

基于多元线性回归模型的锂电池 充电 SOC 预测

林伟钦¹, 汤平², 林旭², 陈德旺¹

(1. 福州大学 数学与计算机科学学院, 福州 350108;

2. 福建星云电子股份有限公司, 福州 350015)

摘要: 在诸多汽车电池中, 锂电池因为性能稳定、寿命长、承受力强等优势, 成为了电动汽车动力电池的绝佳选择; 为了对锂电池进行高效管理, 防止过充、过放的情况发生, 保证锂电池使用的安全性以及性能, 需要对锂电池的荷电状态 (state of charge, SOC) 进行准确预测; 实验基于锂电池充电过程中的实际数据, 使用 Python 语言编程, 建立多元线性回归模型, 通过模型预测出锂电池开始充电到结束充电过程中准确的 SOC 值; 研究表明, 锂电池充电 SOC 的变化过程具有一定的线性规律, 多元线性回归模型预测 SOC 值的误差都能控制得很小, 决定系数都高于 99%, 具有很好的预测效果, 且有一定的通用性; 除此之外, 多元线性回归模型参数较少, 结构简单, 易于实现, 更容易在实际应用中推广。

关键词: 锂电池; SOC; 多元线性回归; 预测

Lithium Battery SOC Prediction Based on Multiple Linear Regression Model

Lin Weiqin¹, Tang Ping², Lin Xu², Chen Dewang¹

(1. College of Civil Engineering, Fuzhou University, Fuzhou 350108, China;

2. Fujian Nebula Electronics Corporation, Fuzhou 350015, China)

Abstract: Among many automotive batteries, lithium batteries have become an excellent choice for power batteries for electric vehicles due to their stable performance, long life, and strong endurance. In order to efficiently manage the lithium battery, prevent overcharging and over discharge, and ensure the safety and performance of the lithium battery, it is necessary to accurately predict the state of charge (SOC) of the lithium battery. The experiment is based on the actual data of the lithium battery charging process, using Python language programming to establish a multiple linear regression model, through the model to predict the accurate SOC value of the lithium battery from the beginning of charging to the end of the charging process. The research results show that the change process of SOC of lithium battery has a certain linear law. The error of multivariate linear regression model to predict SOC value can be controlled to be small, the coefficient of determination is higher than 99%, and has good prediction effect and certain versatility. In addition, the multiple linear regression model has fewer parameters, is simple in structure, easy to implement, and is more easily popularized in practical applications.

Keywords: lithium battery; SOC; multiple linear regression; prediction

0 引言

现如今世界正在遭遇能源危机, 生态环境破坏严重, 空气污染的情况也是越来越不容乐观, 因此电动汽车在汽车产业中脱颖而出。而在诸多汽车电池中, 锂电池因为性能稳定、寿命长、承受力强等优势, 成为了电动汽车动力电池的绝佳选择^[1-2]。为了对锂电池进行高效管理, 防止过充、过放的情况发生, 保证锂电池使用的安全性以及性能, 需要对锂电池的荷电状态 (state of charge, SOC) 进行准确预测^[3-4]。如果能够精确地估计锂电池的充电 SOC 值, 可以根据充电 SOC 值的变化过程评估锂电池的健康状态, 以此来对锂电池进行定期维护, 从而使锂电池的寿命更加长

久, 使用的安全系数也大大提高。

针对锂电池 SOC 预测的问题, 各个国家都在进行深入研究, 并在不同的方法上取得了一定的成果。文献中提到的方法有 PNGV 等效电路模型法、安时积分法、开路电压结合卡尔曼滤波法、改进的卡尔曼滤波法以及神经网络法^[5-8]。但是这些方法都具有一定的局限性, 安时积分法若电流测量不准确, 会导致 SOC 计算误差, 之后误差还会随着时间推移变大, 而且还会受到充放电效率和温度变化的影响。开路电压法的缺点是测量电池需要长时间静置, 以达到电压稳定, 实际情况下静置时间需要长达几小时乃至十几个小时, 这给测量造成了很大的困难。卡尔曼滤波法因为系统内部较为复杂, 用于电池管理系统中费用昂贵, 短板比较明显。神经网络法存在算法过程繁杂的问题, 在实际工程应用中不易于推广^[9]。

实验是基于锂电池充电过程中的实际数据, 使用 Python 语言编程实现, 通过把充电机电压, 充电机电流, 最大单体电压, 剩余充电时间, 电池充电电压, 电池充电电

收稿日期: 2018-03-22; 修回日期: 2018-05-04。

基金项目: 产学研合作项目(01001707)。

作者简介: 林伟钦(1994-), 男, 福建泉州人, 研究生, 主要从事机器学习和深度学习方向的研究。

流, 充电时间, 充电能量, 充电总容量, 最大单体温度, 最小单体温度这十一个特征变量数据作为输入数据, 锂电池的充电 SOC 作为输出数据, 运用多元线性回归模型进行训练。模型训练完成后导入新的输入数据, 通过模型预测出锂电池开始充电到结束充电过程中准确的 SOC 值。

1 多元线性回归模型

1.1 模型概念

多元线性回归模型是用多个特征向量的给定值作为条件的回归分析, 得到一个输出变量和多个输入变量间的线性关系^[10], 通过数学公式的计算, 训练相关数据, 建立反映输入变量和输出变量之间关系的模型, 之后按照所得到的模型进行预测。多元线性回归模型的假设函数公式为:

$$Y = \theta_0 + \theta_1 X_1 + \theta_2 X_2 + \dots + \theta_n X_n \quad (1)$$

公式 (1) 中, n 为输入变量的个数, θ_i ($i=1, 2, \dots, n$) 为各个输入变量的回归系数, θ_0 为截距, X_i ($i=1, 2, \dots, n$) 为输入变量, Y 为输出变量。

若 X 的列满秩可以采用普通最小二乘法, 回归系数矩阵为:

$$\hat{\theta} = (X^T X)^{-1} X^T Y \quad (2)$$

1.2 代价函数

理论上只要知道了假设函数, 就能够用模型进行数据预测了。关键在于假设函数存在多个未知量, 即回归系数及截距。当选择不同回归系数和截距时, 模型的预测效果就会不同。代价函数就是用于找到最优解的目的函数, 它能帮助寻找最优的回归系数和截距, 使模型的预测效果达到最好。多元线性回归模型的代价函数公式为:

$$J(\theta_0, \theta_1, \dots, \theta_n) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2 \quad (3)$$

公式 (3) 中, $J(\theta)$ 为代价函数值, θ_i ($i=1, 2, \dots, n$) 为各个输入变量的回归系数, θ_0 为截距, m 为训练样本的数量, h_{θ} 为假设函数值即预测值, $x^{(i)}$ ($i=1, 2, \dots, n$) 为输入变量, $y^{(i)}$ ($i=1, 2, \dots, n$) 为真实值。

1.3 梯度下降法

梯度下降算法是一种优化算法, 它的作用在于能够找到一个函数的局部极小值点, 是求解机器学习算法模型参数的常用方法之一。在求解代价函数的最小值时, 可以通过梯度下降法来一步步迭代求解, 最终得到最小化的代价函数和模型参数值。多元线性回归模型的梯度下降法公式为:

$$\theta_j = \theta_j - \alpha \frac{\partial}{\partial \theta_j} J(\theta_0, \theta_1, \dots, \theta_n) \quad (4)$$

公式 (4) 中, θ_j ($j=0, 1, \dots, n$) 为截距以及各个输入变量的回归系数, α 为学习率, 用来控制下降的幅度。 $\frac{\partial}{\partial \theta_j} J(\theta_0, \theta_1, \dots, \theta_n)$ 为梯度, 也就是对代价函数求各个 θ 的偏导数。

1.4 评价标准

在估计出多元线性回归模型的参数之后, 需要对模型进行评价, 以此来判断模型预测的效果。评价的指标包括直接误差, 平均误差, 绝对平均误差, 标准差, 均方根误

差, 拟合优度检验 (决定系数) 等。

1) 直接误差, 指的是一个量的预测值或计算值与其真实值之差。

$$e = S_p - S_i \quad (5)$$

e 为模型误差, S_p 为模型输出值, S_i 为实际值。

2) 平均误差, 指的是预测得到所有值的随机误差的算术平均值。

$$\mu = \frac{\sum_{i=1}^n e_i}{n} \quad (6)$$

3) 绝对平均误差, 又叫平均绝对离差, 它是所有单个预测值与算术平均值的偏差的绝对值的平均。

$$MAE = \frac{\sum_{i=1}^n |e_i|}{n} \quad (7)$$

4) 标准差, 又常称均方差, 是离均差平方的算术平均数的平方根, 标准差能反映一个数据集的离散程度。

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (e_i - \mu)^2}{n}} \quad (8)$$

5) 均方根误差, 是预测值与真实值偏差的平方与预测次数 n 比值的平方根。

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (e_i)^2}{n}} \quad (9)$$

6) 拟合优度检验 (决定系数), 用来验证预测数和按照某种假设或算法模型计算得到的理论数之间一致性的一种统计假设检验, 以此判断该模型或者假设是否和目标预测数相一致。记 $ESS = \sum (\hat{Y}_i - \bar{Y})^2$ 为回归平方和, $RSS = \sum (Y_i - \hat{Y}_i)^2$ 为残差平方和, $TSS = \sum (Y_i - \bar{Y})^2$ 为离差平方和, 拟合优度检验的公式为:

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} \quad (10)$$

公式 (6) 中, R^2 为决定系数, 决定系数越靠近 1, 模型的拟合度就越好。

2 模型工作原理

模型训练数据的过程, 实质是求解模型参数最优解的过程。假设函数 h_{θ} 的值越接近真实值 y 时, 说明此时的模型参数预测效果越好。这里选择均方误差来作为衡量标准, 目的是想要每个样例的估计值与真实值之间差的平方的均值最小, 即得到代价函数 $J(\theta)$ 的最小值。首先随机选择 $\theta_0, \theta_1, \dots, \theta_n$, 然后不断改变它们的值, 使得 $J(\theta)$ 变小, 直至最终找到 $J(\theta)$ 的最小值点。寻找过程中采用的就是梯度下降法, 可以想象成下坡路, 假如想尽可能快下坡, 应该每次都往坡度最大的方向下山。由于多维函数不好可视化, 这里以回归参数为二维的情况为例说明, 如图 1 为梯度下降法求解代价函数 $J(\theta)$ 最小值的示意图。迭代多次之后可以得到最优的模型参数, 用最优的模型参数对应的假设函数来进行预测。

3 实验数据预处理

实验中使用了两种不同锂电池的充电数据, 记第一种




图 1 梯度下降法求解最优解示意图

锂电池为 A 锂电池, 第二种锂电池为 B 锂电池, 部分样本数据如表 1 所示。

表 1 部分样本数据

电池充电电压/V	电池充电电流/A	最大单体电压/V	剩余充电时间/min	充电机电压/V	充电机电流/A
353	69.1	3.73	65	356.7	82.88
356.8	95	3.79	43	360.6	101.98
359.9	95.5	3.81	39	363.7	102.73
364.2	100.3	3.86	33	368	99.1
369.1	117	3.92	25	373	115.43
充电时间/min	充电能量/WH	充电总容量/AH	最大单体温度/°C	最小单体温度/°C	SOC/%
1	0.92	2.56	14	22	40
6	3.3	9.22	17	24	45
10	5.57	15.49	21	27	50
13	7.83	21.65	23	29	55
16	9.78	26.92	25	31	60

数据预处理采用的是最大-最小值法 (Max-Min normalization), 最大-最小值法是对原始数据进行线性变换。记 x_{min} 和 x_{max} 分别为属性 x 的最小值和最大值, 将 x 的一个原始值 x_k 通过标准化映射成在区间 $[0, 1]$ 中的值。其转换映射公式为:

$$f(x_k) = \frac{X_k - X_{min}}{X_{max} - X_{min}} \quad (11)$$

4 实验过程及结果

4.1 实验步骤

步骤一: 首先用 Python 语言读取充电机电压, 充电机电流, 最大单体电压, 剩余充电时间, 电池充电电压, 电池充电电流, 充电时间, 充电能量, 充电总容量, 最大单体温度, 最小单体温度这十一个特征变量数据作为输入数据, 锂电池充电 SOC 作为输出数据。

步骤二: 使用最大-最小值法对输入输出数据进行预处理, 把每一维的数据都缩小到 $[0, 1]$ 之间。

步骤三: 将数据预处理之后, 对标准化了的输入输出数据进行随机分片, 其中 80% 的数据集作为训练集, 20% 的数据集作为测试集。

步骤四: 将训练集导入多元线性回归模型, 通过梯度下降法求解代价函数的最小值, 从而得到最优的回归参数。

步骤五: 分别用训练集和测试集数据对训练完成的多元线性回归模型进行测试, 得到训练集和测试集预测的锂电池充电 SOC 的值。

步骤六: 根据多元线性回归运行结果的预测值和真实值, 能够绘制误差分布图, 计算出回归方程, 直接误差, 平均误差, 绝对平均误差, 标准差, 均方根误差以及决定系数这些评价指标。

步骤七: 分析各项评价指标, 评估多元线性回归模型对锂电池充电 SOC 的预测效果

4.2 实验结果

实验首先用 A 锂电池的训练集进行测试, 训练集锂电池充电 SOC 的误差分布如图 2 所示。然后用 A 锂电池的测试集进行测试, 测试集锂电池充电 SOC 的误差分布如图 3 所示。两个图的横坐标表示测试数据的数量, 纵坐标表示锂电池充电 SOC 的误差。




图 2 A 锂电池训练集 SOC 误差分布




图 3 A 锂电池测试集 SOC 误差分布

程序执行结束后在本地输出判断预测精度的评价指标, A 锂电池充电数据在多元线性回归模型中拟合后的各个评价指标如表 2 所示。第一行是训练集的评价指标, 第二行是测试集的评价指标。

表 2 A 锂电池训练集和测试集评价指标

p	$\mu/\%$	MAE/%	$\delta/\%$	RMSE/%	$R^2/\%$
train	-0.358e-13	1.2	1.681	1.681	99.422
test	0.0699	1.23	1.727	1.729	99.412

由图 2 可以看到 A 锂电池训练集充电 SOC 的误差在 0 附近上下小范围内波动, 呈现出正态分布的样子, 再由表 2 中训练集一行的各项评价指标, 可以看到平均误差小到几乎可以忽略不计, 决定系数达到 99.422, 没有出现欠拟合的情况, 从而能够得到实验中多元线性回归模型训练得相当成功这一结论。

由图 3 可以看到 A 锂电池测试集充电 SOC 的误差分布与图 1 训练集中的十分相似, 同样是在 0 附近小范围上下浮动, 能直观地看出对锂电池充电 SOC 预测的效果不错。再由表 2 中测试集一行的各项指标详细分析, 平均误差, 绝对平均误差, 标准差, 均方根误差都很小, 决定系数达到了 99.412, 相当接近去 1, 整体的结果都和训练集的结果非常相近。由此说明多元线性回归模型适用于 A 锂电池充电 SOC 的预测, 能够很准确地估算出 SOC 值。

通过拟合的回归系数, 可以得出 A 锂电池的多元线性回归方程为:

$$Y = 0.16 - 1.627X_1 - 0.0293X_2 + 0.223X_3 + 0.025X_4 + 2.496X_5 - 0.224X_6 - 0.004X_7 - 7.517X_8 + 7.327X_9 - 0.305X_{10} + 0.298X_{11} \quad (12)$$

在测试完 A 锂电池后, 开始对 B 锂电池的实验。同样先用 B 锂电池的训练集进行测试, 训练集锂电池充电 SOC 的误差分布如图 4 所示。然后用 B 锂电池的测试集进行测试, 测试集锂电池充电 SOC 的误差分布如图 5 所示。两个图的横坐标表示测试数据的数量, 纵坐标表示锂电池充电 SOC 的误差。




图 4 B 锂电池训练集 SOC 误差分布




图 5 B 锂电池测试集 SOC 误差分布

B 锂电池充电数据在多元线性回归模型中拟合后的各个评价指标如表 3 所示。第一行是训练集的评价指标, 第二行是测试集的评价指标。

表 3 B 锂电池训练集和测试集评价指标

$\mu/\%$	MAE/%	$\sigma/\%$	RMSE/%	$R^2/\%$
1.089e-14	0.755	0.958	0.958	99.839
-0.034	0.784	1.0039	1.0045	99.823

从图 4 可以看到 B 锂电池训练集充电 SOC 的误差分布在 0 左右, 并且误差值都非常小, 整体也近似于正态分布, 从表 3 中训练集一行的各项评价指标, 能够发现平均误差几乎为零, 决定系数达到 99.839, 没有出现欠拟合的情况, 所以可以认为 B 锂电池充电数据在多元线性回归模型中同样训练得很好。

从图 5 可以看到 B 锂电池测试集充电 SOC 的误差都保持在 0.04 以内, 误差非常小, 直观地看出估算的准确性, 同 A 锂电池的预测误差相比, 对 B 锂电池的预测显得更加优秀。再对表 3 中测试集一行的各项指标进行分析, 平均误差, 绝对平均误差, 标准差, 均方根误差都十分小, 并且接近训练集的误差指标, 决定系数达到了 99.823, 这些评价指标充分体现了多元线性回归模型对 B 锂电池充电 SOC 预测的准确性。

通过拟合的回归系数, 可以得出 B 锂电池的多元线性回归方程为:

$$Y = -0.242 - 0.179X_1 + 0.088X_2 - 0.076X_3 + 0.007X_4 + 0.881X_5 + 0.003X_6 + 0.832X_7 - 1.269X_8 + 0.917X_9 + 0.573X_{10} - 0.044X_{11} \quad (13)$$

从实验结果可以了解到, 多元线性回归模型对 A 锂电池和 B 锂电池充电 SOC 值的预测结果都十分理想。这说明了锂电池充电 SOC 的变化过程具有一定的线性规律, 可以应用多元线性回归模型来做预测。而且, 多元线性回归针对该问题还具有一定通用性, 对不同的锂电池进行实验, 都能有不错的预测效果。

5 总结

针对锂电池充电 SOC 的预测问题, 使用了多元线性回归模型对两种不同的电动汽车锂电池的充电数据进行训练, 测试。研究表明, 锂电池充电 SOC 的变化过程具有一定的线性规律, 多元线性回归模型预测 SOC 值的误差都能控制得很小, 决定系数都高于 99%, 具有很好的预测效果且有一定的通用性。除此之外, 多元线性回归模型参数较少, 结构简单, 易于实现, 更容易在实际应用中推广, 这是诸如卡尔曼滤波法和神经网络法等方法所不具备的特点。

参考文献:

[1] 王笑天, 杨志家, 王英男, 等. 双卡尔曼滤波算法在锂电池 SOC 估算中的应用 [J]. 仪器仪表学报, 2013, 34 (8): 1732

- 1738.

[2] 时 玮, 姜久春, 李索宇, 等. 磷酸铁锂电池 SOC 估算方法研究 [J]. 电子测量与仪器学报, 2010, 24 (8): 769-774.

[3] 张 利, 朱雅俊, 刘征宇. 锂离子电池 SOC 与模型参数联合估算研究 [J]. 电子测量与仪器学报, 2012, 26 (4): 320-324.

[4] 杨 阳, 汤桃峰, 秦大同, 等. 电动汽车锂电池 PNGV 等效电路模型与 SOC 估算方法 [J]. 系统仿真学报, 2012, 24 (4): 938-942.

[5] 李 哲, 卢兰光, 欧阳明高. 提高安时积分法估算电池 SOC 精度的方法比较 [J]. 清华大学学报 (自然科学版), 2010, 50 (8): 1293-1296, 1301.

[6] 付 浪, 杜明星, 刘 斌, 等. 基于开路电压法与卡尔曼滤波法相结合的锂离子电池 SOC 估算 [J]. 天津理工大学学报, 2015, 31 (6): 9-13.

[7] 潘卫华, 刘晓丹. 基于改进卡尔曼滤波的锂电池 SOC 估算研究 [J]. 计算机仿真, 2014, 31 (3): 148-150, 247.

[8] 张传伟, 李林阳, 赵东刚. 基于 BP 神经网络法估算动力电池 SOC [J]. 电源技术, 2017, 41 (9): 1356-1357, 1368.

[9] 邓 青, 刘成武. 电池管理系统关键技术 SOC 估算的研究 [J]. 福建工程学院学报, 2017, 15 (6): 519-522, 534.

[10] 张景阳, 潘光友. 多元线性回归与 BP 神经网络预测模型对比与运用研究 [J]. 昆明理工大学学报 (自然科学版), 2013, 38 (6): 61-67.

(上接第 45 页)

仿真算例 (三): 计算 $FDR = 0.95, FIR = 0.9$ 时的优化仿真结果, 如表 4 所示。

表 4 测试优化配置仿真结果(三)

V_T	$f(s)$	γ_{FD}	γ_{FI}	m	不能检测到的故障	不能隔离的故障
11101 10101 10111 11111 11011	0.044	0.96	0.92	20	fm_7	fm_9 fm_{12}
11011 11111 01111 01111 11101	0.048	1.0	1.0	21	无	

无仿真算例 (三) 中所提测试性指标基本可以达到武器装备的测试性指标要求。由表 4 可知至少需要为模型设置 $m=20$ 个测试才能满足所提测试性指标要求; 至少需要 $m=21$ 个测试才可以完全检测和隔离所有故障模式, 这比仿真算例 (一) 中满测试配置方案减少使用了 4 个测试, 效率提高了 16%, 若考虑测试接口设计和测试费用, 该测试配置方案可以大大降低实际系统的设计难度和全寿命周期费用。

4 结论

本文针对目前测试性建模工作中尚无具体方法指导测试配置这一问题, 以系统故障空间为基础, 建立了系统的故障传播模型。然后以测试性分析的指标为约束, 以测试数量为优化目标, 提出了一种基于混合离散二进制粒子群一遗传算法的测试优化配置方法, 并应用在某型装备涡扇发动机的传动供电系统中。通过考虑不同的测试性指标要求, 得到了不同情况下的最优测试配置方案及对应的测试性指标和无法检测、隔离的故障模式。由测试配置仿真结果可知, 该算法可以在满足系统测试性指标要求下给出系

统的最优测试配置方案, 有效地解决了系统测试性分析与设计方面的问题, 能够提高测试性分析与设计效率, 降低系统的设计难度, 对于指导复杂系统的测试性建模工作具有实际应用价值。

参考文献

[1] 邱 静, 等. 装备测试性建模与设计技术 [M]. 北京: 科学出版社, 2012.

[2] 唐小峰. 面向故障诊断的测试流程自动生成技术研究 [D]. 长沙: 国防科学技术大学, 2010.

[3] 代 京, 张 平, 李行善, 等. 航空机电系统测试性建模与分析新方法 [J]. 航空学报, 2010, 31 (2): 277-284.

[4] 丁 昊. 基于多信号流图的系统测试性建模分析及软件设计 [D]. 哈尔滨: 哈尔滨工业大学, 2013.

[5] 石君友. 测试性设计分析与验证 [M]. 北京: 国防工业出版社, 2011.

[6] Holland J H. Adaptation in natural and artificial systems [M]. MIT Press, 1992.

[7] Man K F, Tang K S, Wong S K. Genetic algorithms: Concepts and applications [J]. IEEE Transactions on Industrial Electronics, 1996, 43: 519-532.

[8] 苏永定. 机电产品测试性辅助分析与决策相关技术研究 [D]. 长沙: 国防科学技术大学, 2004.

[9] Turgut O E. Hybrid Chaotic Quantum behaved particle swarm optimization algorithm for thermal design of plate fin heat exchangers [J]. Applied Mathematical Modelling, 2016, 40 (1): 50-69.

[10] 高云龙, 闫 鹏. 基于多种群粒子群算法和布谷鸟搜索的联合寻优算法 [J]. 控制与决策, 2016, 31 (4): 601-608.

[11] 方 群, 徐 青. 基于改进粒子群算法的无人机三维航迹规划 [J]. 西北工业大学学报, 2017, 35 (1): 66-73.

[12] Kennedy J. A discrete binary version of the particle swarm optimization algorithm [J]. Proc Smc, 1997, 5: 4104-4108.

[13] 胡乃平, 宋世芳. 一种局部与全局相结合的微粒群优化算法 [J]. 计算机工程, 2008, 34 (17): 205-207.

[14] 张雪峰. 基于 TSP 的改进遗传算法研究及系统实现 [D]. 长春: 东北师范大学, 2009.