

# 基于云边协同和图神经网络的电动汽车充电站负荷预测方法

邓彬<sup>1</sup>,张宗包<sup>1</sup>,赵文猛<sup>2</sup>,罗新航<sup>3\*</sup>,吴秋伟<sup>3</sup>

(1.深圳供电局有限公司,广东深圳518001;2.南方电网科学研究院,广东广州510663;3.清华大学清华深圳国际研究生院,广东深圳518055)

**摘要:**针对电动汽车充电站预测方法在隐私保护、计算效率和预测精度方面的问题,提出一种基于云边协同和图神经网络的电动汽车充电站负荷预测方法。在云端开发一个基于嵌入的隐私保护模块,通过嵌入变换重构输入数据以预防潜在隐私泄露风险;开发一种基于聚类的图结构表征生成方法,以提供额外时空信息,实现更为精准的预测;基于云端的图结构表征,为客户设计个性化图神经网络预测模型,在保护隐私前提下实现不同地区电动汽车充电站协同训练。在Perth数据集的试验结果表明,模型和基准方法相比具有更高预测精度,本研究提出的云边协同框架能够有效提升基于图神经网络的算法在电动汽车充电站负荷预测任务上的表现。

**关键词:**云边协同;图神经网络;电动汽车充电站;负荷预测

**中图分类号:**TP391 **文献标志码:**A

**引用格式:**邓彬,张宗包,赵文猛,等.基于云边协同和图神经网络的电动汽车充电站负荷预测方法[J].山东大学学报(工学版),2025,55(5):62-69.

DENG Bin, ZHANG Zongbao, ZHAO Wenmeng, et al. Cloud-edge collaborative and graph neural network based load forecasting method for electric vehicle charging stations[J]. Journal of Shandong University (Engineering Science), 2025, 55(5):62-69.

## Cloud-edge collaborative and graph neural network based load forecasting method for electric vehicle charging stations

DENG Bin<sup>1</sup>, ZHANG Zongbao<sup>1</sup>, ZHAO Wenmeng<sup>2</sup>, LUO Xinhang<sup>3\*</sup>, WU Qiuwei<sup>3</sup>

(1. Shenzhen Power Supply Co., Ltd., Shenzhen 518001, Guangdong, China; 2. Electric Power Research Institute, CSG, Guangzhou 510663, Guangdong, China; 3. Tsinghua Shenzhen International Graduate School, Tsinghua University, Shenzhen 518055, Guangdong, China)

**Abstract:** Aiming at the problems of privacy protection, computational efficiency, and predictive accuracy in existing forecasting methods for electric vehicle charging stations, a cloud-edge collaborative and graph neural network based load forecasting approach was proposed. A privacy preserving module based on embedding is developed in the cloud, which reconstructs the input data through embedding transformation to prevent potential privacy leakage risks. A method for generating representation with graph structure based on clustering is proposed to provide additional spatiotemporal information and achieve more accurate forecasting. Personalized graph neural network forecasting models are designed for clients based on cloud's graph structure representation, enabling collaborative training of electric vehicle charging stations in different regions while protecting privacy. Experimental results on the Perth dataset demonstrate that the model outperforms benchmark methods in predictive accuracy and that the cloud-edge collaborative framework proposed in this study significantly enhances the performance of graph neural network algorithms in the task of load forecasting for electric vehicle charging stations.

**Keywords:** cloud-edge collaborative; graph neural network; electric vehicle charging stations; load forecasting

收稿日期:2024-08-28

基金项目:深圳供电局有限公司科技资助项目(SZKJXM20220036)

第一作者简介:邓彬(1989—),男,湖北大冶人,高级工程师,硕士,主要研究方向为电网自动化。E-mail:15219495096@163.com

\*通信作者简介:罗新航(2000—),男,江西乐平人,硕士研究生,主要研究方向为负荷预测。E-mail:1743504495@qq.com

# 0 引言

近年来环境恶化问题引起广泛关注。电动汽车作为新兴能源技术,因可减少化石能源消耗、降低环境污染并增加社会效益而快速普及,产业规模迅速扩张,电动汽车数量激增<sup>[1-2]</sup>。2022年,全球电动汽车销量占汽车总销量14%,2023年增至18%<sup>[3]</sup>。电动车数量快速增长给电网调度和运行带来新挑战,集中充电需求使电网面临额外的负荷压力,波动的充电负荷则会影响电网运行的稳定性和电动汽车充电站(electric vehicle charging station, EVCS)的运行效率。及时准确预测电动汽车充电站负荷对缓解上述问题至关重要。

充电站负荷受天气类型、温度变化、补贴政策、充电起始时刻、充电桩的功率、数量和空间分布等因素影响,充电行为呈现高度随机性和不确定性,负荷数据具有高负荷波动性与非独立同分布特点。传统预测模型受限于单个电站电动汽车充电记录数据不足,难以充分挖掘用户充电模式并准确预测负荷;多个充电站数据联合预测虽可提升预测精度,但涉及到运营商核心数据共享,存在隐私泄露风险,且电站数量增加将加剧云端服务器通信与计算压力。上述问题已成为负荷预测落地的关键瓶颈。

充电站负荷预测模型主要分为基于传统统计方法的模型、基于机器学习的模型和基于深度学习的模型<sup>[4]</sup>。文献[5]用自回归积分移动平均模型预测电力负荷和充电需求,虽通过调整差分和自回归阶数提高预测精度,但统计方法假设时间序列稳定性,本质上只能捕捉线性关系,对非线性负荷数据预测精度低。文献[6]用差分进化算法选择支持向量机(support vector machine, SVM)的参数,预测精度相比标准SVM模型提升1.52%。文献[7]用4种机器学习技术预测两个不同数据集的电动汽车充电负荷。文献[8]结合神经网络提出一种新颖的Q学习算法预测插电式混合动力电动汽车的充电负荷。文献[9]首次构建基于循环神经网络的短期负荷预测模型。文献[10]和[11]分别建立基于长短期记忆神经网络(long short-term memory, LSTM)的短期电动汽车充电需求预测模型和基于门控循环单元(gated recurrent unit, GRU)的电动汽车充电站超短期负荷预测方法,解决了RNN梯度消失和梯度爆炸问题。文献[12]提出使用卷积神经网络(convolutional neural network, CNN)对电动汽车充电负荷进行概率预测。上述方法忽略对充电站拓

扑结构考虑,缺乏捕捉电站负荷空间依赖关系的能力。图神经网络因具备处理复杂网络结构和理解用户行为模式的能力,在电动汽车充电站负荷预测领域被广泛研究。文献[13]在图神经网络模型(graph neural network, GNN)基础上提出一种自适应相关图模型,并与多头注意力机制结合捕捉充电站负荷波动性。文献[14]结合多尺度GNN和LSTM模型在不同时间尺度上捕捉负荷的时空特征,提出一个多尺度时空增强模型(multiscale spatio-temporal enhanced model, MSTEM),预测精度优于多数模型。基于GNN的预测模型虽在预测准确度和鲁棒性上优于多数模型,但面临许多问题:基于GNN的模型需要联合多充电站负荷数据进行分析,会给云端服务器带来巨大计算和通信压力;联合预测时,充电站负荷数据中的用户和运营商隐私信息易受侵犯;实际应用中,数据集通常无图结构信息,无法使用该模型。

针对上述问题,本研究提出一种基于云边协同和图神经网络的电动汽车充电站负荷预测模型(cloud-edge collaborative multiscale spatio-temporal enhanced model, CEC-MSTEM)。首先,云端接收客户端上负荷数据后加密确保数据隐私安全;然后,学习不同充电负荷模式生成图结构特征数据;最后,客户端用该特征信息扩展本地子图并纳入本地模型学习,使用基于图神经网络的负荷预测模型进行训练,直到全局模型收敛。

# 1 方法

本研究所提CEC-MSTEM的总体框架如图1所示。

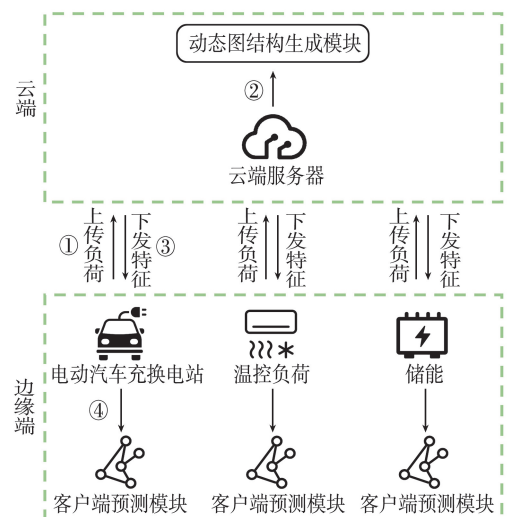


图1 云边协同总体框架

Fig.1 Framework of cloud-edge collaboration

在本框架中,每个电动汽车充电站作为一个本地客户端构成边缘侧,而云端则包含一个受信任中心云服务器。在边缘侧,每个充电站客户端都持有一个本地历史负荷数据集。信息传递过程中,边缘侧首先分别向云端传输本地历史负荷,经云端聚合生成动态图结构表征后,发送回相应客户端用于协同本地图神经网络模型训练。CEC-MSTEM 框架主要包括云端图结构生成模块和客户端聚合预测模块,具体结构如图2所示。

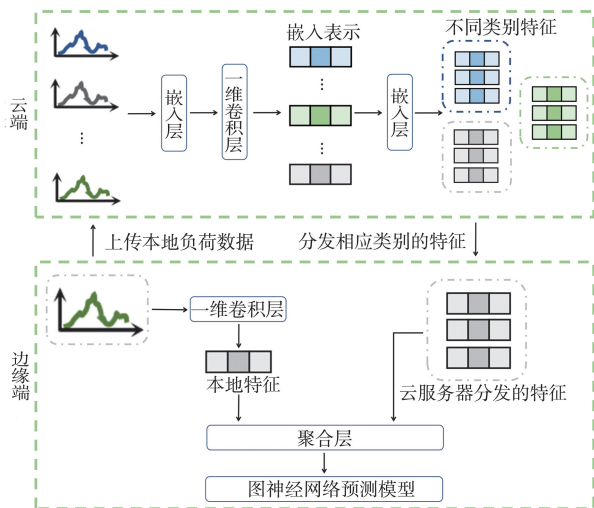


图2 CEC-MSTEM 模型结构  
Fig.2 CEC-MSTEM model structure

云端图结构生成模块主要包括隐私保护模块、特征提取模块和动态图结构表征生成模块。隐私保护模块对各个客户端负荷数据加密以防止潜在隐私泄露风险,特征提取模块提取关键潜在特征,动态图结构表征生成模块生成动态图结构表征用于后续神经网络的学习。客户端聚合预测模块包含一个特征聚合模块和一个预测模块,分别负责聚合云端和本地特征,并训练本地基于图神经网络的预测模型。

CEC-MSTEM 模型预测过程详细步骤如下:

(1)客户端将本地充电站历史负荷数据上传到云端;(2)云端对各个充电站数据进行嵌入加密并提取特征;(3)云端使用提取后的特征生成相应负荷的动态图结构表征并分发给对应充电站客户端;(4)客户端提取本地负荷数据特征,将其与分发特征聚合;(5)客户端使用聚合后的数据训练本地模型进行负荷预测,获得最终的预测结果。

### 1.1 云端图结构数据生成模块

所有电动汽车充电站充电记录构成的集合表示为  $\mathbf{X} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N\}$ ,其中  $N$  为 EVCS 总数。充电

站负荷数据本质上构成一个时间序列,用  $\mathbf{X}_i$  表示第  $i$  个电站历史负荷数据,则  $\mathbf{X}_i = [x_0 \ x_1 \ \dots \ x_t] \in \mathbf{R}^t$ 。各客户端首先将本地负荷数据发送给受信任的云端服务器,云端将其聚合为负荷矩阵  $\mathbf{X} = [\mathbf{X}_1 \ \mathbf{X}_2 \ \dots \ \mathbf{X}_N]$ ,并将充电负荷数据转换为固定长度为  $l$  的时间序列片段  $\mathbf{X}_i = [[x_0, x_1, \dots, x_{l-1}], \dots, [x_{t-l+1}, x_{t-l+2}, \dots, x_t]]$  以匹配预测模型的输入。对于不同客户端数据,若其充电记录总时长不同,则通过截短序列使得其片段数目保持一致。

#### 1.1.1 隐私保护模块

由于负荷数据面临高波动性和异质性消费行为的挑战,单个充电站信息很可能不足以准确预测其负荷,需要通过图结构提供额外空间信息,以捕捉节点之间复杂关系,例如考虑车辆在不同站点之间流动和相互作用。由于联合不同 EVCS 数据库存在隐私泄露的潜在风险,使得模型实际运行时难以实施。因此,云端在获得负荷输入矩阵后,通过嵌入层对其进行加密和重构。对于时间序列形式数据,嵌入层将由两个全连接层组成,其结构如图3所示。




图3 嵌入层结构

Fig.3 Structure of embedding layer

嵌入过程表示为

$$\tilde{\mathbf{X}} = \mathbf{W}_2(\mathbf{W}_1\mathbf{X} + \mathbf{b}_1) + \mathbf{b}_2 \quad (1)$$

式中: $\tilde{\mathbf{X}}$  为经过嵌入层后最终学到的维度与原始输入矩阵  $\mathbf{X}$  相同的嵌入表示矩阵; $\mathbf{X}$  为输入的负荷矩阵; $\mathbf{W}_1 \in \mathbf{R}^{n_{\text{hide}} \times l}$ ,  $\mathbf{W}_2 \in \mathbf{R}^{l \times n_{\text{hide}}}$  为全连接层的权重矩阵,其中  $l$  为序列的长度, $n_{\text{hide}}$  为隐藏层的维度; $\mathbf{b}_1$ 、 $\mathbf{b}_2$  为偏置向量。

嵌入过程首先通过第一个全连接层将原始数据转换为低维向量表示,在保留原始信息情况下提供一定程度上的隐私保护。然后通过第二个全连接层重构数据,使嵌入表示尽可能保留原始特征,再将嵌入表示送入卷积层提取特征。经过嵌入变换后的数据和原始数据的表示完全不同,即使传入其它客户端也能够保护用户隐私安全。同时经嵌

入变换后,模型能够进一步利用变换后数据,提取相似特征并利用全局信息。

隐私保护领域的代表性算法联邦学习算法在处理非独立同分布数据和模型参数通信效率方面面临挑战。由于数据集来自不同类型、不同地区客户端,其数据特征通常是非独立同分布,联邦学习加权聚合梯度信息时,数据集之间相互影响可能会导致训练过程难以收敛,增加通信轮次并限制模型表现。同时,频繁的本地模型更新会导致更大通信压力。

本研究所提方法中的隐私保护模块通过在云端进行数据加密保护隐私,通过生成与原始数据维度相同但不可逆的嵌入表示,使得数据即使在传输或存储过程中被截获,攻击者也无法还原敏感信息。相较联邦学习算法,无需频繁上传本地模型参数或下载全局模型,仅需在初始化阶段传输加密后的嵌入数据,显著降低通信开销。此外,模型确保加密数据在隐藏隐私信息的同时,仍保留原始负荷关键时空特征,为后续分析提供有效输入。

### 1.1.2 特征提取模块

对充电负荷数据的预测依赖于捕捉和识别数据中模式,在得到嵌入表示后,模型使用一维卷积层提取充电信息中特征。一维卷积层是一种常用的专门处理一维序列数据的特征提取方式,其结构如图4所示。




图4 一维卷积层结构

Fig.4 Structure of 1D convolutional layer

在一维卷积层中,通过使用一维卷积核在嵌入表示序列上沿着时间维度进行滑动卷积操作以提取特征。当卷积核在输入序列上滑动时,它会计算与当前位置输入数据片段的点积并生成对应位置上的输出,最终生成特征序列。整个计算过程的表达式为

$$(\mathbf{X}_e * \mathbf{w})[a] = \sum_0^{K-1} \mathbf{X}_e[a-k] \cdot \mathbf{w}[k], \quad (2)$$

式中,  $\mathbf{X}_e$  为嵌入表示矩阵的第  $e$  个嵌入表示序列,  $(\mathbf{X}_e * \mathbf{w})[a]$  为嵌入表示序列和卷积核  $\mathbf{w}$  在输入序

列位置  $a$  上的卷积结果,  $K$  为卷积核大小,  $\mathbf{w}[k]$  为卷积核在位置  $k$  上的权重,  $\mathbf{X}_e[a-k]$  为嵌入序列在位置  $a-k$  上的值。为保证输入和输出序列长度一致,使用填充策略控制输出特征图的大小,填充范围是卷积核大小的一半。

### 1.1.3 动态图结构表征生成模块

动态图结构表征生成模块利用提取的特征来构建动态的图结构负荷特征数据。受空间因素影响,相邻 EVCS 很可能具有相似模式和特征,将特征相似数据组合不仅能增强模型对不同负荷模式识别能力,还能使模型学习到更泛化的特征表示,从而提高预测准确性。对于空间范围较大的充电集群,即便相邻 EVCS 的充电模式差异较大,聚类模块仍可通过捕捉时间和空间维度上充电行为的相似模式,提升模型预测能力。

为识别和区分特征,模型采用  $K$ -Means 聚类算法将特征聚类,并将同一类特征组成对应特征图。不同电动汽车充电站在同一时间段很可能具有不同充电特征,即使对于同一充电站,在不同时间段负荷模式也大相径庭。因此,模型对处于不同时间段的特征序列分别进行聚类并构建动态变化图。聚类具体过程如下。

给定需聚类的某一时间段的特征序列集合  $\mathbf{X} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N\}$ , 其中  $\mathbf{X}_i = [x_u, x_{u+1}, \dots, x_{u+\tau-1}]$  为第  $i$  个电站从  $u$  时刻起长度为  $\tau$  的特征片段。首先,为减少数据尺度差异对聚类效果的影响,需对输入进行  $z$ -score 标准化处理:

$$\mathbf{X}_i^* = \frac{\mathbf{X}_i - \mu}{\sigma}, \quad (3)$$

式中,  $\mathbf{X}_i^*$  为标准化后特征序列,  $\mu$  和  $\sigma$  分别为所有样本特征的均值和标准差。经过标准化处理后,随机选择  $m$  个特征序列  $\mathbf{v}_i (i=1, 2, \dots, m)$  作为初始质心,其中  $m$  是最终聚类数目,由肘部法寻找决定。然后对每个样本分别计算它到每个质心距离,并将其分配给最近质心,以此将数据划分为  $m$  个类别。使用欧几里得距离度量

$$d(\mathbf{X}_i - \mathbf{v}_i) = \|\mathbf{X}_i - \mathbf{v}_i\|_2. \quad (4)$$

对每个类别,计算已分配给它的所有样本的均值,并使用该均值更新质心。比较新旧质心,当质心变化量小于预设阈值或连续多次迭代变化量很小时,则认为算法收敛,此时停止迭代并得到最终聚类划分结果。根据最终聚类结果构建特征图,特征图结构表示为  $\mathbf{G}(\mathbf{V}, \mathbf{E})$ , 其中  $\mathbf{V}$  表示图顶点集,由类别内所有特征序列构成,  $\mathbf{E}$  表示图边集,由连接每两个顶点的边构成。最后,云端根据每个客户端所在类

别,分发其对应特征图数据,与本地客户端数据聚合后进一步进行预测。

#### 1.1.4 损失函数设计

本研究所提框架中嵌入层和特征层参数皆需通过深度学习流程训练获得。为学习一个既能代表充电站历史负荷的表示又能充分刻画不同充电模式之间区别的特征,本研究损失函数主要由重构误差  $L_c$  和聚类损失  $L_r$  两部分组成:

$$L = L_c + L_r. \quad (5)$$

使用均方误差损失作为网络重构损失,以衡量嵌入表示对原始的数据表达能力,即

$$L_c = \frac{1}{n} \sum_{e=1}^n \|Y_e - \hat{Y}_e\|_2, \quad (6)$$

式中,  $Y_e$  为第  $e$  个输入序列,  $\hat{Y}_e$  为经网络重构后序列,  $n$  为序列样本总数。

聚类损失表征是聚类结果与数据内在结构一致性的量化评估,用于衡量聚类效果。动态图结构表征生成模块使用戴维斯-博尔丁指数  $I_{DB}$  作为聚类损失,相较一般聚类模型常用的误差平方和指标,  $I_{DB}$  不仅考虑聚类内部紧密度,还考虑聚类间分离度。  $I_{DB}$  数值越小,表示聚类结果越好。

$$I_{DB} = \frac{1}{m} \sum_{y=1}^m \max_{z \neq y} \frac{\frac{1}{n_y} \sum_{p=1}^{n_y} \|x_{y,p} - c_y\|_2 + \frac{1}{n_z} \sum_{q=1}^{n_z} \|x_{z,q} - c_z\|_2}{\|c_y - c_z\|_2}, \quad (7)$$

式中,  $n_y$  和  $n_z$  分别为第  $y$  类和第  $z$  类中样本总数,  $x_{y,p}$  为第  $y$  个类的第  $p$  个样本,  $x_{z,q}$  为第  $z$  个类的第  $q$  个样本,  $c_y$  和  $c_z$  分别为第  $y$  个类和第  $z$  个类聚类中心。

## 1.2 客户端预测模块

### 1.2.1 特征聚合模块

经过云端对特征提取与聚类后,本地客户端使用云端分发图结构特征数据与本地特征聚合,获得后续本地预测模型输入。在保护隐私前提下,充分整合客户端相似负荷模式并利用图结构提供的空间信息,提升预测精度。

首先使用一维卷积层处理客户端原始负荷数据  $X$ ,提取本地特征  $P$ 。由于提取到的本地特征与云端特征尺度存在差异,不能直接作为输入,需对其进行标准化操作:

$$P^* = \frac{P - \mu'}{\sigma'}, \quad (8)$$

$$Q^* = \frac{Q - \mu'}{\sigma'}, \quad (9)$$

式中,  $P$  为客户端提取的本地特征,  $Q$  为云端下发的

图结构特征数据,  $P^*$  和  $Q^*$  分别为标准化后特征数据,  $\mu'$  为本地和云端特征样本合并后均值,  $\sigma'$  为合并后的标准差。

标准化后模型通过聚合层整合标准化后的本地特征和云端特征,得到最终图结构输入,即

$$G = P^* \oplus Q^*, \quad (10)$$

式中,  $G$  为聚合后特征矩阵,  $\oplus$  为矩阵拼接操作。通过聚合特征数据,可以减少因局部数据异常或不完整而导致的预测偏差,增强模型预测精度和鲁棒性。

### 1.2.2 MSTEM 预测模块

本研究所提框架,通过为数据学习动态图结构表征,可以将非图结构数据转换为适用于基于图神经网络的预测模型的输入。文献[13]提出的多尺度时空增强模型 MSTEM 有效集成了 LSTM 模型和 GCN 模型,以捕获充电站负荷非线性时间依赖性,并充分利用空间信息,通过多尺度融合策略捕获跨不同时间尺度的图结构动态,使模型在不同时间尺度上准确识别复杂负荷模式。因此本研究在聚合特征后,引入 MSTEM 模型对本地充电站负荷进行预测。由于 MSTEM 模型结构复杂,需要大量计算资源,使用本研究框架可以有效保护隐私并缓解云端计算压力,减少通信延迟。MSTEM 模型结构如图 5 所示。

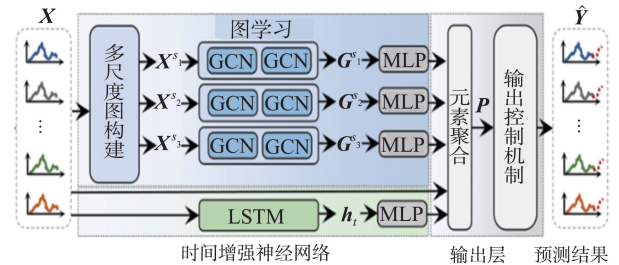


图5 MSTEM 模型结构

Fig.5 Structure of MSTEM

MSTEM 分别使用多尺度图学习模块和时间增强神经网络模块捕获输入数据的特征,再融合两个模块结果得到最终预测输出。在多尺度图学习模块中,将负荷数据  $X$  划分为不同尺度:

$$X^s = S(X, s), \quad \forall s \in S, \quad (11)$$

式中,  $X^s$  为某种尺度的负荷输入,  $s$  为尺度集合  $S$  内元素,函数  $S(\cdot)$  为以  $s$  为间隔对输入数据进行采样。对每个缩放尺度的输入执行图卷积:

$$H^s = \sigma(B(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} X^s W_1^s)), \quad (12)$$

$$R^s = D(H^s; p), \quad (13)$$

$$G^s = \tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} R^s W_2^s, \quad (14)$$

式中,  $H^s$  和  $G^s$  分别为尺度  $s$  上的隐藏表示和最终表

示,  $\tilde{\mathbf{A}}$  为包含自环的邻接矩阵,  $\tilde{\mathbf{D}}$  为度矩阵,  $\mathbf{W}_1^s, \mathbf{W}_2^s$  为权重矩阵,  $\sigma(\cdot)$  表示 ReLU 激活函数,  $D(\cdot)$  为 Dropout 层,  $p$  为 Dropout 比例,  $B(\cdot)$  表示 batch 归一化层。通过元素加法整合得到输出  $\mathbf{G}^{\text{out}}$ :

$$\mathbf{G}^{\text{out}} = \sum_{s \in S} \mathbf{G}^s \mathbf{W}_L^s, \quad (15)$$

式中  $\mathbf{W}_L^s$  为权重矩阵。

在时间增强神经网络模块中,集成 LSTM 单元以增强模型捕获长期时间依赖关系的能力:

$$\mathbf{f}_t = \sigma(\mathbf{W}_f^l \cdot [\mathbf{h}_{t-1}, x_t] + \mathbf{b}_f^l), \quad (16)$$

$$\mathbf{r}_t = \sigma(\mathbf{W}_r^l \cdot [\mathbf{h}_{t-1}, x_t] + \mathbf{b}_r^l), \quad (17)$$

$$\tilde{\mathbf{c}}_t = \tanh(\mathbf{W}_c^l \cdot [\mathbf{h}_{t-1}, x_t] + \mathbf{b}_c^l), \quad (18)$$

$$\mathbf{c}_t = \mathbf{f}_t * \mathbf{c}_{t-1} + \mathbf{r}_t * \tilde{\mathbf{c}}_t, \quad (19)$$

$$\mathbf{o}_t = \sigma(\mathbf{W}_o^l \cdot [\mathbf{h}_{t-1}, x_t] + \mathbf{b}_o^l), \quad (20)$$

$$\mathbf{h}_t = \mathbf{o}_t * \tanh(\mathbf{c}_t), \quad (21)$$

式中  $\mathbf{f}_t, \mathbf{r}_t$  和  $\mathbf{o}_t$  分别为遗忘门、输入门和输出门的输出,  $\tilde{\mathbf{c}}_t$  和  $\mathbf{c}_t$  分别为候选和更新后细胞状态,  $x_t$  为  $t$  时刻充电负荷值,  $\mathbf{h}_t$  为已更新隐藏状态,  $\mathbf{W}_f^l, \mathbf{W}_r^l, \mathbf{W}_c^l, \mathbf{W}_o^l$  为权重,  $\mathbf{b}_f^l, \mathbf{b}_r^l, \mathbf{b}_c^l, \mathbf{b}_o^l$  为偏置项。

此外,模型集成一个残余融合机制,以保持原始时间序列信号完整性。最后, MSTEM 输出层结合多尺度图学习和时间增强神经网络模块的输出生成预测结果,即

$$\mathbf{L}^{\text{out}} = \tilde{\mathbf{X}}^\eta + (\mathbf{X} \mathbf{W}^{\text{lo}}), \quad (22)$$

$$\mathbf{Z} = (\mathbf{W}_1^{\text{out}} \mathbf{G}^{\text{out}}) + (\mathbf{W}_2^{\text{out}} \mathbf{h}_t) + \mathbf{L}^{\text{out}}, \quad (23)$$

式中:  $\mathbf{L}^{\text{out}}$  为残余融合机制的输出;  $\tilde{\mathbf{X}}^\eta$  为从过去  $\eta$  时间步长中捕获的历史负荷序列;  $\mathbf{W}^{\text{lo}}, \mathbf{W}_1^{\text{out}}$  和  $\mathbf{W}_2^{\text{out}}$  均为权重矩阵,  $\mathbf{W}^{\text{lo}}$  用于调整  $\mathbf{X}$  的维度使其与期望的输出形状相匹配,  $\mathbf{W}_1^{\text{out}}, \mathbf{W}_2^{\text{out}}$  用于对不同模块的输出进行线性转换;  $\mathbf{Z}$  为最终负荷预测结果,为贴合实际情况,模型会根据预定义阈值将  $\mathbf{Z}$  中过低预测值修改为 0。

## 2 试验与结果分析

### 2.1 数据集

本研究使用英国 Perth 电动汽车充电站负荷数据集进行负荷预测试验。数据分 3 个时段获取: 2016 年 9 月 1 日至 2017 年 8 月 31 日, 2017 年 9 月 1 日至 2018 年 8 月 31 日, 2018 年 9 月 1 日至 2019 年 8 月 31 日。数据集特征包含充电事件起止时间及充电负荷,按充电设备类型分为快速和慢速充电数据集。快速充电数据集由 13 个站点组成,快速充

电桩输出功率为 22 kW。慢速充电数据集由 3 个站点组成,输出功率为 7 kW。为满足超短期负荷预测需求,将原始数据转换为以小时为间隔的平均负荷序列,快速数据集各站点有 34 313 个数据点,慢速数据集各站点有 34 306 个数据点。为保证对比公平,统一设置数据集,将数据集的 70% 用于训练集, 20% 用于验证集, 10% 用于测试集。超短期预测训练数据用大小为 24、移动步长为 1 的滑动窗口获取。输入变量由单个 EVCS 在当前时间段之前 24 个时间段的历史负荷值构成,即一次预测最大提前时间为 24 小时,输出对应 EVCS 未来 6 个时间段的预测负荷值。

### 2.2 模型设置

试验在配备 NVIDIA GeForce RTX 3080Ti GPU, 2.40GHz Intel Xeon Silver 4214R CPU 的服务器上,使用 Pytorch 深度学习框架实现。云端模型中,基于嵌入的隐私保护模块由两个隐藏层大小为 32 的全连接层构成。特征提取模块由步长为 1,卷积核大小为 9 的一维卷积层构成。动态图结构表征生成模块中,快速充电集聚类数设置为 4,慢速充电集聚类数设置为 2。客户端预测模型训练时,以均方误差  $E_{\text{MS}}$  为损失函数,学习率设为 0.01,批次大小为 32,使用 Adam 优化器。每个充电站分别训练 100 个训练周期。

### 2.3 基准方法

为评估 CEC-MSTEM 模型性能,与时间序列预测任务中的 LSTM<sup>[15]</sup>、门控循环单元(gated recurrent unit, GRU)<sup>[16]</sup>、DLinear<sup>[17]</sup>、图卷积神经网络(graph convolutional network, GCN)<sup>[18]</sup>、时空图卷积神经网络(spatio-temporal graph convolutional network, STGCN)<sup>[4]</sup>、MSTEM<sup>[13]</sup> 这 6 个经典基准模型在相同试验条件下进行对比分析。

### 2.4 评估指标

采用平均绝对误差  $E_{\text{MA}}$ 、均方根误差  $E_{\text{RMS}}$ 、 $E_{\text{MS}}$ 、相对平均误差  $E_{\text{RA}}$  和相对均方误差  $E_{\text{RA}}$  5 个评价指标对上述 7 个模型在充电负荷预测中的性能进行评价。评价指标具体定义如下:

$$E_{\text{MA}} = \frac{1}{n} \sum_{e=1}^n \|Y_e - \hat{Y}_e\|_1, \quad (24)$$

$$E_{\text{RMS}} = \sqrt{\frac{1}{n} \sum_{e=1}^n \|Y_e - \hat{Y}_e\|_2^2}, \quad (25)$$

$$E_{\text{RA}} = \frac{\sum_{e=1}^n \|Y_e - \hat{Y}_e\|_1}{\sum_{e=1}^n \|Y_e - \bar{Y}_e\|_1}, \quad (26)$$

$$E_{RS} = \frac{\sum_{e=1}^n \|Y_e - \hat{Y}_e\|_2^2}{\sum_{e=1}^n \|Y_e - \bar{Y}_e\|_2^2}, \quad (27)$$

式中,  $n$  为样本总数,  $Y_e$  为真实值,  $\hat{Y}_e$  为预测值,  $\bar{Y}_e$  为预测值的平均值。

## 2.5 试验结果和分析

### 2.5.1 对比试验结果和分析

表 1、2 分别列出 7 个模型在慢速和快速充电数据集上的预测误差结果, 加粗数字表示最优结果, 下划线数字表示次优结果。

表 1 慢速充电集上模型的预测误差

Table 1 The prediction error of model on slow dataset

方法	$E_{MA}/$ kWh	$E_{RMS}/$ (kWh) $^{\frac{1}{2}}$	$E_{MS}/$ (kWh) $^2$	$E_{RA}/\%$	$E_{RS}/\%$
LSTM	0.435	1.569	2.462	0.764	1.040
GRU	0.436	1.569	2.462	0.765	1.040
DLinear	<u>0.386</u>	<u>1.393</u>	<b>1.940</b>	<u>0.719</u>	<u>0.923</u>
GCN	0.435	1.570	2.464	0.764	1.040
STGCN	0.468	1.565	2.448	0.792	1.036
MSTEM	0.393	1.435	2.059	0.725	0.951
CEC-MSTEM	<b>0.380</b>	<b>1.007</b>	<u>1.962</u>	<b>0.489</b>	<b>0.628</b>

表 2 快速充电集上模型的预测误差

Table 2 The prediction error of model on fast dataset

方法	$E_{MA}/$ kWh	$E_{RMS}/$ (kWh) $^{\frac{1}{2}}$	$E_{MS}/$ (kWh) $^2$	$E_{RA}/\%$	$E_{RS}/\%$
LSTM	2.114	6.211	38.571	0.791	1.062
GRU	2.102	6.151	37.840	0.789	1.052
DLinear	1.916	5.335	28.458	0.753	0.912
GCN	2.116	6.214	38.608	0.791	1.063
STGCN	2.244	6.110	37.335	0.814	1.045
MSTEM	<u>1.898</u>	<u>5.206</u>	<u>27.099</u>	<u>0.749</u>	<b>0.890</b>
CEC-MSTEM	<b>1.856</b>	<b>4.444</b>	<b>26.650</b>	<b>0.733</b>	<u>0.945</u>

由表 1 可知, 慢速充电集试验中, CEC-MSTEM 在  $E_{MA}$ 、 $E_{RMS}$ 、 $E_{RA}$  和  $E_{RS}$  指标上表现最佳, 较次优 DLinear 模型分别降低 1.5%、27.7%、32.0%、31.9%。CEC-MSTEM 在  $E_{MS}$  指标上和最优结果相差 1.1%。由表 2 可知, 快速充电集试验中, CEC-MSTEM 在  $E_{MA}$ 、 $E_{RMS}$ 、 $E_{MS}$  和  $E_{RA}$  上取得最优结果, 较次优 MSTEM 分别降低 2.2%、14.6%、1.7%、2.1%。而在  $E_{RS}$  指标上, CEC-MSTEM 模型取得次优结果, 和最优结果相差 5.8%。LSTM 和 GRU 模型表现相近, 可能因它们同为 RNN 变体且结构相似。MSTEM 结合时空特征优势, 性能优于 LSTM 和 GCN。

根据试验结果, 对单个电动汽车充电站负荷预测, 模型每个训练周期平均耗时 14.43 s, 训练完成后平均推理仅需 0.98 s, 该算法能在实时预测负荷

的同时保证较高预测准确率。

### 2.5.2 云边协同框架的对预测性能增益试验

为验证本研究提云边协同框架对基于图神经网络的预测模型性能影响, 在相同试验数据下, 对比单独使用图神经网络和使用云边协同框架后的预测表现。通过计算机仿真模拟云边协同环境, 建立一个图结构生成模块, 模拟云端处理全局 EVCS 负荷数据及动态图结构数据生成过程, 并且模拟云端下发特征过程, 利用生成的图结构数据分别建立多个图神经网络模型以模拟边缘侧本地训练和预测过程。在慢速和快速充电数据集上的对比结果分别如表 3 和 4 所示, 其中带 CEC-前缀的模型表示使用本研究提云边协同框架。

表 3 慢速充电集上模型的对比结果

Table 3 The comparison of model results on slow dataset

方法	$E_{MA}/$ kWh	$E_{RMS}/$ (kWh) $^{\frac{1}{2}}$	$E_{MS}/$ (kWh) $^2$	$E_{RA}/\%$	$E_{RS}/\%$
GCN	0.435	1.570	2.464	0.764	1.040
CEC-GCN	<b>0.398</b>	<b>0.991</b>	<b>1.839</b>	<b>0.509</b>	<b>0.635</b>
STGCN	<b>0.468</b>	1.565	2.448	0.792	1.036
CEC-STGCN	0.497	<b>1.116</b>	<b>2.361</b>	<b>0.574</b>	<b>0.709</b>
MSTEM	0.393	1.435	2.059	0.725	0.951
CEC-MSTEM	<b>0.380</b>	<b>1.007</b>	<b>1.962</b>	<b>0.489</b>	<b>0.628</b>

表 4 快速充电集上模型的对比结果

Table 4 The comparison of model results on fast dataset

方法	$E_{MA}/$ kWh	$E_{RMS}/$ (kWh) $^{\frac{1}{2}}$	$E_{MS}/$ (kWh) $^2$	$E_{RA}/\%$	$E_{RS}/\%$
GCN	2.116	6.214	38.608	0.791	1.063
CEC-GCN	<b>1.889</b>	<b>4.509</b>	<b>27.673</b>	<b>0.722</b>	<b>0.931</b>
STGCN	<b>2.244</b>	6.110	37.335	<b>0.814</b>	1.045
CEC-STGCN	2.709	<b>4.773</b>	<b>32.838</b>	0.841	<b>0.956</b>
MSTEM	1.898	5.206	27.099	0.749	<b>0.890</b>
CEC-MSTEM	<b>1.856</b>	<b>4.444</b>	<b>26.650</b>	<b>0.733</b>	0.945

从表 3 和 4 结果可知, 与其他 2 种算法相比, 本研究选取的 MSTEM 算法使用云边协同框架后预测精度最高, 且在 5 个误差指标上性能普遍更优。未采用该框架的方法存在数据隐私泄露风险、面临计算资源限制, 还因缺乏与其它 EVCS 负荷数据的协同训练, 预测准确度不如引入云边协同后的模型。

## 3 结论

本研究针对电动汽车充电站的短期负荷预测问题, 提出一种基于云边协同和图神经网络的深度学习算法。CEC-MSTEM 模型在保护用户隐私前提下, 通过云边协同的方式联合不同 EVCS 负荷数

据并学习动态图结构表征,充分挖掘空间信息,从而有效提升预测精度并减少云端服务器计算压力。在真实世界数据集上的试验证明,CEC-MSTEM模型的预测精度优于现有先进预测方法。

#### 参考文献:

- [1] 杨挺,覃小兵,冯相为,等.计及用户充电行为与隐私保护的联邦学习电动汽车短期充电负荷预测[J].高电压技术,2024,50(10):4512-4519.  
YANG Ting, QIN Xiaobing, FENG Xiangwei, et al. Short-term charging load prediction of federated learning electric vehicles after accounting for user charging behavior and privacy protection [J]. High Voltage Engineering, 2024, 50(10): 4512-4519.
- [2] ZHANG C, SHEN H T, TAO P, et al. Electric vehicle charging pile capacity planning based on normal distribution Monte Carlo sampling model [J]. International Journal of Emerging Electric Power Systems, 2024, 25(2): 189-196.
- [3] IEA. Global EV Outlook 2024 [R/OL]. (2024-04-23) [2024-05-17]. <http://www.iea.org/reports/global-ev-outlook-2024>
- [4] KIM H J, KIM M K. Spatial-Temporal graph convolutional-based recurrent network for electric vehicle charging stations demand forecasting in energy market[J]. IEEE Transactions on Smart Grid, 2024, 15(4):3979-3993.
- [5] AMINI M H, KARGARIAN A, KARABASOGLU O. ARIMA-based decoupled time series forecasting of electric vehicle charging demand for stochastic power system operation[J]. Electric Power Systems Research, 2016, 140:378-390.
- [6] XU X B, LIU W X, ZHOU X, et al. Short-term load forecasting for the electric bus station based on GRA-DE-SVR[C]// Proceedings of 2014 IEEE Innovative Smart Grid Technologies-Asia (ISGT ASIA). Kuala Lumpur, Malaysia:IEEE,2014:388-393.
- [7] MAJIDPOUR M, QIU C, CHU P, et al. Forecasting the EV charging load based on customer profile or station measurement? [J]. Applied Energy, 2016, 163: 134-141.
- [8] DABBAGHJAMANESH M, MOEINI A, KAVOUSI-FARD A. Reinforcement learning-based load forecasting of electric vehicle charging station using  $Q$ -learning technique[J]. IEEE Transactions on Industrial Informatics, 2020, 17(6): 4229-4237.
- [9] VERMAAK J, BOTHA E C. Recurrent neural networks for short-term load forecasting[J]. IEEE Transactions on Power Systems, 1998, 13(1): 126-132.
- [10] WANG S Y, ZHUGE C X, SHAO C F, et al. Short-term electric vehicle charging demand prediction: a deep learning approach [J]. Applied Energy, 2023, 340: 121032.
- [11] 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.  
SHI Liguang, LI Yanzhen, LIU Jiyan, et al. An Improved GRU method for ultra-short-term charging load forecasting at electric vehicle charging stations [J]. Distribution & Utilization, 2023, 40(6): 42-47.
- [12] ZHANG X, CHAN K W, LI H R, et al. Deep-learning-based probabilistic forecasting of electric vehicle charging load with a novel queuing model[J]. IEEE Transactions on Cybernetics, 2020, 51(6):3157-3170.
- [13] 张延宇,张智铭,刘春阳,等.基于动态自适应图神经网络的电动汽车充电负荷预测[J].电力系统自动化, 2024,48(7):86-93.  
ZHANG Yanyu, ZHANG Zhiming, LIU Chunyang, et al. Electric vehicle charging load prediction based on dynamic adaptive graph neural network[J]. Automation of Electric Power Systems, 2024, 48(7): 86-93.
- [14] ZHANG Z B, HAO J, ZHAO W M, et al. Multiscale spatio-temporal enhanced short-term load forecasting of electric vehicle charging stations[C]// Proceedings of the 6th Asia Energy and Electrical Engineering Symposium (AEEES). Chengdu, China:IEEE, 2024: 1180-1185.
- [15] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [16] WANG Y X, LIU M Q, BAO Z J, et al. Short-term load forecasting with multi-source data using gated recurrent unit neural networks[J]. Energies, 2018, 11(5):1138, 2018.
- [17] ZENG A L, CHEN M X, ZHANG L, et al. Are transformers effective for time series forecasting? [C]// Proceedings of the AAAI conference on artificial intelligence. Washington, D. C., USA: AAAI, 2023: 11121-11128.
- [18] SHI J K, ZHANG W G, BAO Y, et al. Load forecasting of electric vehicle charging stations: attention based spatiotemporal multi-graph convolutional networks [J]. IEEE Transactions on Smart Grid, 2023, 15(3): 3016-3027.

(编辑:管昕昉)