

# 基于多元线性回归的锂动力电池荷电状态鲁棒预测

张松<sup>1</sup>, 林伟钦<sup>1</sup>, 陈德旺<sup>1</sup>, 汤平<sup>2</sup>, 郑其荣<sup>2</sup>

(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:** 目前广泛使用的锂电池荷电状态 (state-of-charge, SOC) 预测方法的训练数据需要通过大量的仿真实验获取, 而电动汽车在充电过程中产生的大量的充电记录数据并没有得到合理利用; 为了能有效利用这些充电记录数据, 将多元线性回归算法应用到 SOC 预测中; 多元线性回归方法将电压、电流、电容等物理量作为与 SOC 直接相关的输入变量从而对 SOC 进行回归预测; 由于 SOC 的时序特征, 将 SOC 预测分为多个子预测过程, 不断迭代计算, 循环预测 SOC 的下一时刻输出值; 同时为了克服异常样本对 SOC 预测精度的影响, 采用两种常见的鲁棒回归算法 (Theil-sen 算法与 RANSAC 算法) 来进行 SOC 预测; 实验结果表明, 鲁棒回归算法及多元线性回归算法能够很好地捕捉到 SOC 的增长规律, 相比之下, Theil-sen 算法精度更高, 误差约 1.398%, 能够很好地满足 SOC 预测的实际需求。

**关键词:** 多元鲁棒回归; SOC; 时序特征; Theil-sen; RANSAC

## Robust Prediction of Battery State-of-charge Based on Multiple Linear Regression

Zhang Song<sup>1</sup>, Lin Weiqin<sup>1</sup>, Chen Dewang<sup>1</sup>, Tang Ping<sup>2</sup>, Zheng Qirong<sup>2</sup>

(1. College of Mathematics and Computer Science, Fuzhou University, Fuzhou 350108, China;

2. Nebula Electronics Corporation in Fujian, Fuzhou 300648, China)

**Abstract:** The training data of the widely adopted lithium battery state-of-charge (SOC) prediction method needs to be obtained through plenty of simulation experiments, while the large amount of charging record data generated by the electric vehicle during the charging process is not properly utilized. In order to effectively utilize these data, a multiple linear regression algorithm is applied to the SOC prediction. The multivariate robust regression method uses the physical quantities such as voltage, current, and capacitance of the lithium battery which directly related to the SOC as input variables to perform regression prediction on the SOC. Due to the timing characteristics of the SOC, the prediction of SOC is divided into multiple sub-prediction processes, and the iterative calculation is continuously performed to cyclically predict the next output value of SOC. At the same time, two common robust regression algorithms (Theil-sen algorithm and RANSAC algorithm) are used to predict SOC in order to overcome the influence of abnormal samples on SOC prediction accuracy. The experimental results show that the robust regression algorithm and the multiple linear regression algorithm can well capture the growth law of SOC. In contrast, Theil-sen algorithm has higher precision and the error is about 1.398%, which can satisfy the actual needs of SOC prediction well.

**Keywords:** multivariate robust regression; SOC; Timing characteristics; Theil-sen; RANSAC

## 0 引言

新能源电动汽车作为原有的燃油汽车替代品能够有效缓解油能源紧张、减少尾气污染等问题从而成为未来汽车制造的主要发展方向。其中锂动力电池由于其容量大、循环使用寿命长、安全性高、体积小等优点成为电动汽车的

主要动力来源。电池荷电状态 (state-of-charge, SOC) 是电动汽车电池管理系统的重要指标, SOC 的精确预测能够有效提高电池的利用率, 防止电池过充电和过放电从而避免对电池造成损害, 进而提高电池的使用寿命、降低使用成本。目前来说, SOC 的预测方法主要分为: 安时积分法、开路电压法、卡尔曼滤波法、神经网络法和数据驱动法。

安时积分法是最常用的 SOC 估测方法<sup>[1]</sup>, 它通过对充放电过程中的电流进行积分从而求得电池电量变化。该方法适用于任何类型电池的状态估计, 所以许多学者将其应用于 SOC 估测<sup>[2-4]</sup>。安时积分法的计算需要精确的电流测量值, 如果电流值测量不准确, 在不断的迭代计算中误差不断累积进而导致预测结果的偏差。开路电压法是最简单的

收稿日期: 2019-01-22; 修回日期: 2019-02-18。

基金项目: 国家重点研发计划课题(2018YFB0104403); 产学研合作项目(00101707)。

作者简介: 张松(1995-), 男, 安徽阜阳人, 硕士研究生, 主要从事机器学习等方向的研究。

通讯作者: 陈德旺(1976-), 男, 安徽芜湖人, 博士, 教授, 博导, 主要从事人工智能、大数据、智慧交通、智慧新能源等方向的研究。

SOC 预测方法, 所以该方法得到了大量应用<sup>[5-7]</sup>。但是该方法在测量电池电压时需将电池长时间放置以达到电压稳定才能继续实验, 因此开路电压法不能用于 SOC 的实时预测且精度较低。卡尔曼滤波法是一种精确预测电池状态的算法, 它的核心思想是对动力系统的状态做出最小方差意义上的最优估计。卡尔曼滤波法的优点是它可以实时动态预测 SOC, 但电池参数之间一般为非线性关系, 所以许多非线性预测的改进版本被用于 SOC 估计<sup>[8-10]</sup>。缺点就是卡尔曼滤波预测结果好坏取决于与电池模型能否精确表达电池的动态状态, 但复杂的电池模型意味着计算时间的增加。此外卡尔曼滤波算法对模型噪声和测量噪声的统计特性作了假设, 而实际情况中这些假设条件可能难以成立。神经网络以其复杂的结构、强大的计算力非常适合 SOC 预测这种高度非线性参数关系计算, 该方法被用在 SOC 预测并取得了非常好的效果<sup>[11-13]</sup>。但是该方法需要大量的训练数据且计算量非常大。此外 SOC 预测值的精确度与神经网络结构、输入变量的选择等因素有着直接关系, 不合理的设置将导致预测值偏差很大。数据驱动法在 SOC 预测中也可以称为回归拟合法。该方法不需要对电池系统进行建模, 是一种简单易行且预测精度较高的方法。该方法需要大量的训练数据, 训练方法的选择、输入变量的设置合适与否关系着拟合结果的精确性。目前来说, 对于此方法在 SOC 预测方面的研究<sup>[14-15]</sup>相对较少, 因此有着很大的发展空间。

本文采用多元线性回归方法对 SOC 进行预测, 该方法是数据驱动法中的一种。与其它预测方法不同的是, 基于多元线性回归的 SOC 预测方法可以直接利用充电桩记录的电池充电数据进行训练从而不需要行大量充放电实验获取数据。此外, 由于数据中存在异常样本, 我们选用了线性回归、Theil-sen 和 RANSAC 算法来进行对比实验。实验结果表明, 3 种算法对 SOC 预测都有着很高的精度。相比线性回归算法, RANSAC 和 Theil-sen 算法的预测误差分别降低了 15.4% 和 23.38%。

## 1 多元回归模型

### 1.1 多元线性回归模型

多元线性回归模型是一种常用的回归模型, 它使用多个特征向量作为条件从而得到一个输出变量和多个输入变量间的线性关系。在确定输入变量与输出变量后可使用相关数据对模型进行训练, 求得符合真实变量关系的系数从而建立反映输入变量和输出变量之间关系的数学模型。多元线性回归模型一般数学表示为:

$$(y(\mathbf{w}, \mathbf{x}) = \omega_0 + \omega_1 * x_1 + \omega_2 * x_2 + \dots + \omega_n * x_n) \quad (1)$$

其中:  $n$  为自变量的个数,  $\mathbf{w} = \{\omega_0, \omega_1, \dots, \omega_n\}$  参数向量, 也就是需要通过训练才能确定的系数。 $X_i$  ( $i=1, 2, \dots, n$ ) 为自变量,  $Y$  为因变量。

求解多元回归问题的常用机器学习方法为最小二乘法。最小二乘法对  $\mathbf{w}$  的估计, 是基于模型中变量之间相互独立的基本假设的, 即输入向量  $X$  中的任意两项  $X_1$  和  $X_2$  之间

是相互独立的。多元线性模型的本质是多元线性回归方程的求解。求解方法有梯度下降法、Normal Equation 等等。当特征数量较大时使用梯度法, 反之则使用后者。

其中, Normal Equation 求解系数矩阵的计算公式为:

$$\mathbf{w} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \quad (2)$$

由于 Normal Equation 方法中需要进行矩阵的求逆运算, 所以当特征数量较大时计算量会变得非常大, 这里就需要采用最小二乘法来求解参数。梯度下降法是最常用的迭代优化算法, 可以用于求解最小二乘问题。在确定损失函数后通过梯度下降法逐步减小损失函数的取值, 当取得损失函数的最小值时便得到最终的模型参数值。其中与的等价关系为:

$$\mathbf{Y} = \mathbf{w}\mathbf{X} \quad (3)$$

定义损失函数为残差的平方, 则最小化损失函数为:

$$L(\mathbf{X}, \mathbf{w}, \mathbf{Y}) = \frac{1}{2} (\mathbf{Y} - \mathbf{w}\mathbf{X})^2 \quad (4)$$

这里对于  $\mathbf{w}$  求导为  $\frac{dL}{d\mathbf{w}}$ , 设学习率  $lr$ , 则参数的更新过程为:

$$\mathbf{w} = \mathbf{w} - lr * \frac{dL}{d\mathbf{w}} \quad (5)$$

经过不断的迭代更新, 当损失函数值或迭代次数达到预设的相应阈值时训练过程结束, 这时的  $\mathbf{w}$  便为最终参数值。

### 1.2 鲁棒回归模型

鲁棒回归是一种回归分析形式, 旨在克服传统参数和非参数方法的一些局限性。和一般回归分析方法相比, 鲁棒回归 (Robust Regression) 不容易受离群值的影响。一些常见的鲁棒回归算法包括: Theil-sen、Huber、RANSAC。鲁棒线性回归的数学表达式如下:

$$y(\mathbf{w}, \mathbf{x}) = \omega_0 + \omega_1 * x_1 + \omega_2 * x_2 + \dots + \omega_n * x_n + \epsilon \quad (6)$$

其中:  $\mathbf{w} = \{\omega_0, \omega_1, \dots, \omega_n\}$  参数向量,  $\mathbf{x}$  为训练样本,  $\epsilon$  为模型的随机误差。

多元线性回归方法的常用求解方法为最小二乘法, 而最小二乘法的参数拟合结果非常容易受到异常数据的影响。为了提高模型的鲁棒性, 鲁棒回归模型引入了作为模型的随机误差。其中围绕随机误差的优化从而引出了两种不同的改进思路: 1) 使用一定的采样方法先除去数据样本中异常样本再进行学习; 2) 保留异常值但采取一定的方法减弱其对回归结果的影响。本文选取了 Theil-sen 和 RANSAC 算法作为 SOC 鲁棒预测算法, 其中 Theil-sen 属于减弱异常值影响的优化方法, RANSAC 算法为剔除异常数据的重采样方法。

#### 1.2.1 Theil-sen

Theil-sen 回归是一种非参数统计方法, 该方法对数据分布没有严格要求, 是处理有部分异常数据的理想回归方法。该回归算法需要计算数据两两之间的斜率; 然后取这些斜率的中位数为回归方程的斜率; 之后通过变量  $x$  与变

量  $y$  的中位数计算出截距, 从而得到回归方程。

Theil-Sen 回归是一个参数中值估计器, 它适用泛化中值, 对多维数据进行估计, 因此其对多维的异常点有很强的稳健性。其一元回归模型为:

$$y = \alpha + \beta x + \epsilon \quad (7)$$

其中:  $\alpha, \beta$  为模型的参数,  $\epsilon$  为模型的随机误差。对于单变量的 Theil-Sen 回归, 斜率的计算方程如下:

$$b_{ij} = \text{Median} \left\{ \frac{y_i - y_j}{x_i - x_j}; x_i \neq x_j, i < j = 1, 2, \dots, n \right\} \quad (8)$$

这里有  $b_{ij} = b_{ji}$ , 之后将求得的这些斜率的中位数作为总体回归系数的估计值。截距  $\alpha$  的计算公式如下:

$$(\alpha_i = \text{Med}(y_i) - \beta \text{Med}(x_i)) \quad (9)$$

如此取求得的  $n$  个值的中位数作为截距  $\alpha$  的估计值, 则模型参数求解完毕。

Theil-Sen 回归是一个参数中值估计器, 它适用泛化中值, 对多维数据进行估计, 因此其对多维的异常点有很强的稳健性。同时该算法原理简单, 易于实现。但 Theil-Sen 回归只是取数据参数的平均值并不能消除异常点对参数估计的影响, 且不适用于数据维数较高的情况。

### 1.2.2 RANSAC

RANSAC (random sample consensus) 是一个求解已知模型的参数的框架, 可以用于解决计算机视觉问题、统计学问题以及模型参数估计问题。RANSAC 算法在运行前需要设定几个参数: 1) 迭代次数  $k$ ; 2) 内外点距离阈值  $t_1$ ; 3) 一致性集合大小阈值  $t_2$ 。RANSAC 的算法流程为:

1) 从数据中随机选取模型参数估计的最少的数据 (对于多元线性回归问题, 则取随机的一组数据), 计算出参数方程;

2) 计算出数据集中其余点与已算出模型的距离  $d$ , 当时  $d < t_1$  就判定该点为内点 (inlier), 当  $d_2 > t_1$  时就判定该点为外点 (outlier);

3) 接着统计内点个数  $n$ , 当  $n > t_2$  时就判定该模型为最优模型  $m_{best}$ , 并记录该模型的统计误差  $e_{min}$ , 即每个内点与求得模型的距离;

4) 重复步骤 1) ~ 3), 当得到新模型时, 比较新模型的误差  $e$  与  $e_{min}$  的大小, 如果  $e < e_{min}$  则更新  $m_{best}$  和  $e_{min}$ ;

5) 最终输出  $m_{best}$ , 得到最终的参数模型。

RANSAC 回归原理简单、可以应用在很多问题中。该方法本质上是对数据集的重采样, 很好地避免了异常点对参数估计的影响。但 RANSAC 算法的计算量较大, 同时停止条件和阈值的设定对结果影响很大。

## 2 SOC 回归预测

### 2.1 SOC 定义

目前来说, 较为统一的是从电量角度定义 SOC。所以 SOC 可以定义为: 电池在一定放电倍率下, 剩余电量与相同条件下可用容量的比值。

$$SOC = \frac{Q_n}{C_n} \quad (10)$$

其中:  $Q_n$  为当前剩余电量,  $C_n$  表示当前可用容量。因此, 当  $SOC=1$  时说明电池充电完成, 当  $SOC=0$  时电池电量耗尽。

### 2.2 SOC 预测模型

本文采用多元线性模型对锂动力电池进行 SOC 充电预测, 其中用到的对比方法有线性回归、Theil-sen 和 RANSAC 算法。采用的实验数据是电动汽车在充电站充电时充电桩所记录的充电数据。由于目前研究问题的特殊性, 我们从维数众多的数据中提取出与本文实验相关的特征。此外, 为了简化问题模型以及 SOC 预测系统易于实现, 我们并没有考虑温度、内阻等物理因素。从最终的实验结果来看, 简化的问题模型不仅使问题变得简单, 而且取得了非常高的 SOC 预测精度。其中我们提取的输入特征如表 1 所示。

表 1 输入特征表

特征名称	字段解释	代表符号
StartSOC/%	初始 SOC	S
BatChargerVolt/ V	电池电压	V
BatChargerA/ A	电池电流	A
ChargeTime/ s	充电时间	T
MAH/ Ah	充电容量	m

所以 SOC 预测模型可表示为:

$$y = \omega_0 + \omega_1 * S + \omega_2 * V + \omega_3 * A + \omega_4 * T + \omega_5 * m + \epsilon \quad (11)$$

其中:  $y$  表示模型预测结果 SOC,  $\omega_0 \dots \omega_5$  为模型训练参数,  $\epsilon$  为鲁棒回归的随机误差。

由于 SOC 是一种时间序列型的变量, 本文将充电数据中的两条充电记录时间间隔作为一次计算过程, 输出结果设为变量  $EndSOC$ 。预测过程如卡尔曼滤波算法一般不断迭代计算, 循环预测 SOC 的下一时刻输出值。训练前需要对数据进行预处理, 例如归一化等, 训练时采用最小二乘法进行参数拟合, 最终求得 SOC 的预测模型。

### 3 评价标准

为了量化线性回归、Theil-sen 和 RANSAC 算法预测 SOC 的结果精确度, 本文使用了 4 个常用的模型性能评估指标: 平均误差、绝对平均误差、均方根误差 (root mean square error, RMSE) 和标准差 (Standard deviation, Std)。为了更好地分析算法性能, 本文在数据集上对 3 种算法进行 50 次试验, 并给出其平均结果。

1) 误差定义

首先针对预测值与实际值之间的差异我们定义了误差公式:

$$e = SOC_t - SOC_p \quad (12)$$

其中:  $e$  为模型误差,  $SOC_t$  为真实值,  $SOC_p$  为模型输

出值。

2) 平均误差

$$\mu = \frac{\sum_{i=1}^n |e_i|}{n} \quad (13)$$

3) 平均绝对误差

$$MAE = \frac{\sum_{i=1}^n e_i}{n} \quad (14)$$

(4) 标准差

$$Std = \sqrt{\frac{\sum_{i=1}^n (e_i - \mu)^2}{n}} \quad (15)$$

(5) 均方根误差

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (e_i)^2}{n}} \quad (16)$$

*Std* 指标的计算公式如公式 (8) 所示。*Std* 是一种度量数据分散程度的标准, 可以作为评价数据值偏离算术平均值程度的依据。该指标可以用来衡量算法在训练阶段和测试阶段的稳定性。*RMSE* 指标的计算公式如公式 (9) 所示。其中,  $n$  表示样本的个数,  $e_i$  表示第  $i$  个样本所对应的预测值, 均方根误差能够很好地反映出模型的预测误差。

## 4 实验结果与分析

### 4.1 数据预处理

本文采用的实验数据是从充电桩上采集的汽车充电记录数据, 由于公司考虑到未来的多方面应用, 所以这些数据中特征数量非常多。我们首先需要从中选取与 SOC 预测相关的特征。出于对问题模型的简化以及预测系统的易实现性, 我们只提取了少数相关的特征变量, 这一点在 2.2 节中有说明。但原始的数据与需要的数据形式有着很大的不同, 所以我们要对数据进行一定的处理。

首先是 SOC 数据的离散化问题。由于充电桩记录的电池 BMS 输出 SOC 的精度为 1%, 所以导致数据中的 SOC 值表现为离散化且存在众多相同值。为了解决这一问题, 我们假设在较短的时间间隔内 SOC 为线性增长, 因此可以对原始数据中的重复值进行线性插值处理。处理的结果如图 1 所示:

在图 1 中, (a) 图中深色代表的是原始 SOC 值, 浅色表示的是线性插值处理后的值。可以看到总体上来说线性插值并没有改变 SOC 曲线的趋势及规律。此外, 图 (b), (c), (d) 分别显示的是 SOC 为 1%, 50%, 99% 处的 SOC 值, 这里浅色代表的处理后 SOC 值, 与深色代表的原始值相比, 处理后的连续值更适合 SOC 的预测。

接着是对训练数据进行分片处理。SOC 是一种时间序列型的变量, 所以需要将 SOC 预测处理为许多 SOC 子预测。这里我们将两次记录间作为一次 SOC 子预测过程, 每个子预测中输入有初始 SOC 及其它相关特征 (如电压、电量等), 输出为子预测的结果: EndSOC。这里的 EndSOC 接着作为下一个子预测过程的初始 SOC, 从而实现 SOC 预测的不断迭代计算, 最终完成整个过程的 SOC 预测。

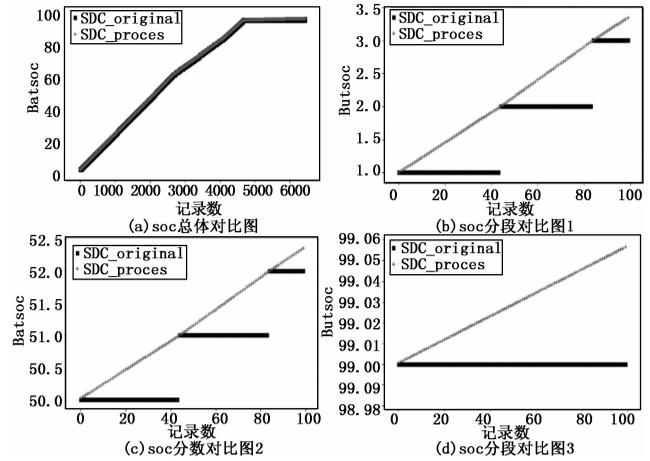


图 1 SOC 处理前后对比图

最后, 由于电子仪器本身的原因, 记录数据中不可避免的会出现一些异常数据, 这里我们以电压、电流数据为例。

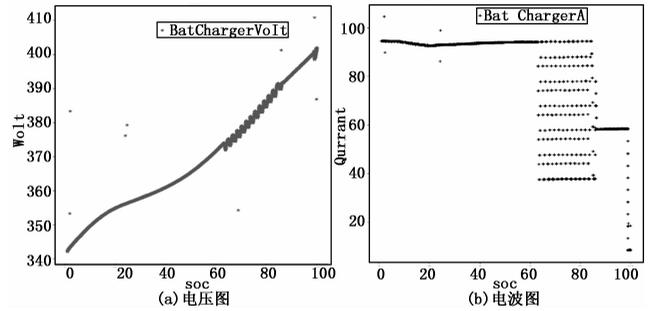


图 2 电压、电流数据图

如图 2 所示, (a) 图表示的是电压与 SOC 之间的关系。从中可以看出, 电压随着 SOC 的增加而增长, 但是存在一些局外点分布在边缘区, 同时在 (b) 图中也存在异常数据点。这些异常数据可能会影响多元线性回归结果的准确性, 但是人工剔除异常数据的代价过大。由于数据样本中异常数据点相对较少, 所以鲁棒回归非常适用于本文的 SOC 预测。

### 4.2 实验结果

本文采用了线性回归、Theil-sen 和 RANSAC 算法预测 SOC, 具体的训练结果如表 2 所示, 其中测试的最优结果用加粗字体表示。

表 2 SOC 预测结果量化表

评价标准	实验算法					
	线性回归		Theil-sen		RANSAC	
	训练	测试	训练	测试	训练	测试
$\mu$	.0001	-0.974	.00023	0.7728	.00001	-0.974
MAE	.00236	0.9748	.00246	1.256	.00237	.9747
<i>Std</i>	.00328	1.5428	.00336	1.165	.00328	1.245
RMSE	.00328	1.8246	.00337	1.398	.00328	1.5428

从表 2 的结果来看, 线性回归的训练结果最好, 其 4 项指标都是最优。而 RANSAC 算法的训练结果与线性回归结果非常接近, 这里的接近同样表现在参数拟合结果上。这里我们认为是由于数据样本中异常样本与正常样本的数量不均衡所导致的。异常样本数量过少, 导致 RANSAC 算法筛选出的正常数据样本与原始样本之间的差异不够明显。不过在测试结果中我们发现 RANSAC 算法预测结果的 *Std* 与 *RMSE* 比线性回归分别降低了 19.3% 和 15.4%。这说明 RANSAC 算法一定程度上能够降低异常数据对 SOC 预测的影响。Theil-sen 算法的拟合结果除了 *MAE* 劣于线性回归与 RANSAC 外, 其  $\mu$ 、*Std*、*RMSE* 与线性回归相比分别降低了 20.6%、24.48% 和 23.38%。这说明与线性回归和 RANSAC 算法相比, Theil-sen 算法即便在异常数据的影响下更能够有效预测 SOC。

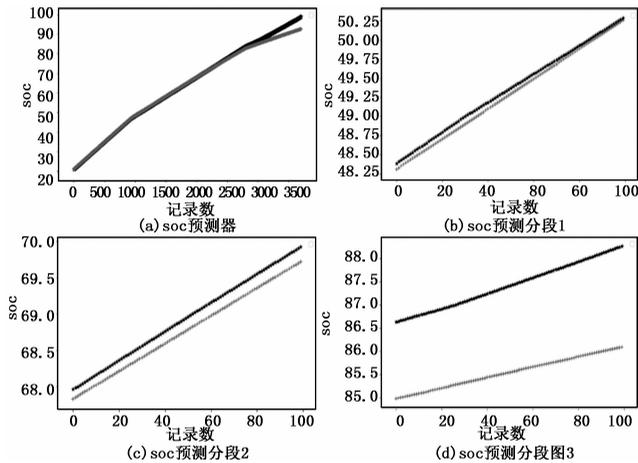


图 3 线性回归 SOC 预测结果图

图 3 显示的训练后的线性回归对 SOC 的拟合结果图, 其中 a 图为总拟合结果图, 其中深色表示的是 SOC 实际值, 浅色表示的是 SOC 预测值。总体上来看, 线性回归拟合结果非常接近实际值, 这一情况在 b 和 c 图得到了体现。但当 SOC 实际达到 85% 左右时拟合值与实际值之间出现了很大的偏差, 图 d 显示了预测值与实际值之间有着 1.5% 左右的平均误差。

图 4 显示的训练后的 RANSAC 算法对 SOC 的拟合结果图, 其中 a 图为总拟合结果图, 其中细线表示的是 SOC 实际值, 粗线表示的是 SOC 预测值。与线性回归结果相似, 除后小段外 RANSAC 算法拟合结果非常接近实际值, 当 SOC 实际达到 85% 左右时 (图 d) 拟合值与实际值之间出现了较大的偏差。

图 5 显示的训练后的 Theil-sen 算法对 SOC 的拟合结果图, 其中 a 图为总拟合结果图, 其中浅色表示的是 SOC 实际值, 深色表示的是 SOC 预测值。与线性回归和 RANSAC 结果不同, 除开始小段 Theil-sen 算法拟合结果与实际值较接近外, Theil-sen 算法在其它阶段的预测值与实际值之间都有着不小的误差。但当 SOC 实际达到 85% 左

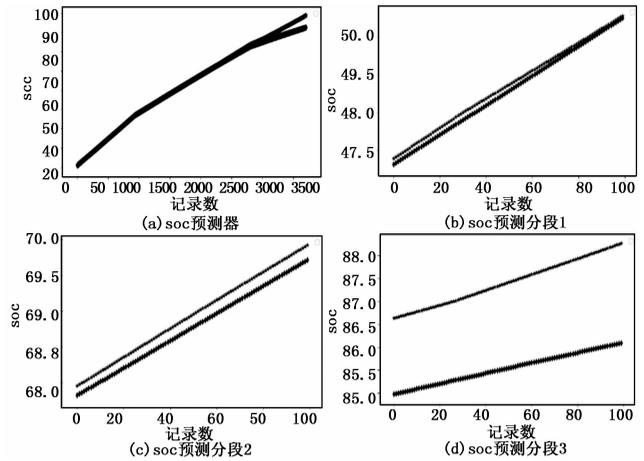


图 4 RANSAC 算法 SOC 预测结果图

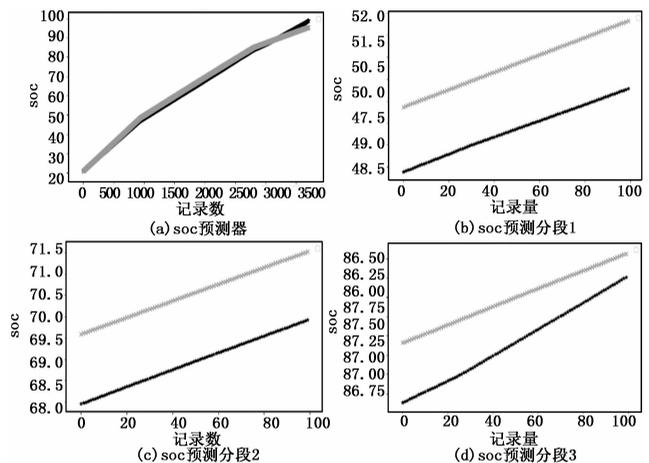


图 5 Theil-sen 算法 SOC 预测结果图

右及之后的阶段中, 拟合值与实际值之间的偏差处于不断缩小的状态。这说明 Theil-sen 算法在 85%~99% 范围内对 SOC 的预测精度要远高于另外两种算法。

### 5 结论

出于对问题模型的简化以及对 SOC 预测系统易于实现的考虑, 本文采用了多元线性回归方法来进行锂动力电池充电时 SOC 预测, 同时将充电桩记录的充电数据作为实验数据样本。由于在数据样本中存在异常数据, 我们选用了 Theil-sen 和 RANSAC 算法对 SOC 进行鲁棒预测。实验结果表明, 基于多元线性模型的回归算法对 SOC 预测都有着很高的精度。其中, 由于异常数据的影响, 线性回归的预测结果在 SOC 实际值为 85% 之后的范围内偏差相对较大; 同时异常数据的数量较正常样本数量非常小使得 RANSAC 算法没有发挥相应的作用; Theil-sen 算法则很好地减少了异常数据对参数拟合产生的影响, 其预测精度在 3 种算法中最高。

但是, 这 3 种算法都没能完全精确地预测 SOC, 例如

(下转第 187 页)