

doi: 10.19562/j.chinasae.qcgc.2024.11.012

基于Transformer的纯电动汽车充电时间预测*

胡杰^{1,2,3}, 陈琳^{1,2,3}, 王志红^{1,2,3}, 卿海华^{1,2,3}, 王浩杰^{1,2,3}

(1. 武汉理工大学, 现代汽车零部件技术湖北省重点实验室, 武汉 430070;

2. 武汉理工大学, 汽车零部件技术湖北省协同创新中心, 武汉 430070;

3. 湖北省新能源与智能网联车工程技术研究中心, 武汉 430070)

[摘要] 纯电动汽车充电时间的安排是车主日常生活中至关重要的环节,直接影响车主出行的便利度和舒适体验。然而,目前仍然面临充电桩资源不足、充电须提前规划等挑战,为解决车主因车辆电量不足而无法立即用车的问题,提出一种基于Transformer模型的充电时间预测解决方案,帮助车主更好地规划日常行程。为了更好地了解电池性能衰减程度和容量损失情况,采用容量法评估电池健康状态,并分析驾驶人的充电行为,对电池充电行为特征进行构建。使用Savitzky-Golay滤波器对表征电池衰减的特征进行平滑处理,并进行累积变换,使特征能更全面地表征电池信息;再耦合皮尔逊相关系数和LASSO(least absolute shrinkage and selection operator)回归算法二次筛选得到最优特征集。最后,利用Transformer模型的超强注意力机制,对充电时间进行预测。通过实验数据验证,此方案可以准确且快速地预测纯电动汽车的充电时间,决定系数达到0.999,运行时间为156 ms。

关键词: 电动汽车; 充电时间; 数据驱动; Transformer

Transformer-Based Prediction of Charging Time for Pure Electric Vehicles

Hu Jie^{1,2,3}, Chen Lin^{1,2,3}, Wang Zhihong^{1,2,3}, Qing Haihua^{1,2,3} & Wang Haojie^{1,2,3}

1. Wuhan University of Technology, Hubei Key Laboratory of Modern Auto Parts Technology, Wuhan 430070;

2. Wuhan University of Technology, Auto Parts Technology Hubei Collaborative Innovation Center, Wuhan 430070;

3. Hubei Technology Research Center of New Energy and Intelligent Connected Vehicle Engineering, Wuhan 430070

[Abstract] The arrangement of charging time for pure electric vehicles is a crucial part of the daily life of car owners, directly affecting the convenience and comfortable experience of their travel. However, there are still challenges such as insufficient charging station resources and the need for advanced planning for charging. To solve the problem of car owners being unable to use the vehicle immediately due to insufficient battery, a charging time prediction solution based on the Transformer model is proposed to help car owners better plan their daily itinerary. In order to better understand the degree of battery performance degradation and capacity loss, the capacity method is used to evaluate the health status of batteries, and the charging behavior of drivers is analyzed to construct the characteristics of battery charging behavior. Savitzky Golay filter is used to smooth out the features representing battery attenuation and perform cumulative transformation, so that the features can more comprehensively represent battery information. Then the Pearson correlation coefficient and LASSO (Least Absolute Shrinkage and Selection Operator) regression algorithm are coupled to obtain the optimal feature set through secondary screening. Finally, using the Transformer model's strong attention mechanism, the charging time is predicted. Through experimental data verification, this scheme can accurately and quickly predict the charging time of pure electric vehicles, with a determination coefficient of 0.999 and a running speed of 156 ms.

Keywords: electric vehicles; charging time; data driven; Transformer

* 广西省科技重大专项(2023AA03009)资助。

原稿收到日期为2024年03月30日,修改稿收到日期为2024年05月16日。

通信作者:胡杰,教授,博士,E-mail:auto_hj@163.com。

前言

近年来,电动车因其环保、节能的显著优势而被广泛应用。在我国,使用公共充电站是纯电动汽车的主要充电方式。为了避免电池过充,延长电池寿命,同时帮助驾驶员更有效地安排行程和充电计划,提高出行效率,对充电时间进行预测尤为重要。为了更加准确预测充电时间,国内外学者都对此进行了研究。目前,基于数据驱动充电时间预测的研究主要分为多模型结合和单模型两种方法。在多模型结合方面,程树英等^[1]采用信息粒化和支持向量回归相结合的方法来进行电池充电剩余时间的预测。Bi等^[2]提出基于回归和时间序列相结合的充电时间预测模型,通过考虑充电量的回归模型和采用时间序列法对回归模型进行校正,以提高模型的拟合精度。Ullah等^[3-4]也通过使用多种不同的机器学习算法来预测电动汽车的充电时间,并使用新开发的Shapley加性解释方法来解决机器学习算法的不可解释性问题。然而,这些研究侧重于多模型,但多模型训练时间长,且未完全考虑到实车充电的复杂影响因素。此外,也有一些研究者采用单个模型,例如杜京义等^[5]使用独立长短期记忆循环神经网络(IndyLSTM)来预测充电剩余时间。虽然该方法利用了IndyLSTM可以长期记忆历史数据的优势,但其泛化性难以保证,因为使用的数据集为实验室数据,无法完全反映实际车况。还有黄忆等^[6]在考虑充电功率、充电温度、荷电状态等多个影响因素的基础上,构建了多层混合效应回归模型,实现了不确定性因素影响下的充电时间。尽管考虑了多种影响因素,但由于样本数据较少,在预测中不能良好地表达模型的预测能力。此外,林鹏程^[7]将充电过程划分为3个阶段,提取相关性高的特征,并通过训练得到3个支持向量回归模型。然而,由于实际充电情况复杂,难以界定三段式的分界点。总体来看,大多数研究者虽然致力于改变算法来提高预测精度,但未能考虑到车辆实际充电的复杂情况和电池健康状态的影响。并且他们仅考虑了机器学习方法,而未深入探索深度学习在充电时间预测领域的可行性。

综上所述,目前充电时间预测存在健康因子考虑不全面,忽略了充电行为和电池健康的影响的问题。故本文提出一种基于Transformer模型实现充电时间预测方法,基于电池健康状态和充电行为,提取多个健康指标。针对电池退化是一个累积退化的过程,将提取到的特征转换为相应累积形式,通过皮尔逊

相关系数初筛特征,LASSO回归二次筛选特征选出最优特征集,避免了特征冗杂,最后采用实际车辆的数据集验证模型的有效性。具体流程如图1所示。

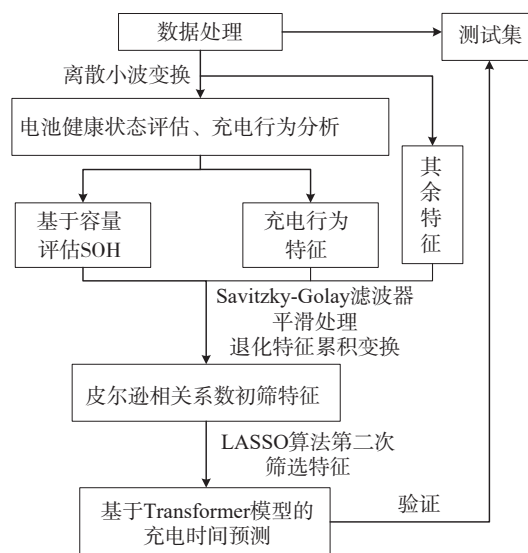


图1 Transformer模型预测充电时间流程图

1 数据收集与处理

1.1 数据收集信息

本研究的数据是从北京和上海各5辆营运类车辆中收集的,时间跨度为2018年到2020年,总共有1 500万个样本。为了满足充电时间计算的需求,仅采用处于充电状态的900万数据进行分析。原始数据包括:①车辆信息,车辆状态、累计里程、总电压、总电流;②电池信息,荷电状态、单体电池最高温度、单体电池最低温度。具体数据信息如表1所示。

表1 数据具体信息

数据字段名称	字段定义	有效值范围	含义与数值
车辆状态	车辆状态	01,02,03	启动,熄火,其它状态
累计里程	累计里程	0-9999999	0-99 999.9 km
总电压	总电压	0-10000	0-1 000 V
总电流	总电流	0-20000	-1 000-1 000 A, 偏移量1 000 A
SOC	电池SOC	0-100	0-100%
电池单体电压最高值	单体电压最高值	0-15000	0-15 V
电池单体电压最低值	单体电压最低值		
最高温度值	电池单体最高温度	0-250	-40-210 °C 偏移量40 °C
最低温度值	电池单体最低温度		

1.2 数据片段划分

为了后续计算充电时间,须对车辆充电数据进行片段划分,将数据切成不同片段,每一个片段代表车辆的一次独立充电片段。间隔小于240 s的片段和数据少于200条,由于其对于整体分析意义不大,且增加计算时间,则进行删除处理。

1.3 数据处理

1.3.1 缺失数据处理

经过分析在已给的原始数据中6、7、8号车的缺失数据达到原有数的39%、49%和53%。其中里程采用同片段内的里程值进行填充,而最高单体电压、最低单体电压和最高温度则采用随机森林填补缺失值。最后,采用五折交叉验证法验证填补后的数据误差,填补误差如表2所示。

表2 填补后的平均相对误差

数据字段名称	平均相对误差/%
电池单体电压最高值	0.520
电池单体电压最低值	0.521
最高温度值	0.518

1.3.2 异常数据处理

原始数据中存在部分异常数据须修正:①车辆处于停车充电状态即电流为负且速度显示为0,但是数据中车辆状态却为行驶状态,须修正车辆状态为停车充电状态;②熄火且不充电但电流不小于0,需要把电流改为0;③数据出现取值为0的数据大部分为异常数据,如图2中总电压、最高最低温度和SOC出现取值为0的情况,须对缺失值进行填补处理;④熄火状态但片段内有行驶里程差,表明该片段中丢失了部分行驶片段,需要把将两个不连续的片段分开。




图2 数值为0异常值

1.4 数据去噪

由于数据在传输、采集等过程可能存在异常,导致数据存在噪声,影响后续模型的精度。因此,选用离散小波变换对采集到的数据进行去噪,通过小波分解细节分量阈值处理和小波重构来剔除影响预测的噪声。

2 特征工程

2.1 特征构建

2.1.1 电池健康状态特征

在电池的使用过程中,随着时间的增长电池SOH(state of health)降低^[8],并且随着电池的SOH降

低,电池内部化学反应速率减慢,导致充电速率变慢,所以为了更好地了解电池充电状态,须构建出SOH特征。从容量方面考虑,其表达式如下:

$$SOH = \frac{C_k}{C_L} \times 100\% \quad (1)$$

式中: C_L 为电池标称容量; C_k 为目前测得的电池容量。

根据容量法的电池SOH评估结果如图3所示。从图中可看出随着电池的老化,电池SOH逐渐降低。

2.1.2 电池一致性特征

电池组是由多个电池单体组成,电池组内电池性能相似时,电池单体充电过程中的特性会比较相




图3 电池健康状态

近,并且也会以相似的速率充电。为了更加准确地预测充电时间,考虑了电池的电压一致性和温度一致性。

温度一致性的计算公式如下:

$$\begin{cases} T_{\Delta\min} = \min\{T_{\max}^i - T_{\min}^i\} \\ \eta_T = 1 - k_T \times f\left(\left(\frac{T_{\Delta} - T_{\Delta\min}}{T_{\Delta\min}}\right)^2\right) \end{cases} \quad (2)$$

电压一致性计算公式如下:

$$\begin{cases} U_{\Delta\min} = \min\{U_{\max}^i - U_{\min}^i\} \\ \eta_U = 1 - k_U \times f\left(\left(\frac{U_{\Delta} - U_{\Delta\min}}{U_{\Delta\min}}\right)^2\right) \end{cases} \quad (3)$$

式中: T_{\max} 、 T_{\min} 、 U_{\max} 、 U_{\min} 分别为该时刻电池单体温度最大值与最小值和电池单体电压最大值与最小值; $T_{\Delta\min}$ 、 $U_{\Delta\min}$ 分别为该车历史数据中单体温度极差和单体电压极差的最小值; k_T 、 k_U 为一致性得分修正系数; η_T 、 η_U 分别为最终的温度一致性和电压一致性得分; f 为归一化函数,其公式见式(4)。

$$f(x) = \frac{x - \min}{\max - \min} \quad (4)$$

2.1.3 充电行为特征

通过以下分析得到充电行为特征。

(1) 充电风格分析

电池充电 SOC 区间和充电电流直接反映了车辆的日常充电习惯,图4展示了电池充电周期内起始和终止 SOC 的情况。将充电 SOC 划分为 A 区、B 区、C 区和 D 区,其中 D 区是电池健康充电区, B 区为电池充电深度最大区域^[9]。图4中分布最密集的区域为 C 区,那么该区则表示该用户习惯充电区域,且该区域 SOC 大部分接近 100%。根据图4的起始 SOC 和结束 SOC,划分出4个区域,得出了4个充电风格,具体划分如表3所示。




图4 起始SOC和终止SOC分布

表3 充电风格划分

SOC 起始值/%	SOC 终止值/%	
	0-80	80-100
0-20	快速型	深度型
20-100	健康型	性能型

(2) 充电模式分析

根据研究,快充和慢充对纯电动汽车的充电时间有着显著的影响。通过图5充电速度散点图,可以清晰地展示每个充电片段的充电速度,进而识别车辆的充电模式。因此,根据提供的数据,能够确定每辆车的每个充电片段所采用的充电模式是快充还是慢充。




图5 充电速度

(3) 充电深度分析

充电深度 (depth of charge, DOC) 即电池在充电过程中从外路接受的电荷量与电池总容量的比值。 $DOC = \Delta SOC$,故可以对电池起始和终止 SOC 分

析得到实际运行电池的充电深度^[10]。图6为充电时间与DOC的散点图,从图中发现充电时间与充电深度之间存在明显的线性关系。

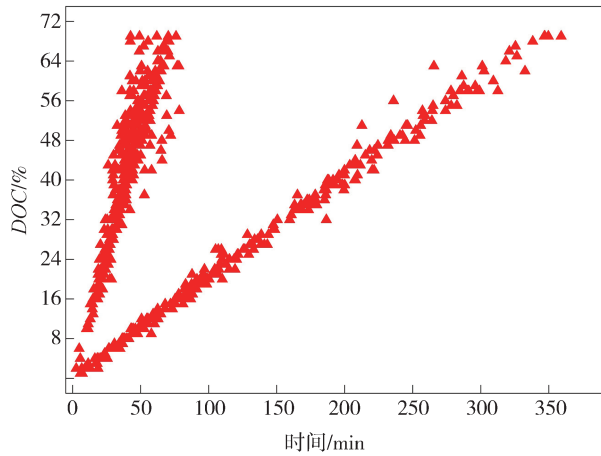


图6 充电深度与充电时间关系图

(4) 充电电流分析

图7为30个充电片段的电流变化曲线,由于充电时电流为负,所以从图中可以看出,一部分电流呈现阶梯递减的状态,一部分为恒流状态。从图中也可观察到阶梯式的充电时间比恒流充电方式所用的时间小。这种阶跃式充电可以看作多个恒流充电的结合。为了更好地捕捉阶跃式电流的波动性得到电流的变化特征,故选择2阶差分法提取电流特征。具体公式如式(5)所示。




图7 充电电流变换曲线

$$\begin{cases} \nabla Y_t = Y_t - Y_{t-1} \\ \nabla^2 Y_t = \nabla Y_t - \nabla Y_{t-1} \end{cases} \quad (5)$$

式中: Y 和 Y_{t-1} 分别为 t 时刻和 $t-1$ 时刻的电流值; ∇Y_t 和 ∇Y_{t-1} 分别为 t 时刻和 $t-1$ 时刻1阶差分。

(5) 充电电压分析

通过观察图8的充电电压变化,可以发现充电

过程分为快充和慢充两个阶段。整体来看,总电压持续上升,由多个线性增长曲线组成。在快充阶段,在充电初期 dU/dt 逐渐减小,在电量达到一定程度后, dU/dt 又出现上升。而在慢充阶段, dU/dt 先减小,随后上升,然后又出现减小,最终出现上升的趋势。




图8 充电电压变化曲线

2.1.4 其它特征

(1) 单体电压最低最高值

动力电池由多个模组组成,每个模组又由多个电池单体组成,动力电池的单体压差和其寿命与安全有较大关系,故把电池单体最高和最低电压值作为特征因子。

(2) 累计行驶里程

在不更换单体电池的情况下,汽车累计行驶里程在某种程度上可以表示电池组老化程度。累计行驶里程越多,充放电次数越多,电池老化越严重^[11]。

(3) 其它影响因素

充电电流、电压、单体电池最高温度、充放电循环次数等对充电时间均有显著的影响^[12]。

2.2 特征处理

电池作为消耗品,在日常使用过程中不可避免地会经历退化,直至最终故障,而能反映电池退化趋势的特征将有助于充电时间的准确预测。鉴于电池退化是一个累计退化过程,故对反映电池衰退的特征进行累积变换。由于累积变换会把存在的噪声逐步放大,所以在累积变换之前须进行平滑处理^[13],几种常见方法对比如图9所示,最后选择采用Savitzky-Golay滤波器,其可以在提高数据精度的同时具有不失真信号的优势。累积变换公式如下:




图9 平滑处理结果对比曲线

$$C_{in} = \frac{\sum_{a=1}^n f_i(a)}{\sqrt{\sum_{a=1}^n f_i(a)^2}}, i = 1, 2, \dots, M \text{ 和 } n = 1, 2, \dots, N \quad (6)$$

式中: N 为总样本数; M 为特征种类数; $f_i(a)$ 为第*i*种

特征的第*a*个特征值; C_{in} 为第*i*个特征在前*n*个样本中的累计变换结果。

2.3 特征筛选

为了增强模型的泛化能力、减少过拟合风险并加快训练速度,需要从所有特征中选择最佳特征子集。通过使用皮尔逊相关系数进行第1轮特征筛选,获得高相关性的特征集合,然而这些特征可能包含冗余信息或噪声,因此须进行第2轮筛选以进一步优化模型的预测性能。由于LASSO回归可以同时特征选择和参数估计,减少模型的复杂度,提高模型的泛化能力,因此选用LASSO回归算法第2次筛选特征。相关系数计算公式如下:

$$\rho_{x_1x_2} = \frac{Cov(X_1, X_2)}{\sqrt{DX_1} \times \sqrt{DX_2}} = \frac{EX_1X_2 - EX_1 \times EX_2}{\sqrt{DX_1} \times \sqrt{DX_2}} \quad (7)$$

式中: ρ 表示相关系数; Cov 表示协方差; DX_1 和 DX_2 分别表示两个变量的标准差; E 表示数学期望/均值。得到的皮尔逊相关系数热力图如图10所示。




图10 皮尔逊相关系数热力图

LASSO回归算法是在普通最小二乘法的基础上增加了一个L1范数惩罚项,从而使得一些回归系数可以被压缩为0,进而剔除了模型中的一些变量^[14]。LASSO回归进行特征筛选就是把不重要的特征系数变成0。筛选后特征重要度如图11所示。在特征筛选过程中,首先利用热力图相关系数排除了相关性较差的几个特征,有助于缩小特征范围并消除与目标变量关联性较弱的特征。接着根据LASSO算法的结果,删除了重要度最低的两个特征,最终得到了表4中的特征。




图 11 特征重要度

表 4 输入特征

特征类型	特征字符
电池健康状态	SOH
充电行为特征	充电深度
	充电风格
	充电模式
电池特征	电压一致性评分
	温度一致性评分
	最低温度
	电池单体电压最高值
	总电压
	SOC
历史特征	充放电循环次数
	累计里程

3 基于Transformer的充电时间预测模型

3.1 Transformer 预测模型

在基于数据驱动的纯电动汽车充电时间预测研究中,机器学习(如长短期神经网络,支持向量回归,XGBoost)得到广泛应用,但传统的机器学习方法通常在处理序列数据时面临着长距离依赖性和上下文感知的挑战,而Transformer模型能够很好地解决这些问题。因此选择基于Transformer的纯电动汽车充电时间预测模型,旨在提高充电时间预测模型的泛化性和预测精度。

通过自注意力机制、多头自注意力机制和位置编码的结合,Transformer能够全面捕捉输入序列的依赖关系、特征交互和位置信息,从而提高预测准确度,并对实际驾驶中的充电时间问题提供更可靠的预测结果。由于其结构限制了其不能直接应用于充电时间预测,故需要对其结构进行一些修改。从图12中可以看出模型主要分为两部分:编码器和解码器。其中编码器共有6层,每一层又可分为两个子

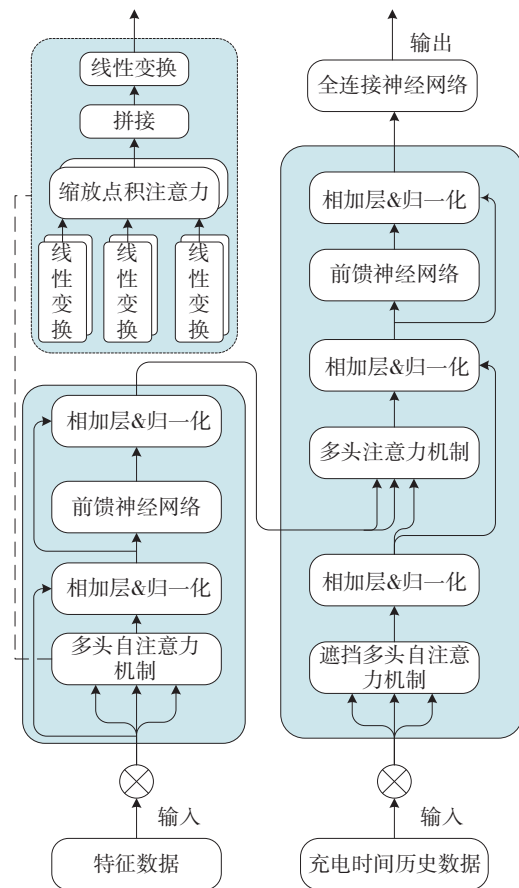


图 12 Transformer 预测结构图

层:(1)多头自注意力机制,由多个注意力机制组成;(2)前馈神经网络层。每个子层都有一个相加层和归一化层。解码器也有6层,每层包含3个子层:(1)遮挡多头自注意力机制层;(2)多头注意力机制层,作用为计算编码器-解码器的注意力;(3)前馈神经网络层。与编码器相同,解码器的每个子层也增加了相加层和归一化层。

在多头注意力机制中,输入用矩阵 X 表示,然后 X 线性变换得出查询矩阵、键矩阵和值矩阵,分别记为 Q 、 K 、 V ,公式如下^[15]:

$$\begin{cases} Q = X \cdot W_Q \\ K = X \cdot W_K \\ V = X \cdot W_V \end{cases} \quad (8)$$

其输出为 Y ,计算公式如下:

$$Y = Attention(Q, K, V) = \text{soft max} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (9)$$

式中: Q 、 K 和 V 是通过输入特征 X 乘以相应的加权矩阵 W_Q 、 W_K 和 W_V 获得的; d_k 为 Q 、 K 、 V 3个矩阵的维数。

多头自注意力机制的实质是在参数总量保持不变的情况下,将相同的查询矩阵、键矩阵和值矩阵映射到原始的高维空间的各个子空间中,然后在最后一步融合各个子空间的注意力。因此,在计算每一个头部时,减少了各个矢量的维数,从而避免了过拟合。

3.2 模型验证

为了验证 Transformer 模型的优越性,在 Python 3.11 环境下进行了实验。硬件环境为搭载 AMD Ryzen 7 4800H 处理器(2.90 GHz)和 Radeon 显卡的双处理器系统,以及 NVIDIA Quadro P3060 显卡。将3号车和7号车数据作为测试集数据,其余8辆车数据为训练集数据。选择从运行速度和模型预测精确度两个方面评价模型的效果。在预测精度方面选取了决定系数(R^2)和均方根误差($RMSE$)来对 Transformer 和其它几个充电时间预测常用模型进行对比分析。决定系数和均方根误差计算公式分别为

$$R^2 = 1 - \frac{\sum_i (\hat{y}_i - y_i)^2}{\sum_i (\bar{y}_i - y_i)^2} \quad (10)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (11)$$

式中: y_i 为真实值; \hat{y}_i 为预测值; m 为数据个数。


在对比实验中,使用了相同的测试数据集对4种不同模型进行模型效果评估,评估结果如表5所示。根据表5的结果可以看出,Transformer模型的决定系

数较其它3种模型更接近于1,而且其均方根误差和运行速度也是最小的。这表明了 Transformer 模型在预测精度和运行速度方面均优于其它模型。


表5 模型效果对比结果

模型	RMSE	R^2	运行时间/ms
Transformer	1.627	0.999	156
SVR	54.221	0.989	2 710
XGBoost	10.874	0.996	182
LSTM	50.104	0.990	255

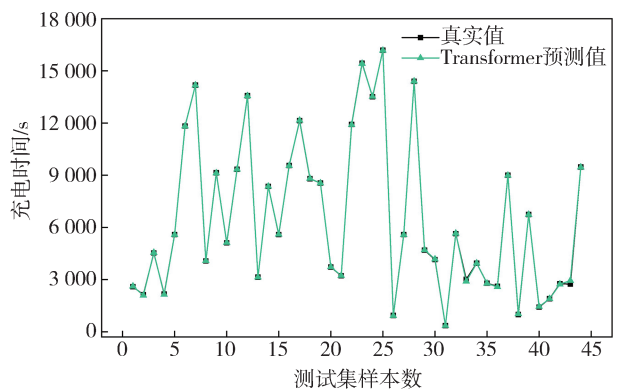
图13展示了Transformer模型和其他几个模型



(a) LSTM预测数据和真实数据的对比图



(b) XGBoost预测数据和真实数据的对比图



(c) Transformer预测数据和真实数据的对比图

图13 模型预测数据与真实数据对比图

预测数据和真实数据的对比。从图中可以看出,Transformer模型的预测值和真实值拟合效果更好,相较于其它模型预测结果没有出现明显的偏差。

4 结论

本研究在利用大量实车数据的基础上,提出了一种解决充电时间预测影响因素考虑不完整问题的方法,构建了关于电池健康状态、充电模式和行为等方面的特征。采用Savitzky-Golay滤波器对电池衰减特征进行了平滑处理,并进行累积变换,更好地描述了电池的退化趋势。耦合皮尔逊相关系数和LASSO回归算法二次筛选得到最优特征集,避免过拟合问题并提高了预测的准确性和泛化能力。数据验证结果表明,该方法的决定系数达到0.999,且运行时间仅为156 ms,说明Transformer能够准确且快速地预测纯电动汽车的充电时间。研究结果可以更好地理解和预测电动汽车的充电需求以及避免电池过充。相比传统方法,该方法具有更高的预测精度和更快的计算速度,提高了电动汽车的充电效率、用户体验和汽车安全性。

参考文献

- [1] 程树英,林鹏程,林培杰.一种新型锂电池充电剩余时间预测方法[J].电源技术,2019,43(1):99-102,135.
CHENG Shuying, LIN Pengcheng, LIN Peijie. A novel method for predicting the remaining charging time of lithium batteries [J]. Power Technology, 2019, 43 (1): 99-102, 135.
- [2] BI J, WANG Y, SUN S, et al. Predicting charging time of battery electric vehicles based on regression and time-series methods: a case study of beijing[J]. Energies, 2018, 11(5): 1040.
- [3] ULLAH I, LIU K, YAMAMOTO T, et al. Prediction of electric vehicle charging duration time using ensemble machine learning algorithm and shapley additive explanations [J]. Int J Energy Res, 2022, 46(11): 15211-15230.
- [4] ULLAH I, LIU K, YAMAMOTO T, et al. Grey wolf optimizer-based machine learning algorithm to predict electric vehicle charging duration time [J]. Transportation Letters, 2023, 15 (7/8): 889-906.
- [5] 杜京义,刘鑫,柳庆莉,等.基于IndyLSTM的锂电池充电剩余时间预测[J].计算机应用与软件,2021,38(5):112-116.
DU Jingyi, LIU Xin, LIU Qingli, et al. Prediction of remaining time of lithium battery charging based on IndyLSTM [J]. Computer Applications and Software, 2021, 38 (5): 112-116.
- [6] 黄忆,刘锴,王江波,等.考虑多层混合效应的电动公交充电持续时间影响因素研究[J].交通工程,2022,22(3):28-32,39.
HUANG Yi, LIU Kai, WANG Jiangbo, et al. A study on the influencing factors of electric bus charging duration considering multi-layer hybrid effects [J]. Transportation Engineering, 2022, 22 (3): 28-32, 39.
- [7] 林鹏程.预测锂电池充电时间的三段SVR模型[J].电源技术,2018,42(8):1155-1157,1232.
LIN Pengcheng. A three stage SVR model for predicting lithium battery charging time [J]. Power Technology, 2018, 42 (8): 1155-1157, 1232.
- [8] 魏克新,陈峭岩.基于多模型自适应卡尔曼滤波器的电动汽车电池荷电状态估计[J].中国电机工程学报,2012,32(31):19-26,3.
WEI Kexin, CHEN Qiuyan. State of charge estimation of electric vehicle batteries based on multi model adaptive Kalman filter [J]. Chinese Journal of Electrical Engineering, 2012, 32 (31): 19-26, 3.
- [9] 张凡,邢子轩,武明虎,等.数据驱动的车载动力电池使用行为分析[J].汽车技术,2023(3):49-55.
ZHANG Fan, XING Zixuan, WU Minghu, et al. Data driven analysis of the usage behavior of in vehicle power batteries [J]. Automotive Technology, 2023 (3): 49-55.
- [10] 李萌.基于容量增量法与机器学习算法的实车动力电池SOH估计[D].西安:长安大学,2023.
LI Meng. Real vehicle power battery SOH estimation based on capacity increment method and machine learning algorithm [D]. Xi'an: Chang'an University, 2023.
- [11] 高航.基于机器学习的纯电动汽车的行驶里程预测研究[D].北京:北京交通大学,2018.
GAO Hang. Research on range prediction of pure electric vehicles based on machine learning [D]. Beijing: Beijing Jiaotong University, 2018.
- [12] 黄忆.数据驱动的电动公交充电持续时间预测及影响因素研究[D].大连:大连理工大学,2023.
HUANG Yi. Research on data-driven prediction and influencing factors of charging duration for electric buses [D]. Dalian: Dalian University of Technology, 2023.
- [13] 曹建军.基于深度学习的滚动轴承剩余寿命预测方法研究[D].兰州:兰州理工大学,2023.
CAO Jianjun. Research on residual life prediction method of rolling bearings based on deep learning [D]. Lanzhou: Lanzhou University of Technology, 2023.
- [14] 王璐,孙聚波. Lasso回归方法在特征变量选择中的应用[J].吉林工程技术师范学院学报,2021,37(12):109-112.
WANG Lu, SUN Jubo. The application of lasso regression method in feature variable selection [J]. Journal of Jilin University of Engineering and Technology, 2021, 37 (12): 109-112.
- [15] 辛洲扬.基于LSTM与Transformer模型的股价预测[D].济南:山东大学,2023.
XIN Zhouyang. Stock price prediction based on LSTM and Transformer models [D]. Jinan: Shandong University, 2023.