

基于 FCM 和 BiLSTM 的电动汽车充电负荷预测

林翔^{1*}, 徐睿麟²

(1. 南京三新供电服务有限公司浦口分公司, 江苏 南京 211899;

2. 东南大学苏州研究院, 江苏 苏州 215123)

摘要: 为了解决江北城乡电动汽车充电缺口问题, 提高充电服务的智能化水平并增进用户体验, 文章提出一种基于 FCM 和 BiLSTM 的电动汽车充电负荷预测方法。为了识别出充电负荷内部结构和模式, 首先将日充电负荷数据集进行 FCM 聚类, 将数据划分为不同集群, 每个集群代表具有相似充电负荷特征的样本。然后针对每个集群的不同样本特征, 构建相应的 BiLSTM 模型进行训练并预测, 通过调整模型参数, 提高模型预测准确性。通过对比实验, 验证了该方法的有效性和实用性。

关键词: 电动汽车; 模糊 C 均值聚类; 双向长短期记忆; 负荷预测

中图分类号: TM714

Load Forecasting Method for Electric Vehicle Charging Based on FCM Clustering and BiLSTM Network

LIN Xiang^{1*}, XU Ruilin²

(1. Nanjing Sanxin Power Supply Service Co., Ltd. Pukou Branch, Jiangsu Nanjing 211899, China; 2. Suzhou Research Institute of Southeast University, Jiangsu Suzhou 215123, China)

Abstract: To address the charging gap issue for electric vehicles in both urban and rural areas of Pukou, and to enhance the intelligence of charging services for an improved user experience, this paper proposes a method for predicting electric vehicle charging loads based on FCM clustering and BiLSTM. Firstly, to identify the internal structure and patterns of charging loads, FCM clustering is applied to the daily charging load dataset, dividing the data into different clusters, with each cluster representing samples with similar charging load characteristics. Subsequently, tailored BiLSTM models are constructed for training and prediction based on the distinct sample features within each cluster. Model parameters are adjusted to enhance prediction accuracy. Through comparative experiments, validating the effectiveness and practicality of the approach.

Keywords: electric vehicle; FCM; BiLSTM; load prediction

0 引言

当前新能源汽车产销两旺, 电动汽车走进百姓生活, 截至 2023 年 12 月底, 南京市新能源汽车保有量约为 22.08 万辆, 仅 2023 年上半年就新增了 4.99 万辆, 同期机动车上牌总量为 18.05 万辆, 其中新能源车占比达到 27.65%。然而, 随着电动汽车的普及, 充电缺口问题随之而来。2019 年以来, 电动汽车充电难题成为南京市江北区 12345 热线快速增长的新型诉求。为实现完善的充电基础设施规划, 优化电网供电, 减少能源浪费和运营成本, 精确的电动汽车充电负荷预测变得尤为重要。

目前, 传统的电动汽车负荷预测的方法主要包括统计模型、机器学习、优化和混合方法。针对现

收稿日期: 2024-01-04, 修回日期: 2024-03-05

有的以用户侧为出发点的预测方法存在较多的不确定性且实用性不强, 文献 [1] 提出了将粒子群优化 (PSO) 算法与最小二乘支持向量机 (LSSVM) [2] 应用于充电负荷预测。在考虑电池容量及其老化速率后, 文献 [3] 提出一种考虑电池老化的电动汽车中长期充电负荷预测方法。通过构建考虑电池老化和温度变化的模型来预测电动汽车电池总容量衰减、更换新电池和车辆增长对总容量的影响, 并构建考虑充电成本的车辆行为仿真模型来模拟电动汽车的出行和充电过程。在超短期充电负荷预测方面, 文献 [4] 提出了一种改进的门控循环单元的短期负荷预测方法, 运用卷积神经网络和门控循环单元相结合 [5] 提取有时序特性的重要特征, 通过注意力机制为隐藏层分配权重来区分其重要度。文献 [6] 提出一种基于聚类分析的电动汽车充电预测方法, 通过提出

基于一致性理论的 K 均值聚类方法^[7]，利用当前时段与相邻时段充电负荷数据的不相似性度量来更新聚类状态，准确计算聚类中心，从而快速求取电动汽车充电概率与充电起始时间概率分布函数。通过识别电动汽车充电行为特性参数，求解非线性规划函数，能准确预测充电高峰时期聚集负荷模型。

上述方法虽然取得了不错的预测效果，但仍存在一些局限性。这些方法往往依赖于目标地区可靠的数据集，特别是对于南京江北城乡地区而言，缺乏充分和准确的数据可能会影响预测的准确性和可靠性。同时，对于江北城乡而言，电动汽车充电负荷存在一定的不确定性，例如用户行为的不确定性，没有考虑季节变化等情况。因此在江北不同地区、不同充电设施和用户行为差异较大的情况下，这些方法的预测效果可能有所下降，因此需要有效的充电时序特征提取方法。

本文提出了一种基于 FCM 聚类 (fuzzy c-means clustering, FCM) 和 BiLSTM (bidirectional long short-term memory, BiLSTM) 的电动汽车充电负荷预测方法。为了识别出充电负荷内部结构和模式，首先将日充电负荷数据集进行 FCM 聚类^[8]，将数据划分为不同集群，每个集群代表具有相似充电负荷特征的样本。然后针对每个集群的不同样本特征，构建相应的 BiLSTM 模型^[9]进行训练并预测，并通过调整模型参数，提高模型预测准确性。其中模型输入是聚类后的充电负荷数据的时间序列，输出是预测的充电负荷需求。以南京江北某电动汽车充电站数据进行验证，证明本文所提方法有效。

1 充电负荷特征聚类

1.1 聚类特征选取

对充电负荷时序而言，均值 $\bar{x}$ 能够表征数据的整体平均水平，标准差 σ 能够表征样本与平均水平的偏离程度，峰度 k 用来描述数据的尾重程度，偏度 s 用来描述样本与中心值的偏离形态，以上 4 项统计指标常用来刻画样本的数据特征。因此，本文选择以上 4 项统计指标作为充电负荷的聚类特征^[10]，构建后续聚类的特征矩阵。

1.2 FCM 聚类

FCM 聚类在电动汽车充电负荷特征提取中应用广泛。在本文所提出的电动汽车充电负荷特征聚类中，采用 1.1 中所选取的均值 $\bar{x}$ 、标准差 σ 、峰度

k 和偏度 s 作为日电动汽车充电负荷特征数据，构建充电负荷数据的聚类特征矩阵，以此对历史日充电样本进行 FCM 聚类操作。FCM 聚类可以将日充电负荷特征集划分为不同的聚类簇，每个聚类簇代表一种典型日充电负荷模式或特征。通过对聚类结果的分析，可以更好地理解充电负荷数据的特征和模式，识别出不同的日充电行为、充电需求分布等。其中，每个日充电负荷特征向量 x 为：

$$x = [\bar{x}, \sigma, k, s] \quad (1)$$

FCM 聚类算法中，将 n 个向量 $x_i (i = 1, 2, \dots, n)$ 分为 c 个模糊组，并确定每组的聚类中心，损失函数描述了各向量到聚类中心的欧氏距离，通过不断迭代隶属度矩阵 U 和聚类中心 $V = [v_1, v_2, \dots, v_c]$ ，使得损失函数取最小值。损失函数的具体定义如下：

$$J(U, V) = \sum_{i=1}^n \sum_{j=1}^c u_{ij}^m d_{ij}^2 \quad (2)$$

式中： u_{ij} 为第 i 个样本属于第 j 类的隶属度； m 为隶属度因子 ($1 \leq m \leq \infty$)； d_{ij} 为样本到聚类中心的欧氏距离， $d_{ij} = \|x_i - v_j\|$ 。

在聚类效果的评价阶段，本文采用轮廓系数 (silhouette coefficient, SC) 和戴维斯-鲍丁指数 (Davies-Bouldin index, DBI) 作为评价指标。SC 指数范围是 $[-1, 1]$ ，越靠近上下限分类效果越好，而对于 DBI 指标，其值越小表示聚类效果越好。本文对每个聚类数 C 的聚类结果计算其 DBI 和 SC 指数，通过综合考虑这 2 个指数选出最优聚类数。

基于 FCM 聚类的电动汽车充电负荷特征提取方法可以帮助了解充电负荷的变化规律，为充电基础设施的规划和运营管理提供依据。通过提取充电负荷的特征和模式，可以进行负荷预测、充电需求调度等优化措施，提高充电效率和能源利用率。

2 BiLSTM

BiLSTM 是一种循环神经网络 (RNN) 的变体，它在传统的 LSTM 基础上增加了反向传播的路径，可以同时捕捉过去和未来的信息。在电动汽车充电负荷预测中，BiLSTM 可以有效地利用序列数据中前后时刻的信息，更好地捕捉充电负荷的时间序列特征和内部模式。

2.1 LSTM

LSTM 主要用于处理输入数据中的时间序列依

赖关系,对于充电负荷数据而言,它可以通过内部的门控机制,有效地建模和捕捉时间序列数据中的长期依赖关系^[11]。其记忆单元结构如图1所示。




图1 记忆单元结构图

在电动汽车充电负荷预测任务中,每个时刻,遗忘门接收当前负荷状态 x_t 和上一时刻隐藏层状态 h_{t-1} ,经由激活函数Sigmoid使遗忘门输出值均在 $[0, 1]$ 之间。输入门的输入经由非线性函数变换后,与遗忘门的输出叠加得到更新后的记忆单元状态 c_t ,最后输出门根据非线性函数运算后的 c_t 动态控制得到LSTM的输出隐藏状态 h_t 。

2.2 BiLSTM

首先通过FCM聚类将充电负荷数据划分为不同的集群,每个集群代表具有相似充电负荷特征的样本。

在LSTM的基础上,构建BiLSTM模型进行训练和预测,其模型如图2所示。其中, h_{L0} 、 h_{L1} 、 h_{L2} 为前向LSTM隐藏状态,而 h_{R0} 、 h_{R1} 、 h_{R2} 为后向LSTM隐藏状态。BiLSTM的输出层将对应时间点的前向和后向隐藏状态进行拼接来融合2个方向的信息。




图2 双向LSTM结构图

在得到FCM聚类出的不同特征簇后,将同簇内相似的充电日负荷数据重新拼接整合为该簇的实验数据集,并将其应用于该特征簇对应的BiLSTM模型的训练和预测之中。并在后续模型测试中采用该簇数据集的80%作为训练集训练模型,20%作为测试集来计算其评价指标。通过对前80%的相似日负荷数据进行模型训练,得到后20%相似日的预测数据,并与后20%相似日的真实数据进行比较,计算其评价指标。

同时在BiLSTM模型的训练中,通过调整单向LSTM层的数量、输入的样本批量大小、神经元节点数、学习率、迭代次数来优化模型性能。并根据20%测试集测试结果和评价指标,对模型的参数进行调整,以进一步提高预测准确性。

3 电动汽车充电负荷分析

首先,对出力时序进行FCM聚类,将聚类目标数 C 进行遍历,根据相应的SC指数、DBI指数选出最佳的 C 值。随后将数据划分为不同集群,得出每个类别的聚类中心线,每个集群代表具有相似充电负荷特征的样本。然后,针对每个集群,构建相应的BiLSTM模型。BiLSTM中的正向传播路径负责利用过去的历史数据,学习和捕捉充电负荷的时间相关性和周期性等特征。反向传播路径则利用未来的数据,帮助模型更好地预测未来的充电负荷情况。通过结合FCM聚类和BiLSTM模型,能够更好地区分不同的日充电负荷特征模式,并为每个特征模式训练专门的模型。基于FCM聚类和BiLSTM的电动汽车充电负荷预测模型的结构如图3所示。

4 电动汽车充电负荷预测

实验的预测部分为电动汽车充电负荷预测,预测结果均采用平均绝对误差(MAE)和均方根误差(RMSE)作为评价指标^[12]。其计算公式分别为:

$$e_{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3)$$

$$e_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (4)$$

式中: e_{MAE} 为平均绝对误差; e_{RMSE} 为均方根误差; N 为预测样本数; y_i 为负荷的真实值; $\hat{y}_i$ 为负荷的




图3 电动汽车充电负荷预测流程图

预测值。

4.1 充电负荷特征聚类

为了验证本文所提的基于 FCM 和 BiLSTM 的电动汽车充电负荷预测方法的有效性，采用南京市江北某电动汽车充电站充电负荷历史数据。其中，历史负荷数据为 2022 年 7 月 14 日 00:00—12 月 14 日 00:00，采样频率为 15 min/点，数据单位为 kW。

在进行负荷预测之前，先进行充电负荷特征提取。首先将历史负荷数据进行清洗，并将历史数据进行归一化操作，然后提取文中所述的 4 项统计指标作为充电负荷特征的聚类特征。

在进行 FCM 聚类时，取模糊指数 (m) = 2, C_0 从 2 开始, $C_{\max}$ 取 9。SC 指数和 DBI 指数如图 4 所示。由图 4 可以看出，当 $C=2$ 时，SC 指数和 DBI 指数最优。因此，聚类数 C 选定为 2，日负荷聚类中心线如图 5 所示。在聚类分析中，聚类中心线通常指的是在对一组数据进行聚类后，每个聚类簇中所有数据点的中心点或者平均点。这个中心点代表了该聚类簇内所有数据点的典型特征，可以作为该簇的典型代表。

由图 5 可以看出，日负荷聚类中心线分别代表了不同种类的典型电车充电负荷曲线，差异明显。这种差异主要是由于季节原因引起的。例如簇 1 负荷曲线，夏季由于天气炎热，电车的制冷设备会大量运行，导致单位时间内的用电量增加，充电频率增加，充电站的负荷也相应增大。因此，负荷曲线从中午到下午及晚上下班时间段内的波动性较大。而在秋冬季节，充电负荷的波动较为平缓，总体用电量也较夏季有所减少，如簇 2 所示。因此充电负



图4 SC 和 DBI 指数随 C 的变化趋势

图5 日充电负荷聚类中心线

荷特征聚类将历史充电负荷主要分为 2 类，并在此基础上按簇进行预测。

4.2 电动汽车充电负荷预测

实验时将聚类好的数据按类进行整理，按簇对模型进行训练，得到每簇相应的预测模型。采用该簇实验数据集的 80% 作为训练集，20% 作为测试集。在对比实验中，引入 BiLSTM 预测模型，FCM-LSTM 预测模型和本文所提出的 FCM-BiLSTM 预测模型进行消融实验与对比试验，进而研究聚类与未聚类、BiLSTM 与其他神经网络预测时的差异。其结果见图 6、图 7。

从图 6 和图 7 的结果来看，本文所提出的电动




图6 聚类标签1测试和预测值




图7 聚类标签2测试和预测值

汽车充电负荷预测模型与真实的出力结果相似度较高, 预测效果最好的是本文所提出的模型, 其次是 FCM-LSTM 预测模型, 而 BiLSTM 模型的预测效果最差。可以看出, FCM 聚类可识别出影响数据集的关键特征, 提高神经网络对相似日特征规律的学习能力, 从而提高预测的精度。同时 BiLSTM 对比 LSTM 有着较为不错的性能, 每簇各自的归一化平均绝对误差、均方根误差如表 1 所示。

表1 评价指标 %

算法	聚类标签1		聚类标签2	
	e_{RMSE}	e_{MAE}	e_{RMSE}	e_{MAE}
FCM-BiLSTM	0.453 4	0.379 2	0.169 7	0.120 1
FCM-LSTM	1.003 4	0.839 1	0.382 1	0.270 4
BiLSTM	3.245 6	2.714 2	1.329 9	0.940 9

对于聚类标签 1, FCM-BiLSTM 模型具有最低的 RMSE 和 MAE, 分别为 0.453 4% 和 0.379 2%, 其预测效果最好。其次是 FCM-LSTM 模型, RMSE 为 1.003 4%, MAE 为 0.839 1%。BiLSTM 模型具有最高的 RMSE 和 MAE, 分别为 3.245 6% 和

2.714 2%, 预测效果不佳。对于聚类标签 2, FCM-BiLSTM 模型同样具有最低的 RMSE 和 MAE, 分别为 0.169 7% 和 0.120 1%。其次是 FCM-LSTM 模型, 而 BiLSTM 模型具有最高的 RMSE 和 MAE。

5 结束语

综上所述, 根据给定的评估指标数据, 可以得出本文提出的 FCM-BiLSTM 模型负荷预测方法评价指标、预测效果最优, 可更准确地预测电动汽车充电负荷, 为电动汽车充电站运营管理提供数据支撑。

参考文献

- [1] 潘越, 普美娜, 范嘉豪. 基于 PSO-LSSVM 的新能源汽车充电负荷预测方法研究[J]. 电力与能源, 2023, 44 (4): 379-384.
- [2] 杨延西, 刘丁. 基于小波变换和最小二乘支持向量机的短期电力负荷预测[J]. 电网技术, 2005 (13): 60-64.
- [3] 董晓红, 孔华志, 丁飞, 等. 考虑电池老化的电动汽车中长期充电负荷预测方法[J/OL]. 电力系统自动化, 1-15 [2023-12-28]. <http://kns.cnki.net/kcms/detail/32.1180.TP.20231009.0751.004.html>.
- [4] 石立国, 李延真, 刘继彦, 等. 电动汽车充电站超短期充电负荷预测的改进 GRU 方法[J]. 供用电, 2023, 40 (6): 42-47.
- [5] MOHAMMED N S, MOHAMMED H E. Accurate photovoltaic power prediction models based on deep convolutional neural networks and gated recurrent units[J]. Energy Sources, Part A: Recovery, Utilization, and Environmental Effects, 2022, 44(3):6303-6320.
- [6] 陈忠华, 朱军, 王育飞, 等. 基于一致性 K 均值聚类的电动汽车充电负荷建模方法[J]. 现代电力, 2022, 39 (3): 338-348.
- [7] 周成龙, 陈玉明, 朱益冬. 粒 K 均值聚类算法[J]. 计算机工程与应用, 2023, 59 (13): 317-324.
- [8] 张慧哲, 王坚. 基于初始聚类中心选取的改进 FCM 聚类算法[J]. 计算机科学, 2009, 36 (6): 206-209.
- [9] 关鹏飞, 李宝安, 吕学强, 等. 注意力增强的双向 LSTM 情感分析[J]. 中文信息学报, 2019, 33 (2): 105-111.
- [10] 宋军英, 何聪, 李欣然, 等. 基于特征指标降维及熵权法的日负荷曲线聚类方法[J]. 电力系统自动化, 2019, 43 (20): 65-72.
- [11] 程冬梅. LSTM 研究现状综述[J]. 信息系统工程, 2022 (1): 149-152.
- [12] CHAI, Tianfeng, and ROLAND R. Draxler. Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. Geoscientific model development, 2014(7): 1247-1250.

作者简介

林翔 (1998—), 男, 本科, 助理工程师, 从事智能电网信息技术、需求侧管理工作, E-mail: 952496197@qq.com.

(责任编辑: 袁航)