

转载自《电力系统保护与控制》2025年53卷6期

引用格式: 李振华, 张成浩, 刘奕舟, 等. 基于多特征提取和多层级迁移学习的电动汽车充电站充电量预测[J]. 电力系统保护与控制, 2025, 53(6): 150-162.

LI Zhenhua, ZHANG Chenghao, LIU Yizhou, et al. Electric vehicle charging station charging forecasting based on multi-feature extraction and multi-level transfer learning[J]. Power System Protection and Control, 2025, 53(6): 150-162.

## 基于多特征提取和多层级迁移学习的电动汽车 充电站充电量预测

李振华<sup>1</sup>, 张成浩<sup>1</sup>, 刘奕舟<sup>1</sup>, 魏伟<sup>2</sup>

(1. 三峡大学电气与新能源学院, 湖北 宜昌 443002; 2. 国网湖北省电力有限公司  
营销服务中心(计量中心), 湖北 武汉 443080)

**摘要:** 电动汽车充电站充电量预测对于充电站规划、建设、充电管理平台营销等有着实际意义。但新建、改造的充电站可能会面临部分时段数据缺失、历史数据不足和浅层神经网络模型难以捕捉等多变且复杂的输入特征的问题。因此, 提出了一种基于多特征提取和多层级迁移学习的电动汽车充电站充电量预测方法。首先, 使用 K-Means 算法对所有用户在不同时间段的充电次数进行聚类, 得到 4 类充电行为特征, 将其和其他影响特征融合作为模型的输入特征集。其次, 设计并行连接的多尺度混合时间卷积网络(temporal convolutional network, TCN)层作为特征提取器, 两层 BiLSTM 层将提取到的特征进行深度学习, Attention 层加强个体特征选择。最后, 将源充电站数据进行相关性等级划分, 按照相关性由弱到强输入到模型中进行多层级迁移学习, 保留损失函数最低的训练权重, 得到最终的预测结果。算例分析表明, 多层级迁移学习可以弥补新建、改造的充电站数据样本不足的缺陷。与直接迁移相比, 多层级迁移平均绝对误差(mean absolute error, MAE)降低了 10.75%, 均方根误差(root mean square error, RMSE)降低了 13.73%, 拟合优度  $R^2$  提升了 0.4%。

**关键词:** 充电量预测; 迁移学习; 特征提取; 时间卷积网络; 双向长短期记忆网络; 注意力机制

### Electric vehicle charging station charging forecasting based on multi-feature extraction and multi-level transfer learning

LI Zhenhua<sup>1</sup>, ZHANG Chenghao<sup>1</sup>, LIU Yizhou<sup>1</sup>, WEI Wei<sup>2</sup>

(1. College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, China;  
2. State Grid Hubei Electric Power Co., Ltd. Marketing Service Center (Measurement Center), Wuhan 443080, China)

**Abstract:** Electric vehicle charging station charging forecasting is crucial for charging station planning, construction, and marketing strategies in charging management platforms. However, newly built or upgraded charging stations may face problems of missing data for some time periods, insufficient historical data, and difficulties in capturing complex input features with shallow neural network models. Therefore, a charging forecasting method for electric vehicle charging stations based on multi-feature extraction and multi-level transfer learning is proposed. First, the K-Means algorithm is used to cluster users' charging frequency over different time periods to obtain four types of charging behavioral features. These are integrated with other influencing features to form the model's input feature set. Next, a parallel-connected multiscale hybrid temporal convolutional network (TCN) layer is designed as the feature extractor, followed by two BiLSTM layers for deeper feature learning. An Attention layer is added to strengthen individual feature selection. Finally, charging station data from source locations are classified into correlation levels, and data are fed into the model in a weak-to-strong correlation order through multi-level transfer learning. The training weights with the lowest loss function value are retained to obtain the final prediction results. Case study results show that multi-level transfer learning can compensate for the lack of data samples in new or upgraded charging stations. Compared to direct transfer learning, the proposed method reduces the mean absolute error (MAE) by 10.75%, decreases the root mean square error (RMSE) by 13.73%, and improves the  $R^2$  by 0.4%.

This work is supported by the National Natural Science Foundation of China (No. 52277012).

**Key words:** charging forecasting; transfer learning; feature extraction; TCN; BiLSTM; attention mechanism

基金项目: 国家自然科学基金项目资助(52277012); 武汉强磁场学科交叉基金项目资助(WHMFC202202)

## 0 引言

作为一种节能、低碳的交通工具,电动汽车已经成为实现可持续发展并满足未来能源需求的重要工具<sup>[1-4]</sup>,不过中国的电动汽车产业仍不够成熟,其中充电站中充电桩利用率低、布局不合理、充电设施建设进度慢、充电费用差异等问题,成为制约电动汽车发展的主要障碍<sup>[5-8]</sup>。充电站的合理部署与高效运营直接影响电动汽车产业的健康发展及用户体验<sup>[9-11]</sup>。尽管新建、改造电动汽车充电站的数量每年都在迅速增加,但由于运营时间短,缺乏足够的历史数据,很难精准预测充电量。新建、改造充电站的充电量预测难以满足优化调度期望,因此拥有较大的提升空间。此外,准确的预测模型能够帮助运营商合理安排充电资源、降低运维成本、提升服务质量,对于充电站的运行规划具有指导意义<sup>[12-13]</sup>。

影响新建和改造的电动汽车充电站充电量预测精度的关键因素包括:1) 由于新建和改造站点可能导致部分时段数据缺失或历史数据不足,需要开发适合数据稀缺情况下的预测方法。2) 浅层神经网络模型在处理多变且复杂的输入数据时具有局限性,需要一种更为精确和高效的深度预测模型。

迁移学习涉及将一个或多个领域的知识迁移到目标领域,使用相关知识来处理不同但相关领域中的问题。文献[14]针对投入运行时间较短的光伏电站,提出一种样本数据不足的光伏发电量数据模型,加入迁移策略后的模型大幅减少了训练时间并提高了预测精度。文献[15]提出一种结合降噪自编码器的神经网络模型,该模型可以使降噪数据和预测模型共享同一损失函数,因此目标任务数据的降噪和预测可以同时优化。文献[16]提出一种逐层无监督训练的迁移模型,针对目标域缺少样本标签的情况,建立了与源域参数共享的预测模型,一定程度上解决了永磁同步电机小样本缺少标签的问题。文献[17]利用 Wasserstein 距离(Wasserstein distance, WD)来选择与目标域相似分布的源域样本,作为提高迁移学习模型性能的辅助算法,用于故障诊断领域。文献[18-19]为了减小源域和目标域之间的分布差异,分别提出一种自适应域迁移学习和域对抗迁移学习策略。域对抗迁移学习通过生成对抗网络来学习如何生成具有与目标域相似分布的数据,而自适应域迁移学习则通过特征对齐或样本重加权等方法来减小领域之间的差异。尽管当前的迁移学习方法已经针对领域层次的不平衡问题进行了一定的探讨,但在源域与目标域样本间的不平衡问题上仍有所忽视,这可能导致信息迁移的效果不理想。同时,

以实例为导向的迁移学习策略未能有效实行对源数据的层级划分与评估,难以满足复杂工程应用的具体需求。

本文提出的基于多特征提取和多层级迁移学习的电动汽车充电站充电量预测方法,包括3个步骤:1) 根据充电站的充电订单信息,通过聚类算法提取出电动汽车用户的充电行为特征,与采集的充电站数据、天气数据一起作为模型输入;2) 根据源充电站与目标充电站样本的交叉熵误差值,对源充电站的样本进行多层级划分;3) 基于多层级的源充电站样本,将其从低到高依次放入多尺度混合时间卷积网络(temporal convolutional network, TCN) BiLSTM-Attention 预测模型中,建立对目标充电站的迁移学习模型。

## 1 基于 K-Means 聚类的用户充电行为特征提取

充电站的充电订单数据包括充电站地点、充电开始时间、充电结束时间、交易电量、交易金额等信息。为了避免无效充电行为对分析结果造成不良影响,需要排除充电时间较短或存在明显参数错误的无效充电数据。

在用户聚类领域中, K-Means 算法因其简单、收敛速度快、可扩展且高效的特点而得到了广泛应用<sup>[20]</sup>。该算法是基于簇聚类的无监督算法,针对给定的多维数据集,按照样本数据值之间的欧氏距离大小,将其划分为  $K$  个簇。其计算步骤如下。

1) 随机选择  $K$  个聚类中心点,计算每个样本与这些中心点的欧氏距离,然后将样本分配到最近的聚类中心所属的类别中,形成初始分类。假定划分的簇类集为  $C_i \{i = 3, 4, \dots, K\}$ , 则簇内欧氏距离  $D$  的计算公式为

$$D = \sum_{i=1}^K \sum_{x \in C_i} \|s - u_i\|^2 \quad (1)$$

式中,  $\|s - u_i\|^2$  表示点  $s$  到其簇中心  $u_i$  的欧氏距离。

2) 选择评价聚类结果的准则函数。本文选取轮廓系数(silhouette coefficient, SC)和聚类时间来确定最佳的聚类结果。

轮廓系数综合考虑了聚类凝聚度和聚类之间的分离度,来判断聚类效果的好坏。轮廓系数  $S_i(t)$  计算公式为

$$S_i(t) = \frac{b(t) - a(t)}{\max\{a(t), b(t)\}} \quad (2)$$

式中:  $S_i(t)$  取值范围为  $[-1, 1]$ ,  $S_i(t)$  越接近于 1, 表示聚类效果越好;  $a(t)$  为类别  $C_i$  下剩余样本点与

样本点  $t$  的距离均值, 表示同一类别下的凝聚度; 定义  $d(t, C_j)$  为样本点  $t$  到其他类别  $C_j$  下所有样本点的平均距离,  $b(t)$  为所有  $d(t, C_j)$  的最小值, 表示不同类别之间的分离度。

聚类时间是记录算法在同一环境下运行的时间(单位为 s), 反映聚类过程计算速度的快慢。

3) 通过不断迭代找到最佳的簇类, 使准则函数的 SC 尽可能接近 1, 得到最优的聚类结果。

选取电网公司提供的某省 8 个地区的国家电网充电站 2022 年 1 月 1 日至 2022 年 8 月 31 日的充电订单数据作为数据集, 来对用户充电行为进行聚类分析。为充分提取用户充电行为特征, 提取了用户 8 个月期间每次充电的开始时间、结束时间和平均充电时间, 并基于这些特征进行聚类分析, 计算各类用户每小时充电次数的平均值, 得到聚类结果。通过聚类分析, 可以获得每类用户的充电量曲线分布。

为验证提取的数据对用户行为充电的影响大小, 本文讨论了在不同输入样本下的聚类评价指标, 如表 1 所示。

表 1 不同输入样本下的评价指标

Table 1 Evaluation indicators with different input samples

| 输入数据         | SC    | 聚类时间/s |
|--------------|-------|--------|
| 开始时间         | 0.365 | 5.42   |
| 结束时间         | 0.356 | 5.52   |
| 开始时间+结束时间    | 0.370 | 9.37   |
| 开始时间+结束时间+时长 | 0.372 | 10.24  |

由表 1 可知, 将充电开始时间作为输入样本进行聚类分析的评价指标比输入充电结束时间的效果要好。而将充电开始时间、充电结束时间、充电时长均输入模型中进行聚类分析的评价指标上升效果不明显。相较于只输入充电开始时间, SC 上升了 1.92%, 其聚类时间增长了将近一倍, 但是聚类效果的提升极其有限。因此本文仅提取每次充电的开始时间, 计算每位用户各时间段的充电次数, 形成 24 维的特征向量进行聚类分析。

将选取样本输入 K-Means 模型中进行聚类分析, 计算不同簇类下的轮廓系数, 找到聚类效果最好的簇类。其不同聚类数下的轮廓系数如表 2 所示。

表 2 轮廓系数聚类结果

Table 2 Silhouette coefficient clustering result

| 聚类数  | 3     | 4     | 5     | 6     | 7     | 8     |
|------|-------|-------|-------|-------|-------|-------|
| 轮廓系数 | 0.423 | 0.450 | 0.416 | 0.385 | 0.315 | 0.203 |

从表 2 可知, 当簇类数目为 3—6 时, 轮廓系数变化较为稳定, 其中簇类为 4 时 SC 值最大, 而当

聚类数为 7 以后, 轮廓系数明显下降。因此, 簇类最终选择为 4。聚类划分的 4 个簇类中, 1 类用户有 10 312 位, 2 类用户有 2504 位, 3 类用户有 2072 位, 4 类用户有 594 位, 各类用户的充电行为分布如图 1 所示。




图 1 用户充电行为聚类图

Fig. 1 Clustering diagram of user charging behaviour

通过图 1 可以看出, 1 类用户的充电时间分布比较平均, 15 时的充电频率较高。2 类用户有两个充电高峰期, 分别在 11 时和 18 时。3 类用户主要集中在晚上充电, 在 23 时到次日 1 时这个时间段充电频率最高。4 类用户的充电时间主要集中在 6 点, 其余时间的充电频率较低。

## 2 多尺度混合 TCN-BiLSTM-Attention 模型构建

结合时间卷积网络 TCN、BiLSTM 网络和 Attention 机制, 设计了一种多尺度混合 TCN-BiLSTM-Attention 充电量预测模型结构, 如附录 A 图 A1 所示。

### 2.1 输入层

将预处理后的充电量数据、天气数据以及经济数据输入到预测模型中, 采用滑动窗口大小为  $d$  的多方面特征和充电量作为输入, 则在  $t$  时刻的输入如式(3)所示。

$$X = \{X_{t-d+1}, X_{t-d+2}, X_{t-d+3}, \dots, X_t\} \quad (3)$$

式中:  $X$  表示输入的序列;  $X_t$  表示  $t$  时刻输入的特征数据。

### 2.2 多尺度混合 TCN 层

TCN 网络是一种专门为时序问题设计的模型, 能够有效挖掘数据之间的关联性<sup>[21]</sup>。本文的混合 TCN 模型设计了双路径扩张卷积层结构, 一个扩张卷积层的扩张因子从小到大呈指数增长, 另一个扩张卷积层的扩张因子从大到小呈指数减小, 使用一



个 $1 \times 1$ 卷积将其拼接后的特征降至 1 个输出通道。两个不同扩张系数的卷积层混合拼接，可以创建一个更为广泛的感受野，从而兼顾提取充电量特征的浅层细节和深层依赖信息，过滤掉冗余特征。混合 TCN 残差模块结构如图 2 所示。




图 2 混合 TCN 残差模块

Fig. 2 Hybrid TCN residual module

本文采用的混合 TCN 层分别选用卷积核大小为 1、4、7 的混合 TCN 网络提取不同尺度的特征，小尺度的卷积核可以堆叠更多层次，构建更深的网络，提取更复杂的特征。大尺度卷积核提供更大的感受野，捕捉全局信息。相较于单一尺度的 TCN 层，混合 TCN 层拥有更强大的特征捕捉能力。将不同卷积核大小的混合 TCN 层使用并行拼接的方式实现特征融合，并输送到 BiLSTM 模块。混合 TCN 层的计算公式如式(4)一式(7)所示。

$$S_1 = T_1(x) \quad (4)$$

$$S_2 = T_4(S_1) \quad (5)$$

$$S_3 = T_7(S_2) \quad (6)$$

$$S = C(S_1, S_2, S_3) \quad (7)$$

式中： $T_1$ 、 $T_4$ 、 $T_7$  分别表示卷积核大小为 1、4、7 的混合 TCN 网络卷积单元； $x$  表示输入向量； $S$  表示混合 TCN 层的输出向量； $C(\cdot)$  表示并行拼接操作； $S_1$ 、 $S_2$ 、 $S_3$  分别表示通过不同卷积核大小的 TCN 网络生成的特征向量。

### 2.3 BiLSTM 层

作为一种特殊的循环神经网络(recurrent neural network, RNN)结构，LSTM 使用递归隐藏层中的记忆单元和门控机制过滤和传递信息<sup>[22]</sup>。BiLSTM 是一种混合的 LSTM 网络，它通过两个相反方向的 LSTM 层来处理时序数据，以捕获时间序列中前后

信息的依赖关系。前向 LSTM 从起点到终点处理序列，后向 LSTM 则从终点到起点处理序列，两者的输出连接起来可提供更全面的上下文信息，从而提升模型对时序特征的理解。BiLSTM 具体理论推导过程如附录 B 所示。

### 2.4 Attention 层

Attention 机制是一种能够使模型对输入数据的不同部分给予不同重视的技术，它广泛应用于时间序列预测领域<sup>[23]</sup>。使用 Attention 机制可以动态地聚焦不同部分输入数据的关键信息，以提高处理效率和预测效果。

### 2.5 全连接层

将注意力层的输出向量通过全连接层进行特征融合，使用 sigmoid 函数计算预测值，设  $t$  时刻预测值为  $y_t$ ，则

$$y_t = \sigma(W_a A + b_a) \quad (8)$$

式中： $\sigma$  表示 sigmoid 激活函数； $W_a$  表示权重矩阵； $A$  表示 Attention 层输出的特征矩阵； $b_a$  表示偏置项。

### 2.6 输出层

将经过全连接层输出的数据进行反归一化处理，得到最终的充电量预测值  $Y_{\text{predict}}$ ，设预测步长为  $n$ ，则

$$Y_{\text{predict}} = [y_1, y_2, \dots, y_n]^T \quad (9)$$

## 3 多层级迁移学习策略

传统的机器学习模型通常假设训练数据和测试数据来自相同的分布。然而，在众多的实际应用中，获取与目标域完全匹配的大量标记数据是十分困难的。迁移学习旨在将知识从一个或多个源领域迁移到目标领域，用现有领域的知识来处理不同但相关领域中的问题<sup>[24-26]</sup>。本文在传统迁移学习策略基础上提出了一种多层级迁移学习策略，通过在不同隐含层级上进行知识迁移，使模型能够更好地从源域学习到适用于目标域的深层次特征。该方法分为源域数据相关性等级划分和多层级迁移学习建模两个部分。

### 3.1 基于交叉熵的源域数据等级划分

使模型具有良好域适应性的关键在于如何选择领域间具有相似判别性的样本<sup>[27]</sup>。本文提出了一种基于交叉熵误差函数源数据分级划分流程，交叉熵是用于分类问题的一种评价指标，其主要用于衡量两个概率分布之间的差异。本文通过交叉熵误差函数来判断源域与目标域样本的相关性程度，交叉熵误差函数表达式如式(10)所示。

$$L(\hat{y}, y) = -y \log(\hat{y}) - (1 - y) \log(1 - \hat{y}) \quad (10)$$

式中:  $\hat{y}$  表示源域预测的概率分布, 取值范围为  $[0,1]$ , 其值越接近 1 表示源域样本与目标域样本的相关性越强;  $y = 0$  或  $1$ , 表示不相关或者相关。

基于交叉熵误差函数的源充电站数据等级划分流程如图 3 所示, 主要包含以下几个步骤: 首先将目标充电站实测的少量数据经过滑动窗口输入到多尺度混合 TCN-BiLSTM-Attention 模型中进行训练, 建立初始的预测模型, 然后用源充电站数据同样按以上方式输入到初始预测模型中进行训练, 接着将训练得到的预测结果与实际充电量进行交叉熵误差计算, 最后根据交叉熵误差的大小筛选相关数据并对其进行分级排序。




图 3 源充电站数据等级划分流程

Fig. 3 Source charging station data segmentation process

### 3.2 多层级迁移学习策略

在深度迁移学习框架中, 每个隐含层都生成针对新领域的特征表示。然而, 由于先前领域的特征是基于相关性较弱的数据集训练的, 这些特征可能并不完全匹配新领域的实际需求。因此, 需要对这些隐含层输出的特征进行筛选, 从而为后续的迁移任务挑选出更适合的特征。本文采用多层级迁移学习策略, 通过判断预测模型中每一层权重是否更新, 从而筛选出最优的特征。

多层级迁移学习策略首先将源域数据相关性由低到高划分成  $M$  组数据  $\{X_1, X_2, X_3, \dots, X_M\}$ ,  $M$  也表示模型的层数, 从第 2 节可知本文模型总共有 7 层, 因此  $M = 7$ 。首先, 采用相关性低的数据  $X_1$  训练浅层网络  $M_1$ , 并保留浅层神经网络的权重  $w_0$ ; 再用相关性较高的数据  $X_2$ , 训练浅层网络  $M_2$ , 加载上一层的权重, 训练得到该层新的权重  $w_1$ , 判断该层预测误差相较于上一层是否有所减小, 如果预测误差减小, 则  $w_1$  作为下一层网络训练的初始权重, 否则不更新权重,  $w_0$  继续作为下一层网络训练的初始权重。以此类推, 直到源充电站中相关性最强的数据训练完成。多层级迁移学习策略流程如图 4 所示。




图 4 多层级迁移学习策略流程

Fig. 4 Multi-level transfer learning strategy process

### 3.3 迁移学习模型自适应学习和结构优化

#### 3.3.1 迁移模型自适应学习

为了防止模型在迁移过程中出现负迁移现象, 需要对模型进行动态调整, 本文通过引入  $l_2$  范数的正则化, 动态调整多尺度混合 TCN-BiLSTM-Attention 网络的权重参数, 实现迁移学习模型的自适应学习, 具体步骤如下。

##### 1) 目标函数的设计

迁移模型的目标函数包括两个部分: 一部分是平方和损失, 通过计算每个样本的预测误差平方并求和, 使模型在训练过程中逐步减少预测误差; 另一部分是基于  $l_2$  范数的正则化项, 用于避免权重过大导致的过拟合问题。目标函数  $L$  可以表示为

$$L = \frac{1}{2} \sum_{t=1}^T (y_{or} - y_{dr})^2 + \frac{\lambda}{2Q} \|W\|^2 \quad (11)$$

式中:  $y_{or}$  和  $y_{dr}$  分别表示在时间步  $t$  的预测输出和期望输出;  $T$  表示样本数量;  $W$  表示预测模型中的权重;  $Q$  表示权重参数的数量;  $\lambda$  表示惩罚因子, 用于控制正则化项的影响。

##### 2) 自适应正则化因子的调整

为了进一步提升自适应能力, 本文提出一个基于权重分散度的自适应惩罚因子调整机制。惩罚因子  $\lambda$  的大小会根据预测精度和权重的分散度动态调整。首先, 定义权重分散度  $e_w$  为

$$e_w = \sqrt{\frac{1}{Z-1} \sum_{m=1}^M (W_m - \bar{W})^2} \quad (12)$$

式中:  $Z$  表示权重的数量;  $W_m$  为第  $m$  个权重;  $\bar{W}$  表示权重的平均值。权重分散度反映了权重值的分布情况, 当  $e_w$  较大时, 说明权重值分散程度高, 此时可以增大  $\lambda$  来抑制权重过大的情况; 当  $e_w$  较小时, 表明权重相对集中, 可以减小  $\lambda$  的值。

为了反映模型的预测精度, 定义预测误差变化率  $\Delta e$  如式(13)所示。

$$\Delta e = \frac{e_{t+1} - e_t}{e_t} \quad (13)$$

式中,  $e_t$  表示第  $t$  次迭代的预测误差。结合权重分散度  $e_w$  和  $\Delta e$ , 自适应正则化因子  $\lambda$  可表示为

$$\lambda = \Delta e \cdot e_w \quad (14)$$

自适应惩罚因子调整机制能够根据模型的学习状态动态调整正则化强度, 使模型在不同训练阶段都能保持良好的学习能力。

### 3.3.2 基于敏感度分析神经元增生策略的结构优化

在结构优化中, 预测模型中的 BiLSTM 层通过敏感度分析来确定是否需要添加新的神经元。计算隐藏层神经元的激活强度, 并以此作为神经元敏感度的指标。对于输入样本  $x_n$ , 第  $k$  个神经元的敏感度  $\varphi_k(x_n)$  计算公式为

$$\varphi_k(x_n) = o_i \cdot \tanh(C_i) \quad (15)$$

式中,  $o_i$  和  $c_i$  分别表示 BiLSTM 的输出门和细胞状态。敏感度反映了当前样本对神经元激活的影响大小。通过计算每个神经元的敏感度指数并求和归一化得到式(16)。

$$\theta_k = \frac{\varphi_k(x_n)}{\sum_{k=1}^K \varphi_k(x_n)} \quad (16)$$

式中:  $\theta_k$  表示第  $k$  个神经元的归一化敏感度指数;  $K$  为神经元个数。设定一个敏感度阈值  $\theta_0$ , 当所有神经元的敏感度都小于此阈值时, 表示当前样本不能有效激活现有神经元, 此时需要添加新的神经元。

当确定需要添加新的神经元时, BiLSTM 通过已有的高敏感度神经元初始化新神经元的权重参数。具体来说, 选择敏感度最高的两个神经元, 并使用它们的权重均值作为新神经元的初始权重。

$$W_{K+1} = \left| \frac{W_{1,\max} + W_{2,\max}}{2} \right| \quad (17)$$

$$b_{K+1} = \left| \frac{b_{1,\max} + b_{2,\max}}{2} \right| \quad (18)$$

式中:  $W_{K+1}$  表示新增神经元的权重参数;  $b_{K+1}$  表示新增神经元的偏置参数;  $W_{1,\max}$  和  $W_{2,\max}$  表示两个敏感度最高的神经元对应的最大权重;  $b_{1,\max}$  和  $b_{2,\max}$  表示两个敏感度最高的神经元对应的最大偏置。这种

初始化方法确保了新神经元的权重接近已有高敏感度神经元的状态, 使得新添加的神经元能够快速融入现有的网络结构。

## 4 算例分析验证

### 4.1 数据集描述和处理

本文所用的数据是湖北省国家电网充电站充电量实测数据, 时间范围是从 2022 年 1 月 1 日至 2022 年 8 月 31 日, 数据的时间步长为 1 h, 选用 7 个地区的充电站充电量数据作为源域数据, 另外一个地区的充电站充电量数据作为目标域数据, 源域数据合计有  $7 \times 5832$  条数据, 目标域数据有 5832 条数据。目标域充电量数据如图 5 所示。




图 5 目标域充电站数据

Fig. 5 Target domain charging station data

考虑到充电量的时序性、周期性以及环境因素和经济因素, 模型的输入特征主要包括以下 5 类共计 14 维特征, 数据集特征信息如表 3 所示。

表 3 输入特征

Table 3 Input features

| 特征类别   | 具体描述                           |
|--------|--------------------------------|
| 时间戳    | 每条时间序列的年、月、日、小时。               |
| 日期     | 周一至周五为工作日, 周六、周日为周末, 法定节假日为节假日 |
| 用户充电行为 | 通过聚类分析得到的不同类别用户在每小时的充电次数       |
| 环境     | 每天的最高温度、最低温度和天气类型              |
| 电价     | 充电站每小时所收取的电费、服务费总额             |

由于日期和天气类型均为文本数据, 因此需要手动编码将其转化为数值型数据, 对上述特征进行标签编码, 如表 4 所示。

表 4 特征编码

Table 4 Feature coding

|            |                   |
|------------|-------------------|
| 工作日/周末/节假日 | 晴天/阴天/下雨天/下雪天/雾霾天 |
| 0/1/2      | 0/1/2/3/4         |

为构造迁移学习应用的小样本数据场景, 共构建了 3 种迁移学习场景, 其数据划分方法如图 6 所示。



如图6所示, 场景1表示缺失1—4月数据, 将5月、6月数据作为训练集, 7月数据作为验证集, 8月数据作为测试集。场景2表示缺失3—6月数据, 将1月、2月数据作为训练集, 7月数据作为验证集, 8月数据作为测试集。场景3表示缺失5—8月数据, 将3月、4月数据作为训练集, 1月数据作为验证集, 2月数据作为测试集。




图6 充电站数据划分方法

Fig. 6 Charging station data segmentation method

由于数据集中充电量数值在0~2500 kWh波动, 为了消除不同数据之间的量纲差异, 使用 min-max 归一化对数据进行处理。归一化公式为

$$y' = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (19)$$

式中:  $y'$  表示归一化后的样本;  $x_i$  表示经过预处理后的样本;  $x_{\max}$ 、 $x_{\min}$  分别表示特征值中的最大、最小值。

#### 4.2 评价指标选取

本文选取平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)、拟合优度( $R^2$ )作为电动汽车充电站充电量预测效果的评价指标, 具体定义式见附录C。

#### 4.3 实验参数确定

预测模型在 Anaconda 环境中的 PyCharm 搭建, 为准确预测小样本条件下的充电站充电量。经过多次调试, 得到了模型的各项参数如表5所示。

#### 4.4 实验结果

##### 4.4.1 充电量与不同类别特征的相关性分析

充电站充电量受到分时电价、充电利用率、气象信息等多因素特征的影响<sup>[28]</sup>。为验证本文提取的不同类别特征与充电量之间的相关性, 选择 Spearman 相关性系数  $\rho$  进行相关性分析, 其计算方法为

$$\rho = \frac{\sum_i^n (R_i - \bar{R})(S_i - \bar{S})}{\sqrt{\sum_i^n (R_i - \bar{R})^2 \sum_i^n (S_i - \bar{S})^2}} \quad (20)$$

式中:  $R_i$ 、 $S_i$  表示两变量的观测值秩次;  $\bar{R}$ 、 $\bar{S}$  表

表5 模型参数设置

Table 5 Model parameter setting

| 名称                                       | 参数设置量                                                              |
|------------------------------------------|--------------------------------------------------------------------|
| 全局参数                                     | 滑动窗口大小 = 6                                                         |
|                                          | 特征数目 = 14                                                          |
|                                          | batch_size = 32                                                    |
|                                          | epoch = 200                                                        |
| 混合 TCN <sub>1</sub> -TCN <sub>3</sub>    | kernel_size=1/4/7                                                  |
|                                          | nb_filters=64                                                      |
|                                          | nb_stacks=2                                                        |
|                                          | dilation <sub>1</sub> =[1,2,4,8], dilation <sub>2</sub> =[8,4,2,1] |
|                                          | padding=casual                                                     |
| Concat                                   | dropout_rate=0.1                                                   |
|                                          | —                                                                  |
| BiLSTM <sub>1</sub> -BiLSTM <sub>2</sub> | Units = 128                                                        |
|                                          | Activation = ReLU                                                  |
| Attention                                | —                                                                  |
|                                          | —                                                                  |
| 全连接层                                     | Activation = Sigmoid                                               |
|                                          | Loss = MSE                                                         |
| 训练参数                                     | learning_rate = $1 \times 10^{-4}$                                 |
|                                          | Optimizer = Adam                                                   |

示两变量的平均秩次;  $n$  表示每种变量的总数量。

Spearman 系数  $\rho$  的范围为[-1,1], 其绝对值越大表示相关性越强,  $\rho=0$  表示变量之间无相关性。通过逐一计算变量两两之间的 Spearman 相关系数, 得到的热力图如图7所示。




图7 充电站充电量与各特征间的相关性

Fig. 7 Correlation between charging volume of charging station and each characteristic

由图7可知, 充电量与充电次数间的相关性最强, 相关系数为0.93; 电费、服务费的相关系数次之, 分别为0.74、0.91; 温度的相关影响因素较强,

最高、最低温度分别为 0.52、0.55；天气类型、日期类型相关性较弱，分别为 0.21、0.32。所得结论基本与用户充电习惯一致，充电站充电量与用户充电次数的相关性最强，因此将用户的充电次数和充电时间进行聚类分析，挖掘出用户的充电行为特征，以提高模型的预测精度。

#### 4.4.2 考虑用户充电行为与不考虑用户充电行为对比

为验证模型在考虑用户充电行为作为特征输入时的优越性，将考虑充电行为特征和不考虑充电行为特征进行对比分析，为严格控制变量，两者均用本文设计的模型进行训练，实验结果如表 6 所示。

表 6 不考虑用户充电行为与考虑用户充电行为的模型误差指标对比

Table 6 Comparison of model error metrics with/without considering user charging behaviour

| 特征选取    | MAE/kWh | RMSE/kWh | $R^2$ |
|---------|---------|----------|-------|
| 不考虑充电行为 | 40.86   | 51.92    | 0.959 |
| 考虑充电行为  | 20.59   | 26.13    | 0.989 |

表 6 列举了在充电站充电量预测中是否考虑充电行为特征作为输入特征的 3 个评价指标。通过分析可知，在均使用本文所提模型的前提下，考虑充电行为与不考虑充电行为相比，MAE 降低 49.61%、RMSE 降低 49.67%， $R^2$  提高 3.13%，验证了考虑充电行为作为特征可以更准确地对充电站充电量进行预测。

#### 4.4.3 模型性能对比

为验证本文使用的混合神经网络模型每一部分模块的有效性，选择不同网络层数的混合 TCN、BiLSTM 模型对测试集数据进行预测，为严格控制变量，实验模型的内部参数均保持一致。不同网络层数混合 TCN、BiLSTM 模型预测误差对比结果如表 7 所示。

表 7 不同网络层数混合 TCN、BiLSTM 误差结果比较

Table 7 Comparison of error results of improved TCN and BiLSTM with different number of network layers

| 预测模型   | 网络层数 | MAE/kWh | RMSE/kWh | $R^2$ |
|--------|------|---------|----------|-------|
| 混合 TCN | 2 层  | 57.36   | 72.24    | 0.920 |
|        | 3 层  | 54.12   | 69.53    | 0.928 |
|        | 4 层  | 53.81   | 69.04    | 0.928 |
| BiLSTM | 1 层  | 55.70   | 70.69    | 0.925 |
|        | 2 层  | 53.28   | 67.81    | 0.930 |
|        | 3 层  | 54.06   | 69.47    | 0.928 |

由表 7 可知，混合 TCN 网络层数从 2 层增加到 3 层时，预测精度提升较为明显，从 3 层增加到 4 层时，预测精度几乎没有提升，反而大大增加了模型的训练时间。BiLSTM 网络层数为 2 层时预测精

度最高。因此本文采用混合 TCN 为 3 层、BiLSTM 为 2 层的多尺度 TCN-BiLSTM-Attention 混合神经网络模型。

为验证本文所提模型拥有更高的预测精度，将机器学习模型 SVR 和深度学习中的 TCN、混合 TCN、LSTM、TCN-LSTM、TCN-GRU 模型与本文所提模型进行对比分析，各模型预测结果如表 8 所示。

表 8 不同模型预测误差结果比较

Table 8 Comparison of prediction error results of different models

| 预测模型     | MAE/kWh | RMSE/kWh | $R^2$ |
|----------|---------|----------|-------|
| SVR      | 81.35   | 104.26   | 0.834 |
| TCN      | 54.12   | 69.53    | 0.928 |
| 混合 TCN   | 51.95   | 64.62    | 0.932 |
| LSTM     | 53.28   | 67.81    | 0.930 |
| TCN-GRU  | 31.73   | 40.17    | 0.976 |
| TCN-LSTM | 30.24   | 38.21    | 0.978 |
| 本文模型     | 20.59   | 26.13    | 0.989 |


由表 8 预测误差结果比较分析可知，SVR 的核函数主要是用来处理线性问题，在处理非线性复杂模式的时间序列数据时具有局限性。LSTM、TCN 这类单一神经网络模型不能充分捕捉时序和特征间的潜在关联，预测精度相对较差，其中混合 TCN 模型相较于传统 TCN 模型，MAE 下降了 4.01%，RMSE 下降了 7.06%， $R^2$  上升了 0.43%，证明了双扩张层结构的混合 TCN 网络可以提供一个更广泛的感受野，增加了预测精度；混合神经网络模型在预测精度上相较于单一神经网络均有所提升。本文通过多尺度时间卷积网络提取不同层次和不同间隔的特征，双向长短期记忆网络捕捉时间序列长期依赖关系，注意力机制强化个体特征选择，结合每一模块的优势，采用一种多尺度混合 TCN-BiLSTM-Attention 预测模型，该模型的 3 个评价指标表现均为最优。

#### 4.4.4 调整惩罚因子 $\lambda$ 的影响

通过设置  $\lambda < 0.5$ ，平衡交叉熵损失函数的影响中相关性较强样本和较弱样本的占比。下面以  $\theta_0 = 0.45$  为例说明惩罚因子  $\lambda$  对暂态稳定评估模型性能的影响。 $\lambda$  变化范围为 0.1~0.5，变化步长为 0.05，随着  $\lambda$  的变化，模型的指标变化趋势如图 8 所示。


观察图 8 可知：随着  $\lambda$  的增大，评价指标的误差总体上呈上升趋势，这是因为正则化过强，模型会受到较大的限制。权重被迫缩小甚至接近零，导致模型无法有效学习数据中的模式。 $\lambda = 0.1$  和  $\lambda = 0.15$  的预测精度接近，考虑到惩罚因子过小时可能导致模型过拟合，导致泛化性降低，因此设置  $\lambda = 0.15$  较为合理。



图 8  $\lambda$  与模型评价指标的关系Fig. 8 Relationship of  $\lambda$  and model evaluation indicators

#### 4.4.5 调整敏感度阈值 $\theta_0$

为分析敏感度阈值对模型预测性能的影响, 设置  $\lambda = 0.15$ ,  $\theta_0$  的变化范围为 0.1~0.5, 步长为 0.05, 各项指标随  $\theta_0$  变化的趋势如图 9 所示。

图 9  $\theta_0$  与模型评价指标的关系Fig. 9 Relationship of  $\theta_0$  and model evaluation indicators

敏感度阈值  $\theta_0$  的设置控制在结构优化中是否添加新的神经元。它通过判断神经元的激活强度, 决定当前网络结构是否足够来应对输入数据。由图 9 可知, 当  $\theta_0 < 0.4$  时, 各项性能评估指标均有提升, MAE 和 RMSE 误差的下降说明引入敏感度阈值  $\theta_0$  可以提高模型的预测精度。当  $\theta_0 > 0.4$  时, 预测精度开始下降, 这是由于阈值增大导致神经元增多, 模型的复杂度加大, 可能会过度拟合训练数据, 对数据中的噪声过于敏感, 从而在测试集上的表现下降。因此设置  $\theta_0 = 0.4$  时, 多尺度混合 TCN-BiLSTM-Attention 模型达到最优。

#### 4.4.6 多层级迁移性能分析

本文根据多尺度混合 TCN-BiLSTM-Attention 模型将其划分成 7 层, 每一层迁移学习基于上一层

学习得到的权重进行更新, 直至最后一层学习完后保留模型的最优权重对目标域数据进行预测, 为验证每一层迁移后模型的预测精度是否有所提升, 对比了测试数据不同层级迁移归一化后的平均绝对误差、均方根误差和拟合优度, 如图 10 所示。




图 10 不同迁移层数预测误差

Fig. 10 Prediction error for different migration layers

由图 10 可以看出, 随着迁移层数的增加, 各预测误差均有所下降, 其中迁移层数在 1 至 4 层时, 迁移学习模型逐渐从源域中学习更多特征信息, 并将其成功转移到目标域, 使得预测误差显著下降。迁移层数到达 5 至 7 层时, 模型的 MAE、RMSE 和  $R^2$  均趋于稳定, 表明模型经过正则化惩罚因子和敏感度阈值, 将较高权重的神经元成功保留, 进行多次自适应迁移后达到了最优性能状态, 并且未出现负迁移现象。在迁移到第 7 层时, 各个预测误差达到最低, 因此本文选取第 7 层迁移学习的权重作为模型最终权重。

为了验证本文提出的多层级迁移策略能够提升训练数据缺失的充电站充电量预测精度, 分别采用了不迁移和将源域数据直接迁移与本文采用的多层级迁移进行对比, 测试集在 5—8 月数据缺失情况下, 不同迁移策略的充电量预测曲线对比如图 11 所示。由图 11 分析得出, 在只有少量样本的情况下, 不迁移直接对少量数据进行预测, 预测效果并不理想; 采用迁移学习策略, 可以通过利用预训练的网络权重, 加速训练过程的收敛, 对比从头开始训练模型要节省大量的计算资源和时间, 另外, 利用其他充电站的数据来训练模型, 然后将这些模型迁移到数据稀缺的充电站地区, 从而解决数据不足的问题, 相较于不迁移的预测效果有明显提升。

由表 9 可以看出, 相较于直接迁移, 本文采用的多层级迁移学习的预测模型预测精度有明显提升, 在 5—8 月数据缺失的情形下, MAE 降低了 10.75%, RMSE 降低了 13.73%,  $R^2$  提升了 0.4%, 预测曲线更

贴合电动汽车充电站充电量的实际测量值。在 1—4 月和 3—6 月数据缺失情形下，多层迁移的误差均为最低，证明其在不同时段数据缺失情况下均有良好的预测效果，证明本文预测模型的有效性和适用性。




图 11 预测曲线对比

Fig. 11 Comparison of forecast curves

表 9 不同迁移策略预测误差对比

Table 9 Comparison of prediction errors for different migration strategies

| 缺失数据  | 迁移策略 | MAE/kWh | RMSE/kWh | $R^2$ |
|-------|------|---------|----------|-------|
| 1—4 月 | 不迁移  | 73.96   | 94.57    | 0.872 |
|       | 直接迁移 | 24.17   | 31.24    | 0.985 |
|       | 多层迁移 | 21.32   | 27.48    | 0.989 |
| 3—6 月 | 不迁移  | 84.45   | 106.38   | 0.858 |
|       | 直接迁移 | 33.59   | 42.01    | 0.973 |
|       | 多层迁移 | 26.64   | 33.72    | 0.980 |
| 5—8 月 | 不迁移  | 71.43   | 91.02    | 0.874 |
|       | 直接迁移 | 23.07   | 30.29    | 0.986 |
|       | 多层迁移 | 20.59   | 26.13    | 0.989 |

5 结论

本文针对新建、改造充电站充电量数据样本不足的问题，提出了基于多特征提取和多层级迁移学习的电动汽车充电站充电量预测方法，通过算例分析验证，得出了以下主要结论：

- 1) 通过 K-Means 聚类算法对电动汽车用户的充电订单数据进行分析，提取了不同时间段的充电次数。根据充电行为将用户划分为 4 类，并将这些聚类结果作为输入特征，能够有效提高预测模型的精度。
- 2) 提出的多尺度混合 TCN-BiLSTM-Attention 模型，通过并行连接的混合 TCN 模块提取多尺度特征，增强了对复杂数据结构的解析能力，并优化了特征选择过程。BiLSTM 网络通过双向学习时间序列的长期依赖关系，能够更全面地捕捉上下文信息。结合注意力机制，模型能够强化对关键特征的选择。与其他模型相比，该方法有效提升了预测精度。
- 3) 通过使用交叉熵损失函数对源域数据进行筛选，并根据数据的相关性划分等级，分级的数据

输入到模型中进行多层级迁移学习训练。实验结果表明，采用多层级迁移学习的模型预测精度高达 98.9%。相较于不进行迁移学习或直接迁移的策略，该方法具有明显的优势。实验结果验证了在数据缺失的情况下该方法依然能保持高精度的预测能力。通过自适应迁移学习与结构优化的协同设计，结合参数动态调节和网络结构增生策略，实现模型能力的多层级优化，有效提升了模型的收敛性和泛化能力。

附录 A




图 A1 多尺度混合 TCN-BiLSTM-Attention 模型结构

Fig. A1 Multi-scale hybrid TCN-BiLSTM-Attention model structure

## 附录 B BiLSTM 网络模型

LSTM 引入了门控机制来处理时间序列的依赖关系, 门控机制包括输入门 ( $f^{(t)}$ )、遗忘门 ( $i^{(t)}$ ) 和输出门 ( $o^{(t)}$ ) 3 种门结构, 输入门负责调节输入信息 ( $x^{(t)}$ ) 对于细胞状态的贡献, 遗忘门用来确定保留多少上一时刻的细胞状态, 输出门则决定了从当前细胞状态到下一状态输出的内容。经过综合输入门和遗忘门的信息, 更新候选细胞状态 ( $g^{(t)}$ )、细胞状态 ( $C^{(t)}$ )。LSTM 隐藏状态 ( $h^{(t)}$ ) 的更新依赖于输出门的激活值和细胞状态。各参数的计算公式如式(B1)一式(B5)所示。

$$f^{(t)} = \sigma(W_f \cdot [h^{(t-1)}, x^{(t)}] + b_f) \quad (B1)$$

$$i^{(t)} = \sigma(W_i \cdot [h^{(t-1)}, x^{(t)}] + b_i) \quad (B2)$$

$$o^{(t)} = \sigma(W_o \cdot [h^{(t-1)}, x^{(t)}] + b_o) \quad (B3)$$

$$C^{(t)} = g^{(t)} i^{(t)} + C^{(t-1)} f^{(t)} \quad (B4)$$

$$h^{(t)} = o^{(t)} \tanh C^{(t)} \quad (B5)$$

式中:  $\sigma$  表示 sigmoid 激活函数;  $W_f$ 、 $W_i$ 、 $W_o$  表示权重;  $b_f$ 、 $b_i$ 、 $b_o$  表示偏置项。LSTM 的网络结构如图 B1 所示。




图 B1 LSTM 结构示意图

Fig. B1 Schematic diagram of LSTM structure

Bi-LSTM 通过在序列数据上同时运行两个独立的 LSTM 网络, 通过双向传播可以有效地捕捉充电量序列的前向和反向关联信息。 $\vec{h}_c$  和  $\vec{h}_f$  分别表示在当前时间步的前向和反向传播隐藏状态, 其更新上一时间步的前向和反向隐藏状态  $\vec{h}_{c-1}$  和  $\vec{h}_{f-1}$  的有效信息, 将这两个隐藏层加权连接得到 Bi-LSTM 的输出  $h_t$ , BiLSTM 计算过程如式(B6)一式(B8)所示。

$$\vec{h}_c = \text{LSTM}(x_t, \vec{h}_{c-1}) \quad (B6)$$

$$\vec{h}_f = \text{LSTM}(x_t, \vec{h}_{f-1}) \quad (B7)$$

$$h_t = \sigma(W_h \cdot [\vec{h}_c, \vec{h}_f] + b_h) \quad (B8)$$

式中:  $W_h$  表示权重矩阵;  $b_h$  表示偏置参数。

## 附录 C

三大评价指标的计算公式分别为

$$e_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (C1)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (C2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (C3)$$

式中:  $N$  表示预测样本数量;  $\hat{y}_i$  表示预测值;  $y_i$  表示真实值;  $\bar{y}$  表示真实值的平均值。

## 参考文献

- [1] 徐俊俊, 程奕凌, 张腾飞, 等. 计及充电行为特征与可调性的电动汽车集群优化调度[J]. 电力系统自动化, 2023, 47(23): 23-32.  
XU Junjun, CHENG Yiling, ZHANG Tengfei, et al. Optimal scheduling of electric vehicle clusters considering characteristics and adjustability of charging behavior[J]. Automation of Electric Power Systems, 2023, 47(23): 23-32.
- [2] 朱思嘉, 余思雨, 王戈, 等. 基于条件风险价值的电动汽车充电站规划[J]. 电测与仪表, 2023, 60(7): 13-18, 82.  
ZHU Sijia, YU Siyu, WANG Ge, et al. Research on charging station planning of EV based on CVaR[J]. Electrical Measurement & Instrumentation, 2023, 60(7): 13-18, 82.
- [3] HUANG Zhao, FANG Baling, DENG Jin. Multi-objective optimization strategy for distribution network considering V2G-enabled electric vehicles in building integrated energy system[J]. Protection and Control of Modern Power Systems, 2020, 5(1): 48-55.
- [4] 李振华, 兰芳, 钟悦, 等. 基于双骨架共绕技术的测量保护一体化电流传感器[J]. 高电压技术, 2022, 48(11): 4427-4436.  
LI Zhenhua, LAN Fang, ZHONG Yue, et al. Measurement-protection-integrated current sensor based on double-bobbin co-winding technology[J]. High Voltage Engineering, 2022, 48(11): 4427-4436.
- [5] 庞松岭, 赵雨楠, 唐金锐, 等. 基于充电桩利用率的充电负荷超短期预测方法研究[J]. 电力科学与技术学报, 2024, 39(1): 115-123, 133.  
PANG Songling, ZHAO Yunan, TANG Jinrui, et al. A novel ultra short-term charging load forecasting method based on usage degree of charging piles[J]. Journal of Electric Power Science and Technology, 2024, 39(1): 115-123, 133.
- [6] 李振华, 廖星锐, 童悦, 等. 基于动态重燃弧模型的 VFTO 与 VFCT 仿真及特性分析[J]. 电力系统保护与



- 控制, 2023, 51(3): 79-88.
- LI Zhenhua, LIAO Xingrui, TONG Yue, et al. Simulation and characteristic analysis of VFTO and VFTC based on a dynamic reignition arc model[J]. power System Protection and Control, 2023, 51(3): 79-88.
- [7] 范云松, 田俊山, 郑传钊, 等. 高速公路与电网耦合背景下的充电站布局规划[J]. 电力系统及其自动化学报, 2023, 35(9): 40-52.
- FAN Yunsong, TIAN Junshan, ZHENG Chuanzhao, et al. Layout and planning of electric vehicle charging stations under background of coupled expressway and power grid[J]. Proceedings of the CSU-EPSC, 2023, 35(9): 40-52.
- [8] 李振华, 崔九喜, 卢和平, 等. 电力系统宽频宽动态电流测量技术研究综述[J]. 高电压技术, 2024, 50(8): 3421-3439.
- LI Zhenhua, CUI Jiuxi, LU Heping, et al. Review of wideband and wide-dynamic-range current measurement techniques in power systems[J]. High Voltage Engineering, 2024, 50(8): 3421-3439.
- [9] 潘胤吉, 邱晓燕, 吴甲武, 等. 基于马尔可夫决策过程的电动汽车充电行为分析[J]. 电力建设, 2018, 39(7): 129-137.
- PAN Yinji, QIU Xiaoyan, WU Jiawu, et al. Analysis on charging behaviors of electric vehicles based on Markov decision processes[J]. Electric Power Construction, 2018, 39(7): 129-137.
- [10] 姚明, 毛文杰, 曹淑超, 等. 基于多源数据的电动汽车充电设施布局优化方法研究[J]. 智慧电力, 2023, 51(9): 31-37.
- YAO Ming, MAO Wenjie, CAO Shuchao, et al. Optimization method of electric vehicle charging facility layout based on multi-source data[J]. Smart Power, 2023, 51(9): 31-37.
- [11] 张智禹, 王致杰, 杨皖昊, 等. 基于充电需求预测的电动汽车充电站选址规划研究[J]. 电测与仪表, 2024, 61(10): 39-49.
- ZHANG Zhiyu, WANG Zhijie, YANG Wanhao, et al. Research on location planning of electric vehicle charging station based on prediction of charging demand[J]. Electrical Measurement & Instrumentation, 2024, 61(10): 39-49.
- [12] 沈鑫, 严松, 李妍. 考虑交通流量的电动汽车充电站优化规划方法[J]. 智慧电力, 2023, 51(7): 74-79.
- SHEN Xin, YAN Song, LI Yan. Optimal planning method of electric vehicle charging station considering traffic flow[J]. Smart Power, 2023, 51(7): 74-79.
- [13] 吴豫, 董智, 赵阳, 等. 基于 LSTM 算法的配电网分布式电源和电动汽车充电站联合优化规划[J]. 供用电, 2023, 40(6): 64-74.
- WU Yu, DONG Zhi, ZHAO Yang, et al. Joint optimization planning of distribution network DG and EV charging station based on LSTM algorithm[J]. Distribution & Utilization, 2023, 40(6): 64-74.
- [14] 史凯钰, 张东霞, 韩肖清, 等. 基于 LSTM 与迁移学习的光伏发电功率预测数字孪生模型[J]. 电网技术, 2022, 46(4): 1363-1372.
- SHI Kaiyu, ZHANG Dongxia, HAN Xiaoqing, et al. Digital twin model of photovoltaic power generation prediction based on LSTM and transfer learning[J]. Power System Technology, 2022, 46(4): 1363-1372.
- [15] 尹杰, 刘博, 孙国兵, 等. 基于迁移学习和降噪自编码器-长时间记忆的锂离子电池剩余寿命预测[J]. 电工技术学报, 2024, 39(1): 289-302.
- YIN Jie, LIU Bo, SUN Guobing, et al. Transfer learning denoising autoencoder-long short term memory for remaining useful life prediction of li-ion batteries[J]. Transactions of China Electrotechnical Society, 2024, 39(1): 289-302.
- [16] 金亮, 闫银刚, 杨庆新, 等. 小样本条件下永磁同步电机深度迁移学习性能预测方法[J]. 电工技术学报, 2023, 38(18): 4921-4931.
- JIN Liang, YAN Yingang, YANG Qingxin, et al. Prediction method of deep transfer learning performance of permanent magnet synchronous motor under the condition of few-shot[J]. Transactions of China Electrotechnical Society, 2023, 38(18): 4921-4931.
- [17] 廖一帆, 武志刚. 基于迁移学习与 Wasserstein 生成对抗网络的静态电压稳定临界样本生成方法[J]. 电网技术, 2021, 45(9): 3722-3728.
- LIAO Yifan, WU Zhigang. Critical sample generation method for static voltage stability based on transfer learning and Wasserstein generative adversarial network[J]. Power System Technology, 2021, 45(9): 3722-3728.
- [18] 杨建平, 向月, 刘俊勇. 面向配电网投资决策的小样本关联规则自适应迁移学习方法[J]. 中国电机工程学报, 2022, 42(16): 5823-5834, 6159.
- YANG Jianping, XIANG Yue, LIU Junyong. Adaptive transfer learning of small sample correlation rules for distribution network investment decision[J]. Proceedings of the CSEE, 2022, 42(16): 5823-5834, 6159.
- [19] 申锦鹏, 杨军, 李蕊, 等. 基于改进域对抗迁移学习的电力系统暂态稳定自适应评估[J]. 电力系统自动化, 2022, 46(23): 67-75.
- SHEN Jinpeng, YANG Jun, LI Rui, et al. Self-adaptive transient stability assessment of power system based on improved domain adversarial transfer learning[J]. Automation of Electric Power Systems, 2022, 46(23): 67-75.

- [20] 周冰钰, 刘博, 王丹, 等. 基于自组织中心 K-means 算法的用户互动用电行为聚类分析[J]. 电力建设, 2019, 40(1): 68-76.  
ZHOU Bingyu, LIU Bo, WANG Dan, et al. Clustering analysis of user power interaction behavior based on self-organizing center K-means algorithm[J]. Electric Power Construction, 2019, 40(1): 68-76.
- [21] 孙隽丰, 李成海, 曹波. 基于 TCN-BiLSTM 的网络安全态势预测[J]. 系统工程与电子技术, 2023, 45(11): 3671-3679.  
SUN Junfeng, LI Chenghai, CAO Bo. Network security situation prediction based on TCN-BiLSTM[J]. Systems Engineering and Electronics, 2023, 45(11): 3671-3679.
- [22] 王东风, 刘婧, 黄宇, 等. 结合太阳辐射量计算与 CNN-LSTM 组合的光伏功率预测方法研究[J]. 太阳能学报, 2024, 45(2): 443-450.  
WANG Dongfeng, LIU Jing, HUANG Yu, et al. Photovoltaic power prediction method combining solar radiation calculation and CNN-LSTM[J]. Acta Energetica Sinica, 2024, 45(2): 443-450.
- [23] 胡宇晗, 朱利鹏, 李佳勇, 等. 融合深度误差反馈学习和注意力机制的短期风电功率预测[J]. 电力系统保护与控制, 2024, 52(4): 100-108.  
HU Yuhang, ZHU Lipeng, LI Jiayong, et al. Short-term wind power forecasting with the integration of a deep error feedback learning and attention mechanism[J]. Power System Protection and Control, 2024, 52(4): 100-108.
- [24] 李龙, 燕旭滕, 张钰声, 等. 采用迁移学习的小样本锂电池荷电状态估算方法[J]. 西安交通大学学报, 2023, 57(11): 142-150.  
LI Long, YAN Xumeng, ZHANG Yusheng, et al. Lithium battery state of charge estimation method based on transfer learning[J]. Journal of Xi'an Jiaotong University, 2023, 57(11): 142-150.
- [25] 鲍光海, 黄逸欣. 基于 ResNeXt 网络和迁移学习的非侵入式负荷监测[J]. 电力系统自动化, 2023, 47(13): 110-120.  
BAO Guanghai, HUANG Yixin. Non-intrusive load monitoring based on ResNeXt network and transfer learning[J]. Automation of Electric Power Systems, 2023, 47(13): 110-120.
- [26] 魏泽涛, 刘友波, 沈晓东, 等. 基于样本数据迁移学习的贫资料地区小水电超短期出力建模及发电预测[J]. 中国电机工程学报, 2023, 43(7): 2652-2666.  
WEI Zetao, LIU Youbo, SHEN Xiaodong, et al. Ultra-short-term power generation modeling and prediction for small hydropower in data-scarce areas based on sample data transfer learning[J]. Proceedings of the CSEE, 2023, 43(7): 2652-2666.
- [27] 范敏, 杨青, 郭祥富, 等. 面向不平衡数据的配电网故障停电预测方法[J]. 电力系统保护与控制, 2023, 51(8): 96-106.  
FAN Min, YANG Qing, GUO Xiangfu, et al. Prediction method of power outage in a distribution network for unbalanced data[J]. Power System Protection and Control, 2023, 51(8): 96-106.
- [28] 王长春, 王果, 赵倩宇, 等. 考虑分时电价和充电利用率特征的大型电动汽车充电站负荷短期预测方法[J]. 南方电网技术, 2024, 18(5): 75-84.  
WANG Changchun, WANG Guo, ZHAO Qianyu, et al. A short-term load forecasting method for large scale electric vehicle charging stations considering characteristics of charging utilization rate and time-of-use electricity price[J]. Southern Power System Technology, 2024, 18(5): 75-84.

收稿日期: 2024-05-18; 修回日期: 2024-12-19

作者简介:

李振华(1986—), 男, 博士, 教授, 主要研究方向为电磁测量与传感、电力设备状态监测技术; E-mail: lizhenhua1993@163.com

张成浩(2000—), 男, 硕士研究生, 主要研究方向为充电站规划与运行分析、电动汽车充电站充电量预测。E-mail: 870947044@qq.com

(编辑 周金梅)