

基于双层可信联邦学习的电动汽车能量需求预测

岳高峰, 韩迪*, 陈嘉鑫, 王莎

(自动化工程学院, 西安航空职业技术学院, 西安 710089)

摘要: 电动汽车充电需求的准确预测对缓解电网压力至关重要。针对现有预测方法在处理非独立同分布数据时收敛慢、易受不可靠节点影响的问题, 本文提出一种双层可信联邦学习 (Double-Layer Credible Federated Learning, DCFL) 能量需求预测策略。该方法利用启发式关联规则自动挖掘充电信息, 无需额外数据采集; 通过权值损失变化筛选良性本地因子以加速收敛并抵御不可靠节点干扰; 引入多通道注意力机制设计损失函数与加权聚合方式。实验结果表明, 相比传统联邦学习方法, 本方法训练时间减少 71%, 收敛速度提升 17.6%, 在预测准确度和收敛效率方面均有显著优势。

关键词: 能量预测; 启发式关联规则; 电动汽车网络; 隐私保护; 多通道注意力机制

文献标志码: A

doi: 10.11959/j.issn.2096-3750.

Electric Vehicle Energy Demand Prediction Based on Double-Layer Credible Federated Learning

YUE Gaofeng, Han Di*, Chen Jiabin, Wang Sha

School of Automation Engineering, Xi'an Aeronautical Polytechnic Institute, Xi'an 710089, China

Abstract: Accurate prediction of electric vehicle charging demand is crucial for alleviating pressure on the power grid. To address the issues of slow convergence and vulnerability to unreliable nodes in existing prediction methods when processing non-independently and identically distributed (non-IID) data, this paper proposes a Double-Layer Credible Federated Learning (DCFL) strategy for energy demand prediction. The proposed method employs heuristic association rules to automatically mine charging information without requiring additional data collection. It selects benign local updates based on weight loss variation to accelerate convergence and resist interference from unreliable nodes. Furthermore, a multi-channel attention mechanism is introduced to design the loss function and the weighted aggregation scheme of federated learning. Experimental results demonstrate that, compared with traditional federated learning methods, the proposed method reduces training time by 71% and increases convergence speed by 17.6%, showing significant advantages in both prediction accuracy and convergence efficiency.

Key words: energy prediction, heuristic correlation rules, electric vehicles networks, privacy protection, multi-channel attention mechanism

0 引言

伴随着城市公共交通的电气化, 供电系统正面临着越来越严峻的压力^[1]。电动汽车 (Electric Ve-

hicles, EVs) 的快速扩张对电力供应造成了前所未有的挑战。充电服务提供商 (Charging Stations Providers, CSP)、充电站 (Charging Stations, CSs) 与电动汽车之间的能源协调被视为缓解供电

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 韩迪, 女, 2000年6月生, 助教, 硕士学位, 主要研究方向机器学习与隐私保护, Email: 1906720630@qq.com。

基金项目: 校级自然科学基金 (编号: 25XHZZK-13、25XHZQ-054) 支持。

Foundation Items: Fund Project: Supported by school level Natural Science Foundation (No.: 25XHZZK-13, 25XHZQ-054).

压力的有效途径^[2]，而准确预测电动汽车的能量需求是实现这一目标的基础。

近年来，为了实现对电动汽车的精确能量需求预测，人们提出了许多工作。许多学者使用统计模型或机器学习技术来描述直接从电动汽车上收集的充电行为数据^[3-4]。文献[5-7]形成了较为全面的智能化的预测方法。通过考虑电力消费者的行为特征，或者使用一种数据驱动的方法来进行未来的充电需求预测，主要依靠数据分析技术^[8]和简单神经网络预测技术^[9]，这些方法的引入提高了充电需求预测的准确度，成为了规模化电动汽车能量预测的先锋，主要面向电动汽车使用者或者充电站。随着机器学习的快速发展，基于机器学习的一些方法被引入到能量预测中^[10]，这类方法的特点是具有实用性并且也拥有较高的准确性^[11-12]。文献[13][14]使用了机器学习中的方法比如强化学习、卷积神经网络(Convolutional Neural Network, CNN)和长短期记忆网络(Long Short Term Memory, LSTM)，通过提取数据模式或特征来预测电动汽车或充电站的能量需求。其中，文献[13]采用CNN-BiLSTM网络预测高速公路充电站的交通流与充电负荷，并结合多智能体深度强化学习实现充电站的优化调度；文献[14]将注意力机制与LSTM、GRU等深度学习方法相结合，用于公共充电站的负荷预测与能量管理。这些方法继承了神经网络自动特征提取能力和机器学习所具有的记忆能力，可以处理大型的一些多维度数据，最大的优势在于其具有较高的准确性。

然而，这些方法属于早期对能量需求预测的探测，算法处理时间消耗较少，具有一定的理论借鉴，实际的可应用性较低。一方面，随着智慧城市建设的需要，人们对预测精度有了较高要求，这些方法很难再满足，并且无法适用于大规模的城市电动车网络，不是全面的系统层次的预测方法。另一方面随着个体隐私保护意识的加强，这些方法的缺点也显现出来，这些方法是基于公开数据集的能量预测方法，没有考虑用户数据隐私保护的问题，在实际应用中是不可以采用的。

联邦学习(Federated learning, FL)由谷歌于2016年首次提出，旨在解决分布式移动数据集的机器学习的隐私问题^[15]。联邦学习将安全技术和机器学习技术相结合，具有保护用户隐私的天然优势，广泛应用在各个领域^[16-17]。文献[18-21]提供了基于

联邦学习的电动汽车能量消耗估计方案。通过每个车辆的预测而形成服务器端的预测，该方案考虑了客户隐私的问题，具备了智能共享、安全共享的优势。这些方法通过异常检测机制和共享机制保障了模型学习的可靠性，是目前形成的最具创新的电动汽车能量预测方法。但是，缺点是这些方法仅考虑单方面电动汽车或者单方面充电站的能量需求预测，这种结果可参考性具有一定局限性，无法做成城市级别的区域能量预测调度，也无法对充电汽车进行合理的建议。电动汽车、充电站、充电站提供商更多的是一个生态系统。不管是经典神经网络方法还是基于隐私保护的联邦学习方法，这些方法存在的共同点是没有形成电动汽车、充电站、充电站服务商之间的系统性。

针对上述问题，本文的主要贡献总结如下：

首先本文对数据进行了严格分析。通过分析得到数据呈现非独立同分布(Non-independent identical distribution, Non-IID)的特性^[22-24]。针对这种数据集，本文对电动汽车轨迹与能源消耗进行关联分析，同时对电动汽车充电行为以及充电站特性的进行了分析，得到电动汽车充电位置选择的影响因素和充电站特性因素，为本文高精度预测方法提供基础和思路。

为了解决隐私问题，本文采用联邦学习的方法进行能量预测。区别于现有方法被动接收所有节点更新，本文首次提出基于“权值损失变化”的启发式节点筛选策略，主动识别并过滤掉可能降低模型性能的“不可信”节点(如数据分布极偏或恶意节点)，这在电动汽车充电行为高度异构的场景下是保障模型收敛的关键。

本文将双层架构严格对应“电动汽车→充电站(第一层)”和“充电站→服务商(第二层)”的真实物理逻辑，解决了传统方法无法实现系统级(同时覆盖EV, CS, CSP)预测的痛点。不同于传统联邦平均，本文在两层聚合中分别引入了统计-距离联合注意力和地理-竞争联合注意力，使模型能动态关注更重要的本地更新和充电站间关联，这与电动汽车充电选择受“历史偏好”和“实时位置”共同驱动的实际规律高度吻合。

最后本文基于某市电动汽车三个月的数据进行分析，利用Spark大数据计算引擎完成整个算法的数据分析和实验验证，实验证明模型准确度以及

模型收敛速度有了明显提升。下图为某市充电站分布图。



图1 某市充电站分布图
Fig.1 CSs distributed in a city

论文其余部分结构如下：第一节为相关工作总结；第二节进行数据分析；第三节说明方法框架；第四节和第五节详述启发式关联规则与双层可信联邦学习的原理及步骤；第六节讨论性能评估；第七节得出结论。

1 相关工作

在电动汽车这一方面的能量预测引发了很多学者的研究。Mostafa 等人^[5]提出了一种使用KNN的手机应用算法，该算法已经在加州大学洛杉矶分校(UCLA)的电动汽车充电站实现了能源消耗预测，提出的时间加权点积(TWDP)算法提高了准确性和减少了处理时间；Rassaei 等人^[6]提出了一个基于随机过程的电动车非协调充电能量需求模型，以描述其预期的每日能量需求概况。文章将出发时间作为另一个随机变量纳入该模型，并引入自主需求响应(DR)技术来管理电动汽车的充电需求，实现了单个电动汽车的能量需求预测；Feng 等人^[7]本文提出了一种基于能量需求预测和路线预览的插电式混合动力电动汽车的监督控制策略。通过建立一个复杂网络模型来预测车辆的能量需求，它将完整的交通数据简化为几个统计参数，这有助于简化预测过程。Linas 等人^[13]基于能量使用的可变性，提出了概率估计和深度学习相混合的预测方法。深入探索了一套从GPS轨迹数据中学习电动汽车能源消耗的深度学习预测模型，并在两个不同的真实的电动汽车轨迹数据集上对模型进行测试，这种方法的实用性较好，可以在单个电动汽车上广泛推广。Banda 等人^[14]于2021年针对有限标签数据所产生的

拟合不足问题进行了研究，提出了CNN-LSTM的方法，用于基于时间序列的迁移学习，并与最原始的CNN模型进行了性能比较，这种方法继承了CNN自动特征提取能力和LSTM的记忆能力，文章采用三个电动汽车的数据集进行了相关测试。不过以上这些方法普遍存在的问题就是没有将隐私保护问题考虑进去，并且由于电动汽车的移动属性，其充电行为未必跟随充电站变化，这导致所做的能量预测具有一定的时间有效性，在一定时期内能够提供一定参考。

Zhang 等人在文献[18]中首次实现了联邦学习与电动汽车能耗估算相结合的方法。进行了基于真实世界数据的数值实验，以验证模型在异质数据分布下的预测性能，该方法在安全性方面有了很大提升。Saputra 等人在文献[19]于2019提出了一种基于联邦能量需求学习(Federal Energy Demand Learning, FEDL)的预测解决方案，其中充电站服务商从所有充电站收集信息，该方法建立了充电站服务商和充电站之间的联系；文献[20]于2021年提出了集群技术和联邦学习想融合的能量预测方法，其主要目的是加快模型的收敛速度，采用联邦学习代替集中培训；文献[21]提出基于边缘计算和联邦学习混合的需求预测结构。数据在边缘端进行存储并使用梯度信息修正全局模型，而返回的模型将会提升边缘结构的预测能力，一定程度上这种方法保护了用户隐私并提升精度。现有FEDL等方法虽保护了隐私，但均采用单层架构，无法同时输出EV、CS和CSP三方的能量预测值，导致其在实际城市能源调度系统中应用受限。针对此，本文提出双层架构基于双层可信联邦学习的电动汽车能量需求预测。

2 数据集分析

2.1 数据集描述

与传统基于充电站的能量预测不同，本文致力于能量使用者电动汽车端的分析。在这里本文简单介绍使用到的数据集。本文分析统计了某市电动汽车(约1.6万辆)连续三个月的行驶数据，由某市交通委员会收集，记录了电动汽车的经纬度、时间、速度、以及所属公司，记录时间为2019年1月1日至3月31日，时间戳间隔为30秒，每日数据量约为4GB，总量约为360GB，大数据计算引擎为Apache Spark。数据异常值处理：剔除经纬度超出

某市行政区域范围、速度为负值的记录。缺失值处理：对于时间戳间隔不等于 30 秒的缺失片段，采用线性插值方法填补经纬度和速度。对于连续缺失超过 5 分钟（10 个点）的片段，直接删除该段轨迹。重复值去重：删除所有字段完全相同的重复记录。

2.2 动机和结果

作为电力能量的直接使用者，本文知道电动汽车其充电位置的选择受到多方面的影响，例如个人喜好、充电站地理位置、电动汽车活动位置等。本文进行大量数据的分析以便设计出较好的能量预测方法，主要需要解决的有以下几个方面。

(1) 充电行为高度 Non-IID。为了方便后续预测方法的设计，本文分析和观察随机两周时间下三辆电动汽车实际充电行为的分布情况，结果如图 2 (a) 所示。此外，实验测量了电动汽车在三个月内充电时间的平均值和标准差。图 3 (a) -图 3 (b)

展示了测量结果。可以看到，虽然超过 80% 的平均充电时间短于 1 小时，但其余的充电时间在 1 小时到 2.4 小时之间变化很大。虽然对于大约 80% 的电动汽车来说，其充电持续时间的标准差值几乎为 0.1，但其他电动汽车的充电持续时间的标准差值在 0.1 小时到 1.2 小时之间相差很大。

本文会发现不同电动汽车在相同时间段内的充电选择的分布是不同的，但是相同时间相同车辆的充电选择分布也是差异较大，相同时间相同充电站电动汽车的选择更是呈现不同分布。因此，这个数据集在时间和空间上具有不同的分布性质，这导致本文的能量消耗数据是典型的 Non-IID 数据。针对这种情况，传统的联邦学习方法(如联邦平均法)的适用性下降，原因在于数据的异质性对模型的收敛增加了一定的阻力。在第 5 节中，本文将详细说明如何处理具有 Non-IID 充电行为的电动汽车数据集并进行联邦学习训练。




图 2 所有电动汽车充电时间的 Non-IID 性

Fig. 2 Non IID of charging time of all electric vehicles

(2) 电动汽车充电行为分析。本文猜想电动汽车司机对某个指定的充电站会不会有依赖性的喜好存在，比如其充值了会员卡等原因。本文统计一定时期内电动汽车和充电站形成关联 (EV-CS) 的频数概率，如图 3。电动汽车选择某个充电站的平均概率仅为 0.115，大于均值概率的部分就可以认为电动汽车和充电站存在关联关系。通过 CDF 曲线可以看到存在关联的比例为 84.7% ((1-0.156) × 100%)。这个分析结果证明了绝大部分电动汽车由于某些因素会高频次地选择某个充电站。

同时，本文绘制了每个充电站附近电动汽车停留点的数量和选择该充电站充电的数量之差并进行质量分析，结果如图 4 所示。四分位数、中位数和均值的同步性说明很多车是因为在充电站附近停留

而选择该充电站去充电，这也揭示为什么每个充电站的充电数量是变化不大的。换言之，在某个充电站附近活动的电动汽车有很大可能性去选择该充电站。因此，电动汽车选择充电站是由先验充电频率和当前活动位置共同决定。

(3) 充电站特性分析。猜想日常同行业市场竞争的行为会不会出现在充电站之间，另外城市级别的地理围栏会不会对充电站的充电数量产生影响。首先以距离为规则，本文对数据集中邻近充电站的充电电动汽车数量做了相关性分析，如图 5 所示，本文发现邻近的充电站在充电数量总是呈现很大的相关性。当充电站相邻距离超过 1.862 公里的时候，其相关系数低于置信区间下限 0.837，这样的充电站之间本文可以认为不存在相关性。所有充电站之

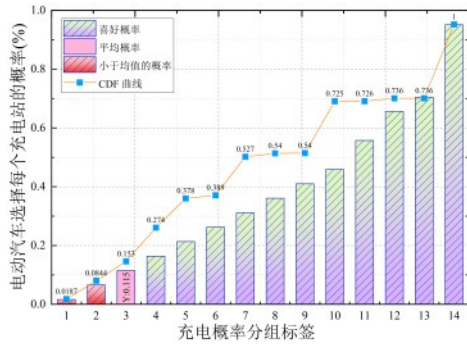


图3 EVs和CSs之间关联性的统计分析

Fig.3 Statistical analysis of the relationship between EVs and CSs

间存在相互作用关系的比例为82.41%。

其次本文将城市地图信息按照距离划分为多个环形并统计每个环形区域内每个期间充电电动汽车的数量，如图6所示。充电的电动车数量在13km处存在一个明显的转移点，这一现象说明了大量的电动车充电行为是在距离城市中心13km的范围内。因此，充电站的电力消耗受到其地理位置的影响。

3 EVs能量预测框架

在电动汽车网络中，电动汽车直接请求充电站能量，而充电站直接请求充电站提供商能量，构成简单的智能电网系统。在这个系统中，充电站服务其覆盖范围的所有电动汽车并且提供相应的充电动作，充电站请求能量储存，充电站提供商可以动态调控充电站的能量储备。通过这种方式可以实现能量供需平衡及低成本电力输送，满足电动汽车网络的正常充电请求。本文所使用的数据是基于电动汽车轨迹的记录，并没有充电站的充电事务数据。基于此，本文设计的能量需求框架立足于能量的直接使用，综合考虑电动汽车的行为特征以及时空特征，文章方法的基本框架如图7所示，图中X代表包含能量E、时间T、充电站标签L的序列向量，SSGF分别代表选择、排序、分组、模糊化的方法。

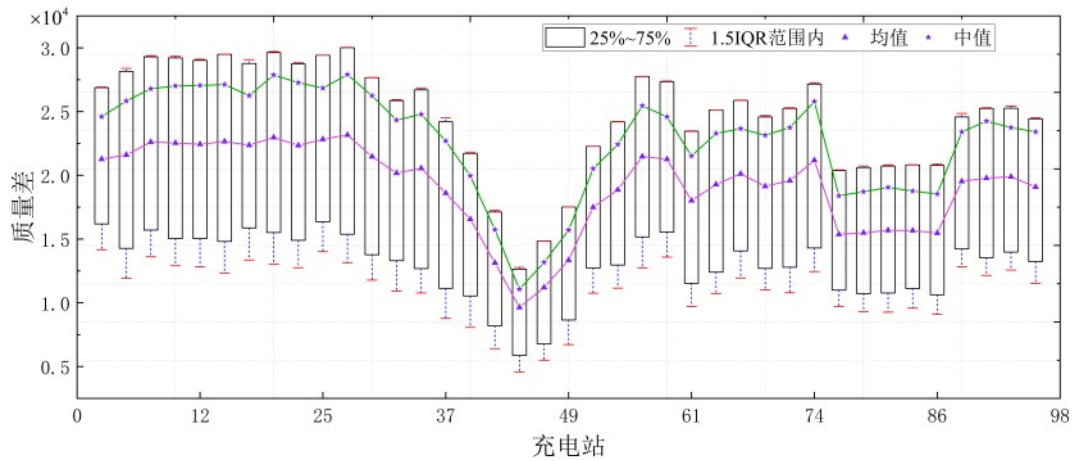


图4 由于附近的的活动而选择CS

Fig. 4 Choose the CS due to nearby activities




图5 附近CS的相互作用

Fig.5 Interaction of nearby CSs




图6 距离的影响分析

Fig.6 Analysis of the impact of distance

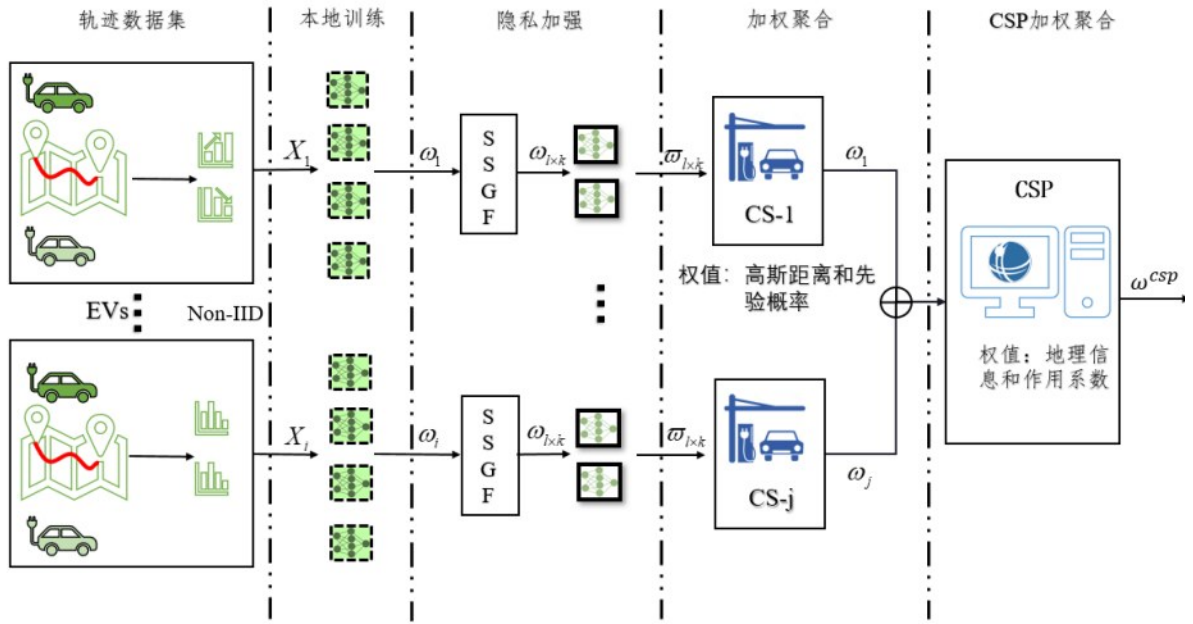


图7 DCFL系统结构

Fig. 7 DCFL system structure

整个学习过程中，假定每个EV都是具有简单智能的个体，其参数服务于CSs模型，CSs所得参数服务于CSP模型即全局模型，该模型可预测未来某时期CSs的所有能量需求，其配合CSs本身的预测即可实现城市级别的动态能量调节，实现电力波谷时期的能量及时存储。为了更好的阐述，约定文章符号如表1。

本文可以采用集合的表示方法。让 $M = \{1, \dots, i, \dots, m\}$ 和 $N = \{1, \dots, j, \dots, n\}$ 分别表示EVs网络集合和CSs集合。为了能量最终的平衡和转移，CSP需要产生每个CS的能量分配比例 $\pi_j^* = \{\pi_1^*, \dots, \pi_j^*, \dots, \pi_n^*\}$, $0 \leq \pi_j^* \leq 1$, 定义CS向CSP请求能量的集合 ζ_j^* 。

$$\zeta_j^* = \{\zeta_1^*, \dots, \zeta_j^*, \dots, \zeta_n^*\} \quad (1)$$

式中 $\zeta_j^* \geq 0$, $\forall j \in \tilde{N}$, $\forall n \in \tilde{N}$ 。

$$\zeta_j^{CSP} = \zeta_{\max}^* \times \pi_j^* = \sum_{j=1}^n \zeta_j^* \times \pi_j^* \quad (2)$$

因此，CSs想要的储备能量 ζ_{\max}^* 受到每个CS的历史数据的影响，而每个CS实际收到的能量 ζ_j^{CSP} 受到CSs请求能量总量和CSP分配比例 π_j^* 的控制。

4 启发式关联规则

本文研究主体为电动汽车汽车，其主要数据来自于车载智能设备，搭配的GPS设备可以不间断的

表1 论文中的符号及含义

TABLE 1 Notations and means in this paper

符号	符号含义
M	电动汽车数量
N	充电站数量
I_d^i	电动汽车的标识符
L_{on}^i	电动汽车的经度
L_{ar}^i	电动汽车的纬度
T_i^j	充电时间戳
Q_c^j	电动汽车充电的天数
ζ_d^i	电动汽车载客状态
h_j^i	电动汽车充电前行驶的距离
L_{on}^j	充电站的经度
L_{ar}^j	充电站的纬度
ζ_{pow}^j	充电站的输出能量值
C_{pow}^j	充电站的额定功率
ζ_j	充电站的电量需求
ζ_j^*	充电站的电量预测值
ζ_{\max}^*	充电站服务商的最大能量容量
π_j^*	充电站的电量比例
ζ_j^{CSP}	充电站服务商为充电站提供的电量

记录车辆的行驶轨迹和行驶区域，这些基础数据正是本文的研究基础。电动汽车产生的数据为动态数据更能反应车辆的移动特性和需求特性。

4.1 驻点检测

对于电动汽车所产生的轨迹数据集并不是本文

想要的，因此本文需要对数据进行关联规则分析。首先引入电动汽车网络中驻点的概念，驻点表示在一定时空中形成的轨迹集合，即表示移动物体在某个地方停留了一段时间，这些轨迹点也被称为“停留点”，如图8中的R区域。




图8 停滞点

Fig.8 Stagnation-point

本文可以分为两种类型，一种是移动物体在一定时间在某个点不会发生绝对的位置变化，一般来说由于传感器的误差，这种几乎是不存在的。还有一种则是在一定范围内纺织成域的面积点，这种数据是科学的是常见的，其表示了移动物体的固有的停留特征，是本文想要的点。对于这些点的检测本文采用启发式关联规则方法，规则有驻点范围R（松弛变量）、速度 v_d^i 和时间 T_i 。首先本文定义轨迹位置点集合 $\Gamma_i(t)$ 和驻点停留轨迹集合 $\Phi_i^*(t)$ ：

$$\Gamma_i(t) = \{L_{on}^i(t), L_{at}^i(t), T_i(t)\} \quad (3)$$

$$\Phi_i^*(t) = \{L_{on}^i(t), L_{at}^i(t), T_i^*(t)\} \quad (4)$$

在这里 $t = \{t_1, t_2, \dots, t_c, \dots, t_r\}$ ， c 、 r 为常数，规则约束如下：

$$s.t. \begin{cases} \Phi_i^*(t) \subseteq R, R \in \{f(\cdot)\} \\ v_{\min} \leq v_d^i \leq v_{\max} \\ T_i \gg 0, i \in \tilde{M} \end{cases} \quad (5)$$

4.2 充电行为检测

因为驻点不一定是充电点，充电点一定是驻点，得到驻点的位置之后，本文更需要确定在这些驻点中，车辆在何时何地进行了充电行为。在第 j 个充电站中，电动汽车的速度和状态会呈现独特的状态，比如速度值会为0。

为了充分找到电动汽车真实的充电位置，文章引入启发因子：

$$\varphi(\chi) = \sum_{k=1}^r \left(\eta \times e^{-(\|L^i - c\|/\sigma)^2} \right) \quad (6)$$

式中 σ 为常数， $\eta = C_{pow}^j$ 为启发因子，表示电动汽

车轨迹点与充电站中心的距离关系，也建立了充电站供电能力与车辆充电之间的联系，如此便可以得到每个电动汽车的充电需求以及得到轨迹对象之间的作用模型。

$$\begin{cases} R = \{L_{on}^j \pm \alpha\varphi(\chi), L_{at}^j \pm \beta\varphi(\chi)\} \\ R = \{L_{on}^{j-\min}, L_{on}^{j-\max}, L_{at}^{j-\min}, L_{at}^{j-\max}\} \end{cases} \quad (7)$$

这里 α 、 β 分别为常数。停留区域的轨迹点总是满足式(7)的表达式，还需要满足 $v_d^j = 0, \zeta_d^j = 0$ 。对于停留时间 $\Delta T_i^j = T_{(i,c)}^j - T_{(i,r)}^j$ ， ΔT_i^j 需要小于单个电动汽车完全充满的最长时间，即 $0 \leq \Delta T_i^j \leq T_i^j$ 。为了防止靠站停车的事件发生，本文引入行驶距离关联规则：

$$h_j^i(t) = \sum_{T_{(i,0)}^j}^{T_{(i,c)}^j} \sqrt{(L_{on}^i - L_{on}^{i+1})^2 + (L_{at}^i - L_{at}^{i+1})^2} \quad (8)$$

在这里 i 代表EV标签， c 代表充电站标签， $T_{(i,c)}^j$ 代表充电行为时刻的时间戳，即 $h_j^i(t)$ 应该属于一个范围：

$$0 \leq h_j^i(t) \leq h \quad (9)$$

式中， h 为电动汽车的正常额定行驶里程。本文建立充电时间和行驶里程的数学模型，即可以得到每个电动汽车在某个充电站理论的充电时间 $T_{(i)}^j$ ， $\Delta\sigma$ 为容错因子：

$$T_{(i)}^j = \frac{h_j^i(t)}{h} \times T_{(i,r)}^j \pm \Delta\sigma \quad (10)$$

通过启发因子得到的充电站的场地尺寸，随后进行行驶里程和停留时间的混合推理，利用车辆速度、状态等信息本文便可以得到高质量地判断电动汽车的具体充电行为，返回每个充电电动汽车的标识、开始充电的时刻，充电时长、充电地址等信息，为下一步联邦学习做好准备。

5 双层可信联邦学习

移动设备使用本地数据协同训练服务器端联邦学习模型，本地设备会不断发送模型更新，即终端将模型权重发送到联邦学习服务器进行聚合，直到达到理想的精度。基于电动汽车端的联邦学习虽然有效提升预测精度，但是Non-IID的数据使得已有的电动汽车用电需求预测模型不再适用。为了解决数据异质和精度不足的问题，本文提出了双层可信联邦学习的能量需求预测方法。

5.1 可信联邦学习

深度神经网络(DNN)正在许多移动和嵌入

式设备上运行，由于该神经网络能满足输入的多样性和输出的准确性，在数据预测方面有着广泛应用^[27]。常见的处理序列数据的神经网络结构有循环神经网络（Recurrent Neural Networks, RNN）、长短期记忆网络（Long-Short-Term Memory, LSTM）、门控循环单元网络（Gate Recurrent Unit, GRU）。相比 LSTM、RNN，GRU 能够更好地对长短时进行依赖表达而且参数配置较少^[28]，所以本文选用 GRU 作为本地网络模型。基本网络结构一般由输入层、隐藏层、输出层构成^[29]。基本参数为，本地模型（GRU）隐藏层维度：30，本地模型（GRU）层数：3，全局学习率：0.01，本地训练轮次：5，可信节点选择分组数：5（即按损失梯度排序后等分为 5 组）。

在第一层联邦学习中，本文注意到进入某充电站的电动汽车集群存在大量跨设备的 Non-IID 数据样本^[30-31]，为此本文提出了可信联邦学习能量预测方法，主要方法是在充电站进行聚合时通过选择可信因子加快收敛速度，防止非可信因子发散模型降低模型精度。选择一组高质量的训练样本，这是一个联邦学习中具有挑战性的问题，因为参与者的本地数据和训练过程不可见^[32]，而训练过程中的随机梯度和模型的有效聚合存在一定联系^[33]。这里本文介绍一种不依赖于任何标签求解的简单的节点选择方法，增加样本的稳定性。

对于每个电动汽车都会有数据集 $D = \{(x, y)\}$ 这里每个 x 都有相应的标签 y 。假定这里有 m 个客户端（EVs），目标标签集合是 y_m ，故 m 个参与端的集合 \tilde{D}_m 可以表示为：

$$\tilde{D}_m = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\} \quad (11)$$

定义在数据集 \tilde{D}_m 上的损失函数为 $l_m(\omega)$ 。

$$l_m(\omega) = \frac{1}{m} \sum_{i \in m} l(f(\omega; x_i), y_i) \quad (12)$$

这里 ω 代表网络的权重值， $f(\omega; x_i)$ 是神经网络的激活函数， $l(f(\omega; x_i), y_i)$ 为第 i 个设备的损失函数。本文需要的是各个参与端的损失最小化。

$$l_i(\omega) = \arg \min l(f(\omega; x_i), y_i) \quad (13)$$

假定 $\omega(t-1)$ 为训练过程中 $t-1$ 回合的权重值，每个电动汽车在 t 回合的权重信息可以表示为：

$$\omega_i(t) = \omega_i(t-1) - \tau \sum_{i=1}^m \nabla_{\omega} [l_i(\omega_i(t-1))] \quad (14)$$

这里 τ 是学习率。 t 回合训练之后获得参与端的

权重集合 $\Delta\omega_i(t)$ 和 $\Delta\omega_{(i,i+1)}(t)$ ：

$$\Delta\omega_i(t) = \{\Delta\omega_1(t), \Delta\omega_2(t), \dots, \Delta\omega_m(t)\} \quad (15)$$

$$\Delta\omega_{(i,i+1)}(t) = \|\omega_i(t) - \omega_{i+1}(t)\| \quad (16)$$

由于数据特征及分布和其训练权重有密切关系，即 $\Delta\omega_i(t)$ 和 $\Delta\omega_{(i,i+1)}$ 有隐式关系， $\Delta\omega_{(i,i+1)}$ 代表相邻电动汽车竞争优势的数据特征。在相同参数训练下两个电动汽车期望输出存在差距，本文可以得到备选因子集合 $\Delta\omega_{(i)}^* = \|\Delta\omega_i(t) - \Delta\omega_{(i,i+1)}(t)\|_2$ 。下一步就是对 $\Delta\omega_{(i)}^*$ 形成索引集合，并对损失函数梯度信息求均方误差（MSE）：

$$I_{(i)}^* \leftarrow \{(\Delta\omega_{(i)}^*, 1), (\Delta\omega_{(i)}^*, 2), \dots, (\Delta\omega_{(i)}^*, m)\} \quad (17)$$

$$\nabla L_m^*(\omega) = \frac{1}{m} \sum_{i=1}^m \sqrt{|\nabla L_i(\omega) - \nabla \bar{L}_m(\omega)|^2} \quad (18)$$

在这里本文保留 $\Delta\omega_{(i)}^* \geq \nabla L_m^*(\omega)$ 的高质量收敛信息，形成待选因子集合 $I_{(i)}^*$ 。为了加强聚合端对局部参与者的容忍性，本文对 $\Delta\omega_{(i)}^*$ 按升序进行排序并将排序结果按等差的方式分成 u 个组，并对每个组对数据进行均值化，均值化后的数据代表这一组参与训练，得到最终集合 $\sigma_{(i)}^*$ ：

$$\sigma_{(i)}^* \leftarrow \{(\Delta\sigma_{(i)}^l, 1), (\Delta\sigma_{(i)}^l, 2), \dots, (\Delta\sigma_{(i)}^l, u)\} \quad (19)$$

这里 l 代表每个组的元素个数。本文设计的方法会过滤掉 $m - l \times k$ 个不可信参与端，得到可信因子集合 $I_{(i)}^{l \times u}$ ，同时分组的方法也进一步加快了 Non-IID 数据处理的速度，这大大增加了样本的稳定性，整体模型的收敛速度将会大幅度提升。

5.2 双层联邦学习

本文旨在建立 EVs、CSs 和 CSP 之间的双层联邦学习(Double-layer federated learning, DFL)框架，充电站作为双层联邦学习的核心点。目的是解决城市电动车能量消耗预测的问题，其优势在于可得到 EVs、CSs 和 CSP 各个环节的能量预测值，是一个系统级的方法。在这种方法中每个电动汽车可以训练自己的模型，不需要将自己本身的数据发送至上层节点，CSs 和 CSP 分别可以接收 EVs 层和 CSs 层模型参数进行聚合，如此便充分保护了各个平台端的信息数据。每个联邦学习框架都具有模型参与者和模型所有者两个部分。本文构建 EVs-CSs 和 CSs-CSP 的双层联邦学习，在这里 CSP 将自己得到的初始化模型发给 EVs，EVs 训练自己的日常充电行为模型，所生成的参数发送到 CSs，CSs 优化聚合自

己的局部模型并将梯度信息发给CSP，CSP进行最终的全局聚合。

定义CSP全局模型的权重向量为 ω^{csp} ；CSs的权重向量 $\omega_{(i)}^c$ ；EVs的权重向量 $\omega_{(i)}^e$ 。假设 p 代表输入矩阵的维度，输入矩阵为 $X_i = \{x_1, x_2, \dots, x_p\}$ ， $x_p = \{Q_c, T_{(i,c)}^j, \Delta T_{i,j}^j\}$ 为某电动汽车在某时期的充电属性集合，至此本文可以建立本地网络模型：

$$Y_i = f_i(\omega_{(i)}^e X_i + b_i) \quad (20)$$

在这里，矩阵 $\omega_{(i)}^e$ 的大小为 $h \times p$ ， b_i 为网络偏置， h 为网络层数， $f_i(\cdot)$ 表示RELU激活函数。每个电动汽车的损失函数则定义为：

$$l_i(\hat{Y}_i, Y_i) = \frac{1}{p} \sum \sqrt{|\hat{Y}_i - Y_i|}^2 \quad (21)$$

采用SGD方法可得电动汽车的权重更新方式：

$$\omega_{(i)}^e(t) = \omega_{(i)}^e(t-1) - \tau \frac{\partial l_i(\hat{Y}_i, Y_i)}{\partial \omega_{(i)}^e} \quad (22)$$

在某个充电站充电的电动汽车本地网络模型训练的梯度信息 $\nabla l_i(\hat{Y}_i, Y_i)$ 会被传送到CSs，在FL1中CSs作为模型聚合者，并且电动汽车也会输出了某个时期的能量需求模型。因为CSs针对每个EV的注意力不同，所以对于不同的充电站本文会选择不同的电动汽车参数进行聚合，这将更好地解决模型质量不平衡的问题。

利用5.1节所提方法对充电站端所下属的参与端进行选择，本文选择充电概率统计值和高斯分布概率值作为注意力，来形成聚合权重。定义 E_j 为某个电动车选择充电站的概率值并取得选择第 j 个充电站的最大概率为：

$$E_{(kj)}^{\max} = \sum P_{(j)}^{x_k} / \sum P_{(k)}^{x_k} \quad (23)$$

$$E_{(j)}^{\max} = \{E_{(1j)}^{\max}, E_{(2j)}^{\max}, \dots, E_{(kj)}^{\max}\}, k = 1, 2, 3 \dots m \quad (24)$$

式中 P^{x_k} 代表充电次数。观察3指出，电动汽车在充电站附近区域而选择该充电站的概率还在距离上服从高斯分布，所以在统计概率的机制上还要引入高斯分布的距离的影响。

$$E_{(gj)}^k = \sum A \exp\left[\frac{(L(k) - L(j))^2}{-A\pi}\right] \quad (25)$$

式中： A 为常数， $E_{(gj)}^k$ 代表在一定区域选择某充电站的概率， $L(k)$ 代表充电前电动汽车的在某充电站附近的活动点， $L(j)$ 为某充电站位置。综上可得充电站端的损失函数和权重更新方式：

$$l_j(\omega_{(j)}^c) = \sum_{i=1}^k E_{(k)}^{\max} \times E_{(gj)}^k \times l_i(\omega_{(j)}^c) \quad (26)$$

$$\omega_{(j)}^c(t) = \omega_{(j)}^c(t-1) - \tau \frac{\partial l_j(\omega_{(j)}^c)}{\partial \omega_{(j)}^c} \quad (27)$$

这样本文就可以解决CSs聚合局部模型时质量不平衡的问题。而在FL2中的CSP端，目标是最小化参与端（CSs）的损失函数。鉴于充电站数据分布的地理特性，CSP将放更多集中注意力在CSs的位置以及充电站的相关性方面。本文在进行第二层联邦学习聚合时引入地理围栏信息即曼哈顿距离函数，形成等式（28）。

$$M_j^d = \left| \{L_{on}^j, L_{(cen,on)}^j\} - \{L_{at}^j, L_{(cen,at)}^j\} \right| \quad (28)$$

这里 $(L_{(cen,on)}^j, L_{(cen,at)}^j)$ 代表某城市的中心位置，计算所有充电站和市中心的曼哈顿距离并进行归一化，即可得：

$$M_w^d = \left\{ (M_j^* - M_{j_{min}}^*) / (M_{j_{max}}^* - M_{j_{min}}^*) \right\} \quad (29)$$

式中： $M_j^* = M_j^d / \sum M_j^d$ 。另一个方面就是充电站之间存在服务竞争、速度竞争等作用关系，本文定义某充电站与其最为相近的充电站之间的相关系数。

$$\rho(j) = \frac{\text{cov}(R_{vj}, R_{vj}^{ad})}{\sqrt{\text{Var}[R_{vj}] \cdot \text{Var}[R_{vj}^{ad}]}} \quad (30)$$

式中 $\text{Var}[R] = \sum \|(H_{fre}^k, \Delta T_j^k)\|^2 / k$ ，表示充电站一定周期内充电车辆频次以及时间的联合。此时本文的CSP端的损失函数可以表达为等式31，而整个模型最终停止的条件是得到最小化的加权损失函数值。

$$l_g(\omega^{csp}) = \arg : \min \sum M_w^d \times \rho(j) \times L_j(\omega_{(j)}^c) \quad (31)$$

在此基础上本文也可以得到CSP端权重更新的模型：

$$\omega^{csp}(t) = \omega^{csp}(t-1) - \tau \frac{\partial l_g(\omega^{csp})}{\partial \omega^{csp}} \quad (32)$$

6 性能评估

6.1 实验设计

本文实验数据为某市2019三个月的电动汽车数据，电动汽车型号为比亚迪型号为e6，电池容量82kWh，普况续航里程320KM，标况续航里程400KM。所用服务器的操作系统为Ubuntu 18.04.6 LT，CPU为Intel(R) Xeon(R) Platinum 8269CY 2.50GHz，GPU为NVIDIA- GeForce系列。为了更直观地了解，本文所使用的软件及版本如表2所示。

表2 软件环境

TABLE 2 Software environment

软件	版本	软件	版本
Python	3.7.11	JDK	1.8.0
Pytorch	1.4.0	Spark	3.1.2
PySyft	0.2.9	Hadoop	3.2.0
VSCode	3.1.2	CUDA	11.5

6.2 实验分析

为了方便后续的一些定量描述，本文引入均方根误差 (Root Mean Squared Error, RMSE)，其数学原理如下：

$$\Delta y_j^* = \sqrt{\frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j|^2} \quad (3.11)$$

(1) 启发式关联算法。为了验证本文所设计的启发式关联规则的有效性和正确性，本文求解了每天每个充电站的电动汽车充电量的RMSE并且对这些结果数据绘制质量控制均值极差图，结果如图9所示。




图9 RMSE的质量控制分析

Fig.9 Quality control analysis of RMSE

通过每个充电站的平均每天电量的误差质量分析，本文可以得到所有充电站的RMSE的组间均值仅为7.62，组内均值的上控制线为17.85，组内均值的下控制线为-2.606，组内极差的上控制线为25.73，组内极差的下控制线为-2.606，RMSE整体均值7.77。RMSE均值和极差全部靠近下控制线并且不大于上控制线，这就证明文章设计的挖掘方法是正确的和合理的，意味可以采用这些数据作为训练集进行后面的联邦学习实验。

(2) DCFL 误差评价。对于从训练集中合理挑选设备是否影响模型准确度进行研究，本文设定相同的迭代次数，将测试集和数据集按照0.1、0.2、

0.3、0.4的比例整。

1) RMSE评估。这一组实验主要是测试文章所使用的可信优化方法对精度的影响，使用DFL和DCFL作为比对。两种方法的本地模型均方误差结果如图10所示。实验结果显示，测试集占比越少，模型的极差越小，数据分布越集中，这也说明数据量对联邦学习的重要性，这也是本文采用电动汽车数据的优势所在。同时，RMSE数据基本维持在75%以下的区域，处于极大值附近的微乎其微，这证明了本文所提方法的正确性；另一方面对于参与训练的设备子集的合理选择反而会提升模型精度，并不会降低预测精度，平均RMSE减少68.7%。




图10 DCFL可信度评估

Fig.10 DCFL credible evaluation

2) 预测能力评估。为了验证该算法的预测能力和准确性，对CS能耗数据进行了四个尺度的预测。在图11中，x轴显示单个充电站，y轴代表实际和预测的能量值。通过观察实际值和预测值，本文发现用所提方法得到的预测值可以更好地遵循实际值。结果表明，本文的方法是有效的，可以为城市中的CS提供能量预测，从而进一步完成对城市中电动车的完整能量预测。

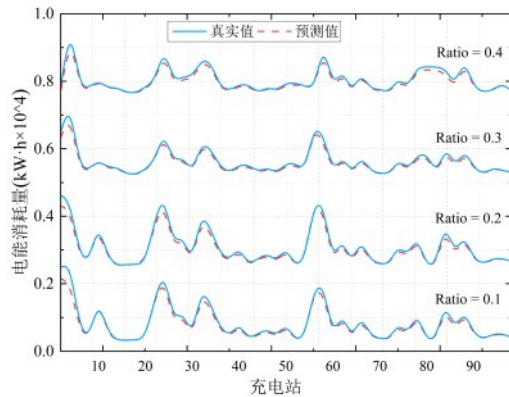


图11 充电站的预测能力

Fig.11 Predictive capability in charging station

(3) **训练时间和收敛性评价。**本文引入了本地模型可信选择和联邦学习加权聚合（注意力机制）方式，本文需要测试收敛一定的精度（96.5%）各种现有方法所需要的训练时间。本文测试平均联邦

学习（FedAvg）、双层平均联邦学习（DFLAvG）以及本文所提出的双层可信加权联邦学习（DCFL），实验结果见表4。该实验证明本文方法在训练时间和收敛性方面具有明显的优势。

表4 训练时间和收敛性
TABLE 4 Training time and convergence

Method	FedAvg	DFLAvG	P ³	DCFL
Duration(hour)	27.2	9.6	8.1	7.9
Reduction Training Time	0%	64.7%	70.2%	71.0%
Iteration Number	500	446	418	412
Reduction Iteration	0%	10.8%	16.4%	17.6%

(4) **多种方法性能评估。**为了与现有方法进行对比，本文提取第二层联邦学习框架，构建充电站与充电站提供商之间的学习机制。选取文献[19]中三种已发表的联邦学习方法作为基线对比：FEDL(DNN)采用深度神经网络作为本地模型，通过传统联邦平均聚合方式进行全局模型更新；FEDL(FedAvg)为标准联邦平均算法，各参与端平等参与聚合，是联邦学习中最基础的聚合策略；FEDL(Clustering)为基于聚类的联邦学习方法，通过对参与端进行分组聚合，在一定程度上缓解了数据异构带来的影响。本文额外更加了最先进的P³算法作为先进性对比，该作者提出了一种新的基于区块链的个性化联邦深度学习方案，即P³，用于电动汽车充电网络中隐私保护的能源需求预测。

此外，本文还设置了消融实验，将所提DCFL的简化版本（仅保留第一层联邦结构，记为DFL子方法）与完整DCFL方法进行对比。精度与收敛速度的测量结果分别如图12和图13所示。实验结果表明，传统联邦学习方法对于非独立同分布数据的处理效果不理想，对参与端进行合理筛选并优化聚合端的权重分配，能够有效提升预测精度，同时更好地保留各充电站的个体特性。本文所提DCFL方法在准确度和收敛速度方面均优于其他传统方法，即使和最先进的P³相比，性能也能媲美，最终预测准确度达到87.8%。

7 结论

对能量的预测和规划是智慧城市建设中重要的环节。本文通过对电动汽车进行数据分析，系统地构建了电动汽车、充电站、充电站供应商三者之间的能量模型，提出了全新的双层可信联邦学习算

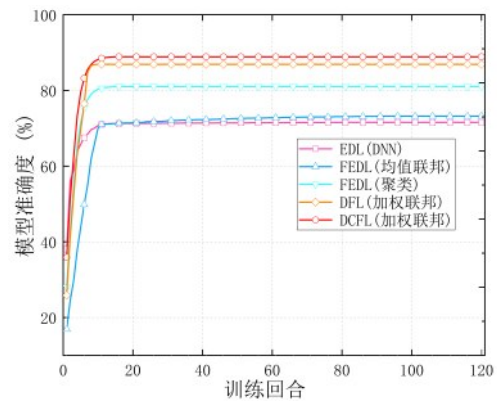


图12 不同算法的准确度比较

Fig.12 Accuracy comparing with different algorithms

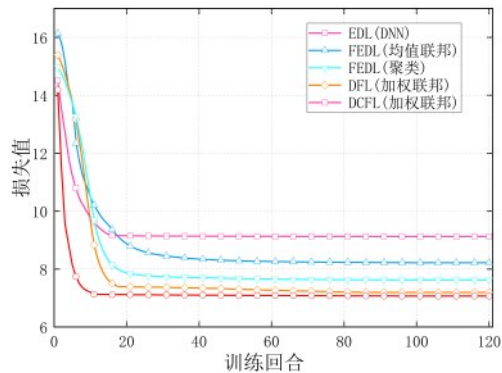


图13 比较多种算法的收敛性

Fig.13 Comparing convergence with multiple algorithms

法。文章首先将电动汽车轨迹数据进行了大量分析，通过挖掘算法转化成能量数据；其次在第一层联邦学习中通过对节点进行可信选择，增加模型收敛速度和Non-IID数据的处理能力，在第二层中引入权重影响因子，提升模型的准确度。通过实验证明，本文方法相比较传统均值联邦学习，训练时间减少71%，收敛速度增加17.6%；相比较已有方法，文中所提方法在收敛速度和精度方面具有明显

的提升。



岳高峰 (1995-11-06), 男, 工学博士学位, 西安航空职业技术学院, 讲师, 专任教师, 主要研究方向: 机器学习与人工智能。

参考文献:

- [1] Hinov N, Vacheva G, Giles B. Mathematical Model for Determination of Energy Cycles in EVs[C]. 2020 24th International Conference Electronics, 2020:1-5.
- [2] Li G, Gorges D. Ecological Adaptive Cruise Control and Energy Management Strategy for Hybrid Electric Vehicles Based on Heuristic Dynamic Programming[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, PP:1-10.
- [3] Elmi S, Tan K L. DeepFEC: Energy Consumption Prediction under Real-World Driving Conditions for Smart Cities[C]. The Web Conference 2021. 2021:1880--1890.
- [4] Majidpour M, Qiu C, Chu P, et al. Fast Prediction for Sparse Time Series: Demand Forecast of EV Charging Stations for Cell Phone Applications[J]. IEEE Transactions on Industrial Informatics, 2015, 11(1):242-250.
- [5] Wang Y, Bennani I L, Liu X, et al. Electricity Consumer Characteristics Identification: A Federated Learning Approach[J]. IEEE Transactions on Smart Grid, 2021, 12(4): 3637-3647
- [6] Fuli Qiao, Shan Lin. Data-driven prediction of fine-grained EV charging behaviors in public charging stations: Poster[C]. Proceedings of the Twelfth ACM International Conference on Future Energy Systems (e-Energy '21). 2021, 276 - 277.
- [7] Zhong D, Sun P, Boukerche A. Empirical Study and Analysis of the Impact of Traffic Flow Control at Road Intersections on Vehicle Energy Consumption[C]. Proceedings of the 18th ACM Symposium on Mobility Management and Wireless Access. 2020: 21 - 28.
- [8] Chis A, Lunde N J, Koivunen V. Reinforcement Learning-Based Plug-in Electric Vehicle Charging with Forecasted Price[J]. IEEE Transactions on Vehicular Technology, 2016, 66(99):1-1.
- [9] Banda P, Bhuiyan M A, Hasan K N, et al. Timeseries Based Deep Hybrid Transfer Learning Frameworks: A Case Study of Electric Vehicle Energy Prediction[C]. ICCS2021-21st International Conference, 2021:259-272.
- [10] Afiya Ayman, Amutheezan Sivagnanam, Michael Wilbur, Philip Pugliese, Abhishek Dubey, and Aron Laszka. Data-Driven Prediction and Optimization of Energy Use for Transit FleEVs of Electric and ICE Vehicles[J]. ACM Transactions on Internet Technology, 2022, 22(01):1-29.
- [11] Naoya Yoshida, Takayuki Nishio, Masahiro Morikura, Koji Yamamoto and Ryo Yonetani. Hybrid-FL for Wireless Networks: Cooperative Learning Mechanism Using Non-IID Data[C]. 2020 IEEE International Conference on Communications (ICC), 2020:1-7.
- [12] Grubwinkler S, Lienkamp M. Energy Prediction for EVs Using Support Vector Regression Methods[J]. Springer International Publishing, 2015(323):769--780.
- [13] Zhou J, Xiang Y, Zhang X, et al. Optimal self-consumption scheduling of highway electric vehicle charging station based on multi-agent deep reinforcement learning[J]. Renewable Energy, 2025, 238121982-121982.
- [14] Yadav K, Singh M. A novel energy management of public charging stations using attention-based deep learning model[J]. Electric Power Systems Research, 2025, 238111090-111090.
- [15] McMahan B, Moore E, Ramage D, et al. Communication-efficient learning of deep networks from decentralized data[C]. Artificial intelligence and statistics. PMLR, 2017: 1273-1282.
- [16] Chen N, Li M, Wang M, et al. Compensation of Charging Station Overload via On-road Mobile Energy Storage Scheduling [C]. 2019:1-6.
- [17] He C, Annavam M, Avestimehr S. Group Knowledge Transfer: Federated Learning of Large CNNs at the Edge[J]. 2020, 33: 14068-14080.
- [18] Wang X H, Zheng X K, Liang X. Charging Station Recommendation for Electric Vehicle Based on Federated Learning[J]. Journal of Physics: Conference Series, 2021, 1792:12055.
- [19] Saputra Y M, Hoang D T, Nguyen D N, et al. Energy Demand Prediction with Federated Learning for Electric Vehicle Networks[C]. IEEE Global Communications Conference (2019). 2019: 1-6.
- [20] Tun Y L, Thar K, Thwal C M, and Hong C S. Federated learning-based energy demand prediction with clustered aggregation[C]. IEEE International Conference on Big Data and Smart Computing (Big Comp)(2021). 2021:164 - 167.
- [21] Christopher Briggs, Zhong Fan, and Peter Andras. Federated Learning for Short-term Residential Energy Demand Forecasting [C]. 2021: 2105.
- [22] Li T, Sahu A K, Zaheer M, et al. Federated Optimization in Heterogeneous Networks[C]. Proceedings of Machine Learning and Systems, 2020, 2: 429-450.
- [23] Karimireddy S P, Kale S, Mohri M, et al. SCAFFOLD: Stochastic Controlled Averaging for Federated Learning[C]. International Conference on Machine Learning. PMLR, 2020: 5132-5143.
- [24] Sattler F, Müller K R, Samek W. Clustered Federated Learning: Model-Agnostic Distributed Multi-Task Optimization under Privacy Constraints[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(8): 3710-3722.
- [25] Zhu Y, Luo H, Chen R, et al. DenseNetX and GRU for the Sussex-Huawei Locomotion-transportation Recognition Challenge[C]. UbiComp/ISWC 20, 2020:373-377.

- [26] Mills, Jed and Hu, Jia and Min, Geyong. Multi-Task Federated Learning for Personalized Deep Neural Networks in Edge Computing[J]. IEEE Transactions on Parallel and Distributed Systems, 2022,33(3):630-641.
- [27] Bonawitz Keith, Ivanov Vladimir, Kreuter Ben, et al. Practical Secure Aggregation for Privacy-Preserving Machine Learning[J]. Association for Computing Machinery. 2017, 17:1175-1191.
- [28] Luo Y, Liu X, Xiu J. Energy-efficient Clustering to Address Data Heterogeneity in Federated Learning[C]. IEEE International Conference on Communications (2021). 2021:1-6.
- [29] Li A, Zhang L, Tan J, Qin Y, Wang J, et al. Sample-IETel Data Selection for Federated Learning[C]. IEEE Conference on Computer Communications (2021). 2021:1-10.
- [30] Jonatan Reyes, Lisa DiJorio, Low Kam, Marta Kersten. Precision-Weighted Federated Learning[C]. 2021: 2107.09627.

- [31] Beibei Li, Yuqing Guo, Qingyun Du, Ziqing Zhu, Xiaohui Li, Rongxing Lu. P3: Privacy-Preserving Prediction of Real-time Energy Demands in EV Charging Networks[J]. IEEE Transactions on Industrial Informatics, 2023, 19(3):029-3038.

[作者简介]



韩迪 (2000-06-30), 女, 工学硕士学位, 西安航空职业技术学院, 助教, 专任教师, 主要研究方向: 多传感器融合。



陈嘉鑫 (1995-04-26), 女, 工学硕士学位, 西安航空职业技术学院, 讲师, 专任教师, 主要研究方向: 大数据处理技术。