂离子电池状态预测

3.1 确定 BP 神经网络的拓扑结构

依据 Kolmogorov 定理，三层的 BP 网络就能够满足所有精确性要求实现对连续函数数值逼近^[9]，本文采取三层网络拓扑结构对锂离子电池的容量进行预测。测试数据采用马里兰大学 CACLE 的锂离子电池数据，测试数据中包含充/放电压、充/放电流、阻抗、温度和测试时间等信息，这些测试数据都会明显影响到电池的容量。所以把他们都作为神经网络的输入变量。需要预测的电池容量作为的 BP 神经网络的输出变量。采用黄金优选方法来确定中间隐含层的神经元节点数。BP 网络的输入层节点数是 m ，输出层节点数目是 p ，则理想的隐含层节点数目 i 的取值范围是：

$$a = \frac{m+i}{2} = \frac{5+1}{2} = 3 \leq i \leq (m+i+10) = (5+1+10) = 16 = b \quad (15)$$

根据上述分析，确定 BP 神经网络如图 3 所示的 5-6-1 三层结构。




图 3 BP 神经网络拓扑结构

使用该 BP 神经网络结构，根据上述的拓扑结构的计算方法，不难得到共有 42 个权值和阈值，在后续 GA 的个体编码长度就是 42，其中输入层到隐含层是 30 位，隐含层是 6 位，隐含层到输出层是 6 位，输出层数 1 位，如表 1 所示，并采用实数对个体进行编码。

表 1 初始权值和阈值位数

| | |
|-------------|------|
| 拓扑结构层的权值与阈值 | 位数 |
| 输入层到隐含层 | 30 位 |
| 隐含层 | 6 位 |
| 隐含层到输出层 | 6 位 |
| 输出层 | 1 位 |

3.2 BP 神经网络预测研究

采用的是 Arbin BT2000 的锂电池实验系统, 并以 Excel 格式保存电池退化的数据, 本文主要是采用容量是 1.1 Ah 锂离子电池的数据进行训练和测试。

针对三层 BP 网络的参数进行 100 次调试, 确定迭代次数是 100, 学习率是 0.1, 训练目标是 0.004%。针对测试数据进行滤波处理, 滤除噪声信号, 并进行归一化处理。随机选取 2000 组数据, 1900 组作为训练数据, 用于网络训练, 100 组作为测试数据, 按照设计要求构建 BP 神经网络预测模型, 用于样本的训练学习。再将测试集输入到 BP 神经网络模型, 对输出值进行预测, 对于选择的测试数据集, BP 神经网络的预测误差如图 4 所示。

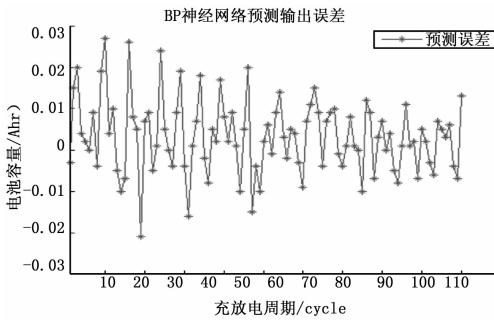


图 4 BP 神经网络预测误差

由图 4 不难看出, BP 神经网络的整体输出结果还是比较不错的, 但是还是存在一定的预测误差, 主要是集中在预测的刚开始阶段, 此时主要是用于训练学习的, 而且误差还是有点大, 最大达到了 0.029 7; 而到了中后期误差会小很多。




图 5 BP 神经网络样本预测误差

由图 5 不难看出, 按照给定的 BP 神经网络结构对训练样本进行学习, 整体的预测效果还是不错的, 最高误差是 0.03。在训练样本数达到 1200 个以后, 预测误差越来越小,

并且比较稳定, 波动性很小, 这就体现出 BP 神经网络的优势。

3.3 GA 优化 LM-BP 神经网络的预测研究

针对 BP 神经网络误差大的缺点, 引入前面 GA 优化 LM-BP 神经网络进行状态预测。首先确定 BP 神经网络是 5-6-1 的三层网络结构, GA 个体的编码长度是 42 位, GA 的进化代数是 50, 种群规模大小是 30, 采用轮盘赌法交叉操作, 交叉概率是 0.8, 变异概率是 0.01, 适应度函数是 BP 网络的预测误差 F。按照 GA-LM-BP 神经网络的建模步骤进行训练学习, GA 优化过程中的适应度函数的变化值曲线是随着代数的增加而下降的。如图 6 所示, 表明预测误差越来越小, 并且经过 50 代进化后得到的最优权值和阈值如表 2 所示。




图 6 适应度变化曲线

表 2 最优初始权值和阈值

| | | | | | | |
|---------------|---------|---------|---------|---------|---------|---------|
| | 1.4819 | 1.4931 | -2.7276 | -2.2447 | -0.9881 | -1.9257 |
| | -0.9496 | -2.5244 | 1.8420 | -2.5901 | -0.0168 | -2.0345 |
| ω_{ni} | 1.0456 | -0.5914 | -2.0804 | -0.0187 | 0.9711 | 1.5852 |
| | -1.3385 | -0.3675 | 1.0724 | 1.1690 | 0.9329 | -1.7788 |
| | -2.7230 | -0.7106 | 1.5464 | 1.5931 | -1.9729 | 1.8532 |
| a_i | 1.7532 | 1.7712 | 1.4588 | -0.3265 | -0.0877 | 0.2911 |
| ω_{ip} | 2.8814 | -1.1865 | 0.6284 | -2.1562 | -0.4892 | 1.3088 |
| b_p | -0.6668 | -- | -- | -- | -- | -- |

将表 2 中的最优权值和阈值赋值给 BP 神经网络, 再利用优化后的网络进行训练, 并预测整个系统的输出, 就可以得到 GA-LM-BP 网络预测的输出, GA-LM-BP 网络预测误差如图 7 所示。




图 7 GA-LM-BP 网络预测误差