

数据驱动下的用户行为特征标签与电池容量衰减诱因分析与容量预测

王乙多

上海理工大学机械工程学院, 上海

收稿日期: 2024年10月26日; 录用日期: 2024年11月19日; 发布日期: 2024年11月26日

摘要

本文通过数据驱动方法, 研究了电动汽车用户行为特征与电池容量衰减之间的关系。通过对不同行为进行标签化与分析, 揭示了快充、深度充电、高温充电等特定行为显著加速了电池容量的衰减。文章采用横向与纵向分析相结合的方法, 识别和评估了用户行为的累积效应。为了进一步提升分析的深度和预测的准确性, 本文结合了统计学模型和多层感知器(MLP)神经网络模型, 对于捕捉用户行为与电池容量衰减之间的微妙联系尤为有效。通过训练MLP模型, 本文能够学习用户行为特征与电池容量衰减之间的复杂映射关系, 从而构建一个基于行为特征的容量衰减预测模型, 为电池管理系统提供优化方向。

关键词

数据驱动, 神经网络, 电池容量衰减, 用户行为, 特征标签, 诱因分析

User Behavior Feature Labels and Analysis of Battery Capacity Degradation Triggers and Capacity Prediction under Data-Driven Conditions

Yiduo Wang

School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Oct. 26th, 2024; accepted: Nov. 19th, 2024; published: Nov. 26th, 2024

Abstract

This paper investigates the relationship between electric vehicle user behavior characteristics and

battery capacity degradation through a data-driven approach. By labeling and analyzing various behaviors, the study reveals that specific actions, such as fast charging, deep charging, and high-temperature charging, significantly accelerate battery capacity degradation. A combination of cross-sectional and longitudinal analysis is employed to identify and evaluate the cumulative effects of user behaviors. To enhance the depth of analysis and improve prediction accuracy, the study integrates statistical models with a multilayer perceptron (MLP) neural network, which proves particularly effective in capturing the subtle links between user behavior and battery capacity degradation. By training the MLP model, we can learn the complex mapping relationship between user behavior characteristics and battery capacity degradation, leading to the development of a behavior-based capacity degradation prediction model. This model provides optimization directions for battery management systems.

Keywords

Data-Driven, Neural Networks, Battery Capacity Degradation, User Behavior, Feature Labeling, Cause Analysis

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在碳中和目标的推动下，新能源汽车尤其是电动汽车(EVs)得到了广泛发展。锂离子电池是电动汽车的核心组件，其使用寿命和容量衰减直接影响着车辆性能和用户体验。然而，随着充放电循环次数的增加，电池容量逐渐衰减，严重影响电池的使用寿命。现有的研究大多基于电池的物理机理，但随着海量车辆数据的积累，数据驱动的分析方法为预测电池衰减带来了新的契机。

电池容量衰减是电池寿命的重要衡量指标，衰减过程受到温度、充放电行为、车辆使用习惯等多因素影响。传统方法主要基于电池内部物理机理，面临复杂性高[1]、数据获取困难的挑战，且难以全面解释不同用户行为对容量衰减的影响。因此，本研究采用数据驱动的方法，深入探讨了电动汽车用户行为特征与电池容量衰减之间的相关性。通过细致地对用户行为进行标签化和分析，本文发现快充[2]、深度放电和高温充电等特定行为对电池容量的衰减有显著的加速作用。文章综合运用了横向分析和纵向分析，不仅识别了用户行为的即时效应，还评估了这些行为随时间累积的长期影响。该模型的输入层包括了各种用户行为特征，如充电频率、充电时长、充电结束时的电量水平等，而输出层则是预测的电池容量衰减率[3]。通过调整隐藏层的神经元数量和激活函数，本文优化了模型的结构，以提高预测的准确性和泛化能力[4]。MLP模型的训练过程中，本文使用了交叉验证和网格搜索等技术，以防止过拟合并优化超参数。

本文的研究旨在通过分析电动汽车用户的充放电行为，建立行为标签与电池容量衰减之间的关系，从而为电池管理系统提供优化策略，延长电池的使用寿命。

2. 数据驱动下的容量衰减诱因分析

2.1. 数据处理

本研究采用数据集为上海市新能源汽车公共数据采集与监测研究中心提供的 2022 年 600 辆不同车型纯电动汽车的出行与充电行为数据，下表(见表 1)为出行数据关键指标说明：

Table 1. Explanation of data fields**表 1.** 数据字段解释

字段名	字段描述
collectiontime	数据采集时间
vehicledata_vehiclestatus	车辆状态
vehicledata_chargestatus	充电状态
vehicledata_speed	车速
vehicledata_summileage	累计里程
vehicledata_sumvoltage	总电压
vehicledata_sumcurrent	总电流
vehicledata_soc	SOC
extremevalue_maxtmpval	最高温度值
extremevalue_mintmpval	最低温度值

数据处理与特征提取：首先，对大量实车数据进行清洗，并提取与电池容量衰减相关的行为特征，包括快充次数、深度充电次数、高温/低温充电时长等。这些特征在一定程度上反映了用户的使用习惯，并对容量衰减产生了影响。

使用统计学中的描述性分析方法(如均值、标准差等)对清洗后的实车数据进行特征提取。提取特征包括：快充累积量 X_1 、深度充电次数 X_2 、高温充电时长 X_3 、日均行驶里程 X_4 ...

例如，通过设定阈值，将这些特征标签化，使得不同用户行为得以量化。例如，用户的快充累积量可以表示为：

$$X_1 = \sum_{i=1}^n \text{快充次数} \quad (1)$$

其中， n 是该用户的充电周期次数。类似地，其他行为特征也通过累积和统计规则提取。数据清洗后，本文需要对目标车辆用户的充电特征行为进行提取。本文通过设置相应的提取规则，将用户的充电特征进行提取(见表 2)：

Table 2. Feature extraction rules**表 2.** 特征提取规则

Numer	充电特征	提取规则
1	快充累积量	累积使用快充次数
2	深度充电	单次充电 $\Delta\text{SOC} \geq 50\%$ 且终止 SOC 大于 80%
3	高温充电累积量	充电时电池环境温度大于 30℃ 且小于 70℃ 的充电时间
4	低温充电累积量	充电时电池环境温度低于 10℃ 且高于 -20℃ 的充电时间
5	日均行驶里程	当前记录里程/当前实车使用时长
6	压差跳变次数→不一致	到当前充电时刻，累积平均充电压差>30 次数

2.2. 横向分析：容量衰减的统计建模

对 100 辆同品牌车辆在固定里程(如 5 万公里、10 万公里)下的特征累积值进行提取，并筛选容量衰减严重的用户，分析其行为特征是否处于前 20%。通过比较用户行为累积值的排名，判断特定行为是否与容量衰减显著相关[3]。横向分析利用多元回归模型来研究用户行为特征对电池容量衰减的影响。假设电池容量衰减量 Y 与多个行为特征 $X_1, X_1, \dots, X_k$ 之间的关系可以用线性回归模型表示：

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon \quad (2)$$

其中， β_0 是截距， $\beta_1, \beta_2, \dots, \beta_k$ 是行为特征的回归系数， ϵ 是误差项。使用普通最小二乘法(OLS)估计这些回归系数，并通过显著性检验(如 t 检验和 F 检验)来判断哪些用户行为特征对容量衰减有显著影响[5]。例如，如果快充次数 X_1 的回归系数 β_1 显著为正，则表明快充行为会加速电池容量的衰减。

2.3. 容量衰减用户分类

为了探究实际电动汽车用户容量衰减与充电行为特征之间的相关性，本研究提出通过分析充电容量衰减严重的用户群体(见图 1)，识别其显著的充电行为特征[6]，并评估这些特征对电池容量衰减的潜在影响。




Figure 1. Classification of attenuated users
图 1. 衰减用户分类

据此，本文将用户群体划分为三个类别：80%的正常用户，15%的中度衰减用户，以及 5%的严重衰减用户。通过提取这些用户在特定里程点(例如，图 1 所示的 5 万公里)的充电特征，本文依据分类规则获取了他们在这一里程下的充电累计特征值。进一步地，本文通过特征经验值分析，筛选出对用户电池容量衰减有显著影响的特征，并将这些特征作为用户的充电行为标签[7]。分析结果表明，严重衰减用户的充电行为标签如下表所示(见表 3)，其中不同用户 ID 对应的行为标签可能正是影响他们电池容量衰减的关键行为因素。这些突出的用户特征行为，作为潜在的影响因素之一，对电池容量衰减的影响值得进一步研究。

Table 3. Horizontal analysis of specified user characteristic behavior labels
表 3. 横向分析指定用户特征行为标签

User ID	行为标签
34	不一致性差
39	高温充电时间
62	低温充电、快充次数多
90	深度充电次数、高温充电时间

2.4. 纵向分析：行为变化的时间序列分析

在对单个电动汽车用户的充电行为进行纵向分析时，本文采用了时间序列分析方法，以详细追踪和评估用户行为在不同里程节点上的变化趋势及其对电池容量衰减的影响。通过这种分析，本文能够识别出用户行为模式的演变，并进一步探讨这些变化是如何影响电池健康状况的。

具体而言，时间序列分析使本文能够观察到用户在不同使用阶段的充电习惯[8]，例如充电频率、充电时长、充电开始的时间点，以及充电结束时的电量水平。通过收集和分析这些数据点，我们可以量化用户行为随时间的变化，并评估这些变化对电池容量衰减的具体影响。

例如，本文发现一些用户在车辆使用初期展现出良好的充电习惯，例如避免过度充电和深度放电，这有助于减缓电池容量的衰减。然而，随着时间的推移，这些用户可能由于便利性考虑或充电基础设施的可访问性变化，开始采取更为激进的充电策略，如频繁的快充或电池电量经常充至 100%。这些行为的变化可能导致电池容量在特定里程段内加速衰减。

下图是假设用户的行为习惯不变，则累积量本应呈现线性增长。本文可视化用户 22 与用户 44 的特征图像(见图 2)，分析他们的特征行为的激进和缓和趋势，即用户行为习惯的变化改变是否会导致行为习惯的变化？本文下面做进一步的研究。




Figure 2. Changes in behavioral habits

图 2. 行为习惯变化图

此外，时间序列分析还揭示了季节性因素对充电行为的影响。例如，在冬季，由于电池性能受低温影响，用户可能需要更频繁的充电以维持相同的行驶里程，这种季节性的充电行为变化也可能对电池容量产生影响。

对单个用户的纵向行为数据进行时间序列分析，研究行为特征 X_t 随时间 t 的变化对电池容量的影响。

假设容量衰减 Y_t 随里程增长表现为一个自回归移动平均模(ARMA):

$$Y_t = \alpha_0 + \sum_{i=1}^p \alpha_i Y_{t-i} + \sum_{j=1}^p \theta_j \epsilon_{t-j} + \epsilon_t \tag{3}$$

通过拟合 ARMA 模型,可以评估用户在不同里程时的行为特征对电池衰减的动态影响。若发现某些行为(如高温充电次数)在某一里程段内显著增加,容量衰减趋势加速,则可以推断行为变化与容量变化的时间依赖性。

2.5. 统计分析方法

为了定量评估电动汽车用户行为特征与电池容量衰减之间的线性关系,本研究引入了皮尔逊相关系数(Pearson correlation coefficient)作为分析工具。皮尔逊相关系数是一种衡量两个变量之间线性相关程度的统计指标,其值介于-1 到 1 之间,其中 1 表示完全正相关,-1 表示完全负相关,而 0 则表示没有线性相关性[9]。

通过对用户充电行为数据的收集,包括充电频率、充电时长、充电开始的时间点,以及充电结束时的电量水平等,本文计算了这些行为特征与电池容量衰减之间的皮尔逊相关系数。分析结果显示,某些行为特征与电池容量衰减之间存在显著的正相关性,例如频繁的快充行为和电池经常充至 100%的电量水平,这些行为可能导致电池容量加速衰减。相反,那些展现出更为温和充电习惯的用户,如避免深度放电和过度充电的用户,其电池容量衰减的速率则相对较慢,这在皮尔逊相关系数中表现为较低的正相关性或负相关性。

此外,本文还发现,随着车辆使用里程的增加,用户行为特征与电池容量衰减之间的相关性可能会发生变化。在车辆使用初期,用户行为对电池容量的影响可能并不明显,但随着时间的推移,某些不良充电习惯的累积效应可能导致电池容量衰减的加速[10],这一点在时间序列分析中得到了体现。




Figure 3. Correlation heatmap of behavioral characteristics
图 3. 行为特征相关性热力图

使用皮尔逊相关系数来定量分析各行为特征与容量衰减之间的线性相关性(见图 3):

$$r_{XY} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \quad (4)$$

其中, X_i 和 Y_i 分别是特征和容量衰减的观测值, $\bar{X}$ 和 $\bar{Y}$ 是均值。

皮尔逊相关系数的计算结果揭示了用户行为特征与电池容量衰减之间的线性相关性, 为本文提供了定量分析工具, 以识别和优化那些可能加速电池容量衰减的用户行为。这些发现强调了对用户行为进行持续监测和干预的重要性, 以减缓电池容量衰减并延长电池的使用寿命。然后本文通过 PCA 得到的主成分可以作为新的输入变量, 用于后续的统计分析或机器学习模型[11], 以评估用户行为对电池容量衰减的影响。这种方法使本文能够在一个更简洁的数据表示中, 探索和理解用户行为与电池容量之间的关系, 从而为电池健康管理和用户行为优化提供科学依据。

3. 多层感知器(MLP)神经网络

多层感知器(MLP)神经网络是一种前馈人工神经网络, 通过至少一层的隐藏层实现对输入数据的非线性变换, 从而能够学习和模拟复杂的函数映射关系。MLP 是深度学习和机器学习领域中常用的模型, 特别适用于处理分类和回归问题。

3.1. MLP 的基本结构

MLP 神经网络通常由三层构成: 输入层、隐藏层和输出层。在某些情况下, 为了增加模型的复杂度和学习能力, 可以增加更多的隐藏层, 形成深层网络结构。

输入层: 接收原始数据输入。

隐藏层: 由多个神经元组成, 每个神经元与其他层的神经元相连, 并通过权重传递信号。

输出层: 产生网络的最终输出, 其神经元的数量取决于任务的类型(例如, 二分类问题通常有一个神经元)。

3.2. MLP 的基本结构

MLP 的工作原理基于每个神经元对输入信号的加权求和, 并通过激活函数进行非线性变换。设输入向量为 $x = (x_1, x_2, \dots, x_n)$, 权重向量为 $w = (w_1, w_2, \dots, w_n)$, 偏置项为 b , 则神经元的输出 a 可以通过以下公式计算:

$$a = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (5)$$

其中, f 是激活函数, 用于引入非线性, 常见的激活函数包括 Sigmoid、ReLU (Rectified Linear Unit) 和 Tanh 等。

3.3. 训练 MLP 神经网络

MLP 神经网络的训练通常采用误差反向传播(Backpropagation)算法, 这是一种监督学习的方法。训练过程包括以下步骤:

1) 前向传播(Forward Propagation): 输入数据通过网络, 计算每层的输出, 直至得到最终的输出结果。

2) 计算损失(Loss Calculation): 根据网络输出和真实标签计算损失函数, 常用的损失函数包括均方误差(MSE)和交叉熵损失等。

3) 反向传播(Backpropagation): 根据损失函数计算梯度, 并通过网络反向传播这些梯度, 以更新网络中的权重和偏置项。

4) 权重更新(Weight Update): 使用梯度下降或其变体(如 Adam、RMSprop 等)根据梯度更新权重和偏置项。

这一过程会迭代进行, 直到网络在训练数据上的表现达到满意的水平或达到预设的迭代次数。

结合前面两种分析方法的结果, 本文将用户分类训练了 MLP 神经网络模型, 以预测电池容量衰减。MLP 模型能够学习横向分析中识别出的普遍行为模式, 以及纵向分析中观察到的个体行为变化, 从而构建一个综合的预测模型。模型的输入层包括了从横向分析中提取的用户行为特征, 如充电频率和充电深度, 以及从纵向分析中提取的行为变化趋势[12]。隐藏层负责捕捉这些特征之间的复杂非线性关系, 而输出层则预测了未来的电池容量衰减情况。

4. 数据分析与结果

在本研究中, 本文利用多层感知器(MLP)神经网络模型对电动汽车用户行为特征与电池容量衰减之间的关系进行了深入分析。以下是对 MLP 预测模型分析结果的详细说明。

4.1. 训练 MLP 神经网络

本文的 MLP 模型包括输入层、两个隐藏层以及输出层。输入层由多个节点组成, 每个节点代表一个用户行为特征, 如充电频率、充电时长和充电温度等。两个隐藏层分别包含多个神经元, 以捕捉输入特征之间的复杂非线性关系。输出层则预测电池容量的衰减率。

为了评估模型的性能, 本文采用了交叉验证的方法[13], 将数据集分为训练集和测试集。通过多次迭代训练, 本文调整了模型的超参数, 包括学习率、隐藏层神经元的数量和激活函数, 以优化模型的预测准确性。

4.2. 预测结果

MLP 模型的预测结果显示, 用户行为特征与电池容量衰减之间存在显著的非线性关系。模型成功地捕捉到了快充、深度充电和低温充电等行为特征对电池容量衰减的加速影响。此外, 模型还揭示了某些行为特征组合的累积效应, 这些组合在单一特征分析中可能并不明显。

例如, 模型预测发现, 频繁的快充行为与深度充电相结合, 会显著提高电池容量衰减的速率。这一发现强调了用户行为多样性对电池容量衰减的综合影响。当其他特征行为按均值设定时, 约快充 178 次后容量达到百分之八十(如图 4)。根据先前的结论, car1 电池容量对温度影响不明显, 因此网络预测结果使得随低温充电时间增加, 电池容量变化仅约为 3.28%(如图 5)。可以反应快充特征对电池容量衰减影响严重。

4.3. 模型准确性评估

为了评估 MLP 模型的准确性, 本文计算了预测值与实际电池容量衰减值之间的相关系数。结果显示, 模型具有较高的预测准确性, 相关系数达到了 0.85 以上。此外, 本文还计算了均方误差(MSE)和平均绝对误差(MAE), 以进一步评估模型的预测性能[13]。MSE 和 MAE 的值均在可接受的范围内, 表明模型能够可靠地预测电池容量衰减。

5. 总结与展望

MLP 神经网络模型的分析结果表明, 用户行为特征对电池容量衰减有显著影响。通过结合横向和纵

向分析，MLP 模型不仅能够识别出影响电池容量衰减的关键行为因素，还能够预测这些因素如何随时间发展而影响电池的健康状况。本文对 car1 车辆用户行为特征进行预测，发现随低温充电时间增加，电池容量变化仅约为 3.28%。这表明低温充电对容量衰减的影响程度并不大。相比于深度充电，快速充电对电池容量衰减程度的影响更大，在快充次数达到 178 次时，SOH 便衰减到 80%。这与本文前面分析的行为相关性所一致，相关性分析表明低温充电行为与容量的相关性最低，而相关性最高的特征即为深度充电特征和快速充电的累积量特征，可以证明模型的可靠性。




Figure 4. Characteristics of capacity decay and fast charging deep charging behavior

图 4. 容量衰减与快充深充行为特征图




Figure 5. Characteristics of capacity decay and low temperature charging behavior

图 5. 容量衰减与低温充电行为特征图

综上所述，这为电池管理系统提供了更为精确的预测工具，使其能够根据用户行为的变化实时调整

电池维护策略，从而有效延长电池的使用寿命并保持其性能。未来的研究可以进一步探索不同用户群体的行为模式[14]，以及如何通过干预措施来优化这些行为，以减缓电池容量的衰减。

参考文献

- [1] Al-Saadi, M., Olmos, J., Saez-de-Ibarra, A., Van Mierlo, J. and Bercibar, M. (2022) Fast Charging Impact on the Lithium-Ion Batteries' Lifetime and Cost-Effective Battery Sizing in Heavy-Duty Electric Vehicles Applications. *Energies*, **15**, Article 1278. <https://doi.org/10.3390/en15041278>
- [2] Han, X., Ouyang, M., Lu, L., Li, J., Zheng, Y. and Li, Z. (2014) A Comparative Study of Commercial Lithium Ion Battery Cycle Life in Electrical Vehicle: Aging Mechanism Identification. *Journal of Power Sources*, **251**, 38-54. <https://doi.org/10.1016/j.jpowsour.2013.11.029>
- [3] You, G., Park, S. and Oh, D. (2016) Real-Time State-of-Health Estimation for Electric Vehicle Batteries: A Data-Driven Approach. *Applied Energy*, **176**, 92-103. <https://doi.org/10.1016/j.apenergy.2016.05.051>
- [4] Li, W., Sengupta, N., Dechent, P., Howey, D., Annaswamy, A. and Sauer, D.U. (2021) One-Shot Battery Degradation Trajectory Prediction with Deep Learning. *Journal of Power Sources*, **506**, Article 230024. <https://doi.org/10.1016/j.jpowsour.2021.230024>
- [5] Wang, Z., Song, C., Zhang, L., Zhao, Y., Liu, P. and Dorrell, D.G. (2022) A Data-Driven Method for Battery Charging Capacity Abnormality Diagnosis in Electric Vehicle Applications. *IEEE Transactions on Transportation Electrification*, **8**, 990-999. <https://doi.org/10.1109/tte.2021.3117841>
- [6] Ecker, M., Gerschler, J.B., Vogel, J., Käbitz, S., Hust, F., Dechent, P., et al. (2012) Development of a Lifetime Prediction Model for Lithium-Ion Batteries Based on Extended Accelerated Aging Test Data. *Journal of Power Sources*, **215**, 248-257. <https://doi.org/10.1016/j.jpowsour.2012.05.012>
- [7] Richardson, R.R., Osborne, M.A. and Howey, D.A. (2019) Battery Health Prediction under Generalized Conditions Using a Gaussian Process Transition Model. *Journal of Energy Storage*, **23**, 320-328. <https://doi.org/10.1016/j.est.2019.03.022>
- [8] Birkel, C.R., Roberts, M.R., McTurk, E., Bruce, P.G. and Howey, D.A. (2017) Degradation Diagnostics for Lithium Ion Cells. *Journal of Power Sources*, **341**, 373-386. <https://doi.org/10.1016/j.jpowsour.2016.12.011>
- [9] Severson, K.A., Attia, P.M., Jin, N., Perkins, N., Jiang, B., Yang, Z., et al. (2019) Data-Driven Prediction of Battery Cycle Life before Capacity Degradation. *Nature Energy*, **4**, 383-391. <https://doi.org/10.1038/s41560-019-0356-8>
- [10] Lindgren, J. and Lund, P.D. (2016) Effect of Extreme Temperatures on Battery Charging and Performance of Electric Vehicles. *Journal of Power Sources*, **328**, 37-45. <https://doi.org/10.1016/j.jpowsour.2016.07.038>
- [11] Barré, A., Deguilhem, B., Grolleau, S., Gérard, M., Suard, F. and Riu, D. (2013) A Review on Lithium-Ion Battery Ageing Mechanisms and Estimations for Automotive Applications. *Journal of Power Sources*, **241**, 680-689. <https://doi.org/10.1016/j.jpowsour.2013.05.040>
- [12] Schmalstieg, J., Käbitz, S., Ecker, M. and Sauer, D.U. (2014) A Holistic Aging Model for Li(NiMnCo)O₂ Based 18650 Lithium-Ion Batteries. *Journal of Power Sources*, **257**, 325-334. <https://doi.org/10.1016/j.jpowsour.2014.02.012>
- [13] Rahman, T. and Alharbi, T. (2024) Exploring Lithium-Ion Battery Degradation: A Concise Review of Critical Factors, Impacts, Data-Driven Degradation Estimation Techniques, and Sustainable Directions for Energy Storage Systems. *Batteries*, **10**, Article 220.
- [14] Xu, B., Oudalov, A., Ulbig, A., Andersson, G. and Kirschen, D.S. (2018) Modeling of Lithium-Ion Battery Degradation for Cell Life Assessment. *IEEE Transactions on Smart Grid*, **9**, 1131-1140. <https://doi.org/10.1109/tsg.2016.2578950>