

基于动态联邦学习的LA模式下短期负荷预测

谷 政¹, 李军祥^{1,2*}

¹上海理工大学管理学院, 上海

²上海理工大学智慧应急管理学院, 上海

收稿日期: 2025年3月28日; 录用日期: 2025年4月21日; 发布日期: 2025年4月29日

摘 要

针对负荷聚合商(LA)模式下数据隐私与样本不足的挑战, 本文提出一种动态联邦学习(DFL)与长短期记忆网络(LSTM)融合的短期负荷预测方法。首先, 提出一种依托电价合同构建的需求响应机制, 以需求响应信号的方式参与负荷预测, 构建多维度DR信号模型, 引入用户满意度动态约束, 优化LA收益目标; 其次, 建立本地的长短期记忆网络模型。最后设计动态联邦学习(DFL), 通过数据分布感知的权重分配, 取代传统平均联邦学习算法, 提升模型泛化能力; 实验表明, 相比传统联邦学习, 本文方法在3个场景测试中平均RMSE误差上减少31.2%, MAPE误差降低41.2%, 训练轮次减少21.7%, 训练时间降低29.6%, 在保证各负荷聚合商数据隐私的同时, 提升了模型的预测精度, 具有更强的实用性。

关键词

负荷聚合商, LSTM模型, 需求响应, 短期负荷预测, 动态联邦学习算法

Short-Term Load Forecasting in LA Mode Based on Dynamic Federated Learning

Zheng Gu¹, Junxiang Li^{1,2*}

¹Business School, University of Shanghai for Science and Technology, Shanghai

²School of Intelligent Emergency Management, University of Shanghai for Science and Technology, Shanghai

Received: Mar. 28th, 2025; accepted: Apr. 21st, 2025; published: Apr. 29th, 2025

Abstract

In response to the challenges of data privacy and insufficient samples in the Load Aggregator (LA) model, this paper proposes a short-term load forecasting method that integrates Dynamic Federated Learning (DFL) and Long Short-Term Memory (LSTM) networks. First, a demand response mechanism based on electricity price contracts is proposed, which participates in load forecasting

*通讯作者。

through demand response signals, constructs a multi-dimensional DR signal model, introduces dynamic constraints on user satisfaction, and optimizes the LA revenue target. Second, a local Long Short-Term Memory network model is established. Finally, Dynamic Federated Learning (DFL) is designed to replace the traditional average federated learning algorithm through data distribution-aware weight allocation, enhancing the model's generalization ability. Experiments show that, compared to traditional federated learning, the proposed method reduces the average RMSE error by 31.2%, the MAPE error by 41.2%, the number of training rounds by 21.7%, and the training time by 29.6% across three scenario tests, while ensuring data privacy for each load aggregator and improving the model's forecasting accuracy, demonstrating greater practicality.

Keywords

Load Aggregators, LSTM Model, Demand Response, Short-Term Load Forecasting, Dynamic Federated Learning Algorithms

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着全球可再生能源发电在电力系统的占比日益增强,电力系统的负荷的管理与调度变得更加难以控制。尤其是大规模接入了风能、光伏等间歇性能源之后,以往僵硬的负荷调节策略根本不足以应对电力系统较高的不确定性和波动性。目前为了更好地实现电网在峰谷阶段的负荷调节,对负荷进行调度,增强负荷的弹性,主流的解决方法是引入需求侧用户参与电力市场的运营调控[1]。需求响应(Demand Response, DR)技术作为一种能够平衡电力供需的重要手段,目前在电力市场中的运用较为广泛。DR 技术通过负荷调节来动态调整用户的用电行为,尤其是在电力需求高峰时段,通过调节用户负荷,从而缓解用电高峰时电网运行压力,优化电网。但是目前国内的电力市场仍处于起步阶段,对于较为分散的各项 DR 资源的整合能力不足,且如果让 DR 资源供需方直接交易也无法保证其弹性水平,为单一用户供需提供响应的调度和管理也无法满足电力市场的成本要求[2]。需要负荷聚合商(Load Aggregator, LA)参与需求响应机制当中,将分散的 DR 资源进行整合,统一调控[3] [4]。在电力系统中,LA 作为一种市场参与者,负责整合分散的需求响应资源,并将这些资源进行统一调度以响应电力市场的需求变化。LA 通过与大量用户签订需求响应协议,实现对用户负荷的调节[5]。然而,由于电力市场中存在大量的用户数据,这些数据往往涉及敏感信息,如何在保证用户隐私的前提下进行负荷预测和调度,成为了一个亟待解决的挑战[6]。

为了应对这一挑战,本文提出了一种基于动态联邦学习(Dynamic Federated Learning, DFL)和长短期记忆网络(Long Short-Term Memory, LSTM)的短期负荷预测方法。以联邦学习的方式实现分布式训练,避免了数据传输和集中存储,从而有效保护了用户的隐私。

2. 基于 LA 模式的 DR 信号模型

在负荷聚合商(LA)模式下,负荷的调节受到多个因素的影响,尤其是用户的需求响应行为,因此,在 LA 模式下进行负荷预测需要充分考虑 LA 参与 DR 的决策行为,而在模型当中则是将 DR 的数据作为 LSTM 的输入量的一种。为了更好地在 LA 模式中对相关的负荷进行预测,充分考虑 DR 的影响,本文参考 LA 模式下预测的主流方式,构建了基于 LA 模式的 DR 子信号模型,并结合 LSTM 进行负荷预测[7]。

本文所涉及的 LA 模式存在 3 类参与者，分别是 DR 需求者、LA 和 DR 资源供给者。其中，DR 资源需求者包含发电商、电网公司、供电公司等，能够与 LA 进行双边交易，并构建 DR 合同，设置激励价格来推动 LA 参与 DR。LA 通过与各类用户签订的需求响应(DR)合同，调节用户的负荷，优化整体电网的负荷平衡。根据负荷性质、DR 能力、各元件的组合特性，本文考虑三种 DR 资源：IL (可中断负荷)、TL (可转移负荷)和光伏储能(PES)。这些 DR 资源的优化目标分别是通过减少高峰负荷、转移负荷到低谷时段，以及利用储能资源的充放电调节负荷，从而实现电网的负荷平衡。立足于这三类 DR 信号模型，合成 DR 信号作为数据集其中的一个输入量，输入到 LSTM 训练网络当中。建立基于 LA 模式的 DR 机制，如图 1 所示：




Figure 1. DR mechanism based on LA mode
图 1. 基于 LA 模式的 DR 机制

在此基础上，将 DR 资源的优化模型进行构建，从而得到本文所考虑的 3 类 DR 资源的信号值，作为最终的输入值，进行模型训练。

2.1. IL 的 DR 子信号

在 LA 模式下，各个时段的经济激励价格和用电的行为有关，在负荷曲线中表现为在高峰阶段时，会通过设定较高的合同价格引导用户积极主动对可中断电负荷 IL 进行削减，降低电力系统在用电高峰时的运行压力。由于本文在 LA 模式下进行负荷预测，所以以 LA 为主体，对该 LA 所管理地区内的 IL 资源进行用电计划优化，所以优化目标是 LA 的盈利最大化，IL 的 DR 子信号模型为：

$$\max \sum_{i=1}^{N_{IL}} P_{LA}^t \cdot S_{IL}(t) - C_{IL}(S_{IL}(t)) \quad (1)$$

$$R_t^{IL} = \sum_{i=1}^{N_{IL}} S_{IL}(t) \quad (2)$$

$$R^{IL} = [R_1^{IL} R_2^{IL} \cdots R_t^{IL} \cdots R_{T-1}^{IL} R_T^{IL}] \quad (3)$$

$$i = 1, 2, \cdots, N_{IL} \quad (4)$$

$$t = 1, 2, \cdots, T \quad (5)$$

其中： P_{LA}^t 为 LA 在时段 t 从 DR 资源购买者处获得的电价激励； $S_{IL}(t)$ 为 IL 用户在时段 t 的负荷削减量，即 LA 在时段 t 中断负荷的大小； $C_{IL}(S_{IL}(t))$ 为负荷削减的成本； R^{IL} 为 IL 的 DR 子信号； R_t^{IL} 为 IL 在时

段 t 的 DR 子信号数值； T 为负荷一日内的时间序列，本文取 $T = 96$ ； N_{IL} 为 IL 用户数目。

对于 LA 与 IL 用户建立的电价合同，需要满足相应的 DR 规则，同时也要满足电网运行要求，即每个用户在时段 t 的实时中断负荷数量、一日内总用电减少量不能超出约定的限额。相应的约束条件如下：

$$0 \leq S_{IL}(t) \leq S_{\max} \quad (6)$$

$$\sum_{t=1}^T S_{IL}(t) \leq S_{\text{total}} \quad (7)$$

式中： $S_{\max}$ 表示合同中规定的最大即时削减负荷功率， S_{total} 表示一日内最大削减电量；对于 LA 模式来说，负荷削减的持续时间需要处于一个合理的区间当中，过长的削减时间会极大降低用户满意度，同时电网 DR 的要求使得持续时间不能太短。除了持续时间外，负荷削减量的变化也会影响用户的满意度，总体上随负荷削减量增加而下降。具体约束如下：

$$T_{\min} \leq \sum_{t=1}^T x_{i,t} \leq T_{\max} \quad (8)$$

$$U_{IL}(t) = e^{-\alpha S_{IL}(t)} \geq U_{\min} \quad (9)$$

式中： $T_{\min}$ 和 $T_{\max}$ 分别为 DR 的持续时间下限和上限； $U_{IL}(t)$ 表示用户在时刻 t 的满意度，随负荷削减量增加而下降； α 为用户对削减负荷的敏感度； $U_{\min}$ 为用户满意度的最低阈值，防止削减负荷过多导致用户不愿参与 DR。

2.2. TL 的 DR 子信号

可转移电负荷 TL 指的是可以灵活调整使用时间的负荷，例如洗衣机、热水器等。LA 可以通过实时电价的指导作用，通过引导用户在电价较低的时段使用这些设备来优化电网负荷曲线，确保一日内负荷总量变化为 0。LA 模式下，其目标函数与 IL 资源大致相同，整体的约束条件略有不同，具体列出如下：

$$0 \leq |S_{TL}(t)| \leq S_{\max} \quad (10)$$

$$\sum_{t=1}^T S_{TL}(t) = 0 \quad (11)$$

$$T_{\min} \leq \sum_{t=1}^T x_{i,t} \leq T_{\max} \quad (12)$$

$$U_{TL}(t) = e^{-\beta |S_{TL}(t) - S_{\text{pref}}|} \geq U_{\min} \quad (13)$$

$$R_t^{\text{TL}} = \sum_{i=1}^{N_{TL}} S_{TL}(t) \quad (14)$$

$$R^{\text{TL}} = [R_1^{\text{TL}} R_2^{\text{TL}} \cdots R_t^{\text{TL}} \cdots R_{T-1}^{\text{TL}} R_T^{\text{TL}}] \quad (15)$$

$$i = 1, 2, \dots, N_{TL} \quad (16)$$

式中： $S_{TL}(t)$ 为第 i 个 TL 用户在时段 t 转移负荷的大小； $U_{TL}(t)$ 表示用户在时刻 t 的满意度， S_{pref} 为用户偏好的用电时间点所需的负荷， $S_{TL}(t)$ 的偏离程度影响用户满意度； β 为用户对时间偏移的敏感度。 R_t^{TL} 为 TL 在时段 t 的 DR 子信号数值，即 LA 在时段 t 转移负荷的大小，正值表示转出，负值表示转入； R^{TL} 为 TL 的 DR 子信号； N_{TL} 为 TL 用户数。

2.3. 光伏储能的 DR 子信号

光伏储能(PES)指的是用户通过太阳能光伏系统及储能设备进行负荷调节，其优化目标是通过合理的

充放电调节, 最大化 LA 的收益。对于 PES 用户来说, 其充放电行为一般满足合理的经济准则, 即当用户 i 的光伏出力 P_{pv}^t 大于固定负荷 P_{load}^t 或 t 时段电价为低谷电价时储能充电; 当用户光伏出力 P_{pv}^t 小于固定负荷 P_{load}^t 且 t 时段电价为高峰电价时储能放电。其充放电行为的数学模型如下:

$$P_{ch}^t \leq \begin{cases} P_{pv}^t - P_{load}^t & \text{若 } P_{pv}^t > P_{load}^t, \text{ 或 } \lambda_t \text{ 为低谷电价} \\ 0 & \text{否则} \end{cases} \quad (17)$$

$$P_{dis}^t \leq \begin{cases} P_{load}^t - P_{pv}^t & \text{若 } P_{pv}^t > P_{load}^t, \text{ 或 } \lambda_t \text{ 为低谷电价} \\ 0 & \text{否则} \end{cases} \quad (18)$$

$$R_t^{PES} = \sum_{i=1}^{N_{PES}} \omega_i P_{dis}^t + (1 - \omega_i) P_{ch}^t \quad (19)$$

$$R^{PES} = [R_1^{PES} R_2^{PES} \dots R_t^{PES} \dots R_{T-1}^{PES} R_T^{PES}] \quad (20)$$

式中, P_{dis}^t 为时刻 t 的放电功率; P_{ch}^t 为时刻 t 的从充电功率; λ_t 为时刻 t 的电价; ω_i 为 0 或 1, 表示储能不能同时进行充电和放电行为, R^{PES} 为 PES 的 DR 子信号; N_{PES} 为光伏储能参与用户数。对于电池, 其容量也对光伏储能的参与程度产生影响, 存在最小限值 E_{min} 和最大限值 E_{max} , 具体公式如下:

$$E_t = E_{t-1} + \eta_{ch} P_{ch}^t - \frac{P_{dis}^t}{\eta_{dis}} \quad (21)$$

$$E_{min} \leq E_t \leq E_{max} \quad (22)$$

式中, E_t 为时刻 t 电池的能量存储量, η_{ch} 和 η_{dis} 为该光储系统的充电和放电功率。

2.4. DR 信号的合成

为了更好在模型中输入上述 3 个 DR 子信号, 本文将 3 类信号进行叠加, 形成一个总 DR 信号, 简化输入 LSTM 的数据量。

$$R = R^{IL} + R^{TL} + R^{PES} \quad (23)$$

式中: R 为 LA 聚合后的 DR 信号。 R^{IL} 、 R^{TL} 、 R^{PES} 代表上文中的 3 类子信号。在本文中, 将削减的负荷视为正, 增加负荷视为负, 选取某月实时电价下的需求响应信号则如下图 2 所示:




Figure 2. DR mechanism based on LA mode
图 2. 实时电价下 DR 信号的聚合原理图

由图 2 可以看出：实际电力市场中，LA 系统调度员发送 DR 信号的时间间隔和电价与电力的供需有关，当某日出现较低的电价，或者在峰值的负荷较低，调度员一般不发出 DR 信号，视为无需进行 DR 调度即可满足电力市运行，因此实际的需求响应要充分考虑其灵活性与随机性。

3. 基于横向联邦学习的负荷预测模型构建

动态联邦学习算法(DFL)是针对传统联邦学习(FedAvg)算法的一种改进，旨在根据每个客户端的数据量和特征相似度自动调整其聚合权重。传统的联邦学习使用固定的权重进行聚合，这对于数据量差异较大的客户端可能导致模型泛化能力较差[8]。DFL 的优势在于，它动态计算每个客户端的聚合权重，以提升整体模型的准确性和稳定性。DFL 的核心思想是根据以下两个因素调整权重：数据量权重：客户端的数据量越大，说明其训练数据对于全局模型的贡献越大，应该赋予较高的权重。特征相似度权重：如果某个客户端的数据与全局模型的特征空间更为接近，则该客户端对全局模型的贡献更大，权重应当增加[9]。

3.1. 基于动态联邦学习的负荷预测框架

3.1.1. DFL-LSTM 模型结构

由于负荷聚合商(LA)分布在不同的区域，每个 LA 的数据具有地域性，不同 LA 的数据分布可能存在较大差异，因此直接在中心服务器上训练 LSTM 模型可能会导致数据孤岛问题。同时，数据的集中化训练会带来隐私泄露风险[10]。因此，本文提出了一种基于 DFL (动态联邦聚合算法) + LSTM 的负荷预测方法，在分布式环境下进行模型训练，避免数据共享，同时提升预测精度。该方法的模型结构如下：

- 1) 输入层：每个 LA 的本地数据作为 LSTM 的输入，包括过去 T 个时刻的负荷数据、需求响应信号 R 、天气、温度、湿度等外部因素
- 2) LSTM 层：通过 LSTM 单元捕捉负荷的时间依赖关系，预测未来时刻的负荷。
- 3) 全连接层：LSTM 的输出传入全连接层进行最终预测。
- 4) 输出层：预测未来时刻的负荷值 $Y(t)$ 。
- 5) 联邦学习(DFL 聚合)：各个 LA 本地训练 LSTM 后，上传模型参数至服务器，使用 DFL 算法进行模型聚合。

3.1.2. DFL 联邦学习流程

DFL-LSTM 在联邦学习的基础上进行优化，基本流程包括模型初始化、客户端本地训练、聚合权重计算、参数聚合和模型更新。DFL 具体步骤如下：

- 1) 初始化：服务器端初始化全局模型参数 θ_0 ，并将其分发至所有客户端。客户端需要根据本地数据集进行训练，得到本地模型参数 θ_k 。
- 2) 本地训练：每个客户端使用本地数据集对模型进行训练，更新本地模型参数 θ_k ，并计算本地训练损失和梯度。每个客户端进行多轮训练，直到本地模型收敛再上传本地模型，以减少全局通信频率，提高后续的联邦训练效率。在本地进行局部训练时，采用动态局部更新的策略，即考虑 LA 负荷数据的稳定性，对本地训练轮次进行动态调整：

$$C_k = \min \left(C_{\max}, \frac{\sigma_k}{\sum_{i=1}^N \sigma_i} \cdot C_{\text{total}} \right) \quad (24)$$

其中： C_k 是第 k 个 LA 的本地训练轮次， σ_k 代表该地 LA 的负荷数据的波动性， $C_{\max}$ 是最大本地训练轮次，也就是针对集中 LSTM 方法下的训练轮次， C_{total} 为总训练轮次。

3) 聚合权重计算：计算每个客户端的权重 w_k ，权重计算公式为：

$$w_k = \frac{n_k \cdot \text{sim}_k}{\sum_{i=1}^k n_i \cdot \text{sim}_i} \quad (25)$$

$$\text{sim}_k = \frac{\sum_{t=1}^T R_k(t) \cdot R_{\text{global}}(t)}{\sqrt{\sum_{t=1}^T R_k^2(t)} \cdot \sqrt{\sum_{t=1}^T R_{\text{global}}^2(t)}} \quad (26)$$

其中： n_k 是客户端 k 的数据量； sim_k 是客户端 k 的数据特征与全局模型的相似度，通过计算各 LA 的需求响应信号 $R_k(t)$ 和全局需求响应信号 $R_{\text{global}}(t)$ 的余弦相似度。

4) 参数聚合：服务器端将每个客户端的本地模型 θ_k 和相应的聚合权重 w_k 进行加权平均，从而得到新的全局模型 θ ：

$$\theta = \sum_{i=1}^k w_k \cdot \theta_k \quad (27)$$

其中， k 是参与训练的客户端数量， θ_k 是客户端 k 的本地模型参数， w_k 是相应的权重。为了更好的应对海量数据的通信压力，减少通信开销，在每一轮训练中，DFL 仅选择高贡献度的客户端参与模型聚合，而非所有客户端均需上传本地模型。同时由于负荷数据的时序特性，不同时间段的特征重要性不同，本文引入梯度剪枝方法，仅上传重要的梯度信息，减少传输数据量：

$$g'_t = \begin{cases} g_t & \text{若 } |g_t| > \tau \\ 0 & \text{否则} \end{cases} \quad (28)$$

其中， g'_t 是最终上传的梯度信息； g_t 是客户端 k 的本地模型的梯度， τ 是梯度剪枝的阈值。

5) 更新与迭代：聚合后的全局模型参数 θ 被发送回客户端，客户端使用该参数进行下一轮本地训练，直到模型收敛。

3.2. 预测评价指标

负荷预测效果评价指标采用均方根误差(Root Mean Square Error, RMSE)和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)，以及训练伦次，三类结果的评价指标值越小代表所得结果与真实负荷的误差也就越小，本文方法的预测效果与实用价值更好。指标计算公式分别如下所示：

$$\eta_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\eta'_i - \eta_i)^2} \quad (29)$$

$$\eta_{\text{MAPE}} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\eta'_i - \eta_i}{\eta_i} \right| \quad (30)$$

式中： η'_i 与 η_i 分别表示负荷的实际值与预测值； n 为样本数量。

4. 算例仿真

4.1. 预测数据与场景

为了更好地模拟 LA 模式下各个负荷聚合商参与需求响应的状态，本文采用 5 台相互独立的计算机代表 5 个本地负荷运营商，也就是代表 5 个地区对实际的需求响应模型进行模拟。

本文数据集则选取某地 75 日内的电网工作日的负荷数据，时间间隔 15 min，也就是一天共 96 个时间节点。训练集和测试集的比例为 8:2，为了更好地体现负荷数值变化对于基量的差异，本文还利用 min-

max 归一化处理。同时, 基于神经网络的特性, 将数据归一化到[0, 1]也能得到更准确的预测值。为验证本文提出的方法的有效性, 我们设计了三个不同的预测场景, 并对其进行了对比分析:

场景 1: 使用传统方法, 即在 LA 模式下使用集中式 LSTM 模型进行负荷预测。所有数据都集中到一个中央服务器进行训练, 不考虑数据隐私问题。

场景 2: 使用传统的联邦学习(FedAvg)方法进行模型训练与聚合。FedAvg 采用固定的权重来进行参数聚合, 不考虑各客户端数据的特征相似度。

场景 3: 使用本文提出的动态联邦聚合算法(DFL)进行模型训练与聚合。该方法根据每个客户端的数据量和特征相似度动态调整聚合权重, 在模型的训练过程中采用动态局部更新和上传梯度剪枝, 以期提高训练中的通信效率。

4.2. 预测结果与分析

将用于实验的 5 个地区全部在 3 种场景下进行仿真实验, 对这 5 个地区逐个进行以下操作: 首先是进行集中式的 LSTM 模型训练, 即每个地区的训练集仅限于本地区所得到的数据, 得到训练好的本地模型, 作为客户端的服务器模型, 并记录集中式 LSTM 训练下所得到的结果用于后续对比; 其次是将该模型下发至处理本地区之外的其他 4 个地区的服务端, 进行模型的联邦操作, 也就是更新、上传、接受、聚合、更新流程, 在其中, 先不考虑动态联邦, 使用平均聚合, 也就是传统联邦学习方法输出结果, 得到结果后, 再进行本文方法, 使用特征相似度对比以及梯度剪枝方法进行动态联邦学习的模型学习流程; 最后记录 5 个地区 3 种场景下的负荷预测结果, 并对比真实负荷、集中式 LSTM 方法、传统联邦学习方法及本文方法的预测结果。得到各地区负荷预测结果对比分别如图 3~8 所示, RMSE 对比结果如表 1 所示, MAPE 结果对比如表 2 所示, 三种方法的训练轮次对比如表 3 所示, 两种联邦学习方法的训练轮时间对比如表 4 所示。




Figure 3. Comparison of load forecast results for region 1

图 3. 地区 1 负荷预测结果对比




Figure 4. Comparison of load forecast results for region 2

图 4. 地区 2 负荷预测结果对比




Figure 5. Comparison of load forecast results for region 3

图 5. 地区 3 负荷预测结果对比




Figure 6. Comparison of load forecast results for region 4

图 6. 地区 4 负荷预测结果对比




Figure 7. Comparison of load forecast results for region 5

图 7. 地区 5 负荷预测结果对比

Table 1. RMSE (kW) comparison
表 1. RMSE (kW)对比

地区	集中式 LSTM	FedAvg	DFL
1	351.1813	172.9268	145.0540
2	890.2984	504.4327	306.7956
3	1133.1096	773.6775	500.1387
4	2591.5062	1348.7641	977.9310
5	750.1747	631.5976	434.3824

Table 2. MAPE (%) comparison
表 2. MAPE (%)对比

地区	集中式 LSTM	FedAvg	DFL
1	4.046	2.712	2.529
2	3.774	2.567	1.472
3	5.039	3.845	2.281
4	6.142	3.926	2.254
5	3.263	2.361	1.315

Table 3. Training rounds comparison
表 3. 训练轮次对比

地区	集中式 LSTM	FedAvg	DFL
1	25	18	16
2	24	21	16
3	23	20	15
4	23	19	16
5	24	18	15

Table 4. Comparison of training times
表 4. 训练时间对比

地区	FedAvg	DFL
1	190 s	145 s
2	218 s	143 s
3	206 s	136 s
4	185 s	147 s
5	178 s	131 s
总训练时间	997 s	702 s

从图 4~8 可以看出, 从集中式 LSTM 方法到 FedAvg 方法到本文使用的 DFL-LSTM 方法, 负荷预测曲线中实际负荷与预测结果的差距呈现出明显的变小。而表 1、表 2 的结果表明, 在每个地区当中, 集中

式 LSTM 预测结果误差普遍较大,在数据量较大的地区 4 的 MAPE 甚至超过了 6%,而 FedAvg 方法虽然通过联邦提升了数据的共享训练,但是不考虑特征误差的情况下,如面对地区 3 和地区 4 这类负荷数据量繁杂的情况下,仍存在较大的误差,这表明仅仅引入联邦学习还不足以解决实际情况中数据量多,特征繁杂的复杂情况,对于误差的控制还有所欠缺。而使用本文所提方法,在负荷波动较大的时段,能够更准确地捕捉趋势。例如,在地区 3,使用 FedAvg 预测的负荷峰值比实际负荷低 332.97 kW,而 DFL 方法的误差减少至 112.54 kW,误差降低了 66.2%。表 3、表 4 的结果表明,通过引入动态联邦聚合,有效缓解数据异构性,相比于集中式 LSTM 方法和 FedAvg 方法,本文方法的模型收敛速度更快,训练损失曲线如下图 8 所示,收敛速度分别提升 34.4%和 21.7%,而动态联邦学习中的局部动态更新和梯度信息剪枝上传使得最终的通信效率得到提升,相比于 FedAvg 方法,本文方法训练时间也减少 29.6%,对于实时性较强的 LA 模式更加具有实际使用价值。




Figure 8. Comparison of training losses

图 8. 训练损失对比

5. 结论

本文提出了基于 LA 模式的动态联邦学习短期负荷预测方法,主要研究成果如下:

- 1) 考虑用户参与 DR 的满意度,构建了和负荷转移呈负相关的函数模型反映用户满意度,进而刻画其在 DR 实际项目中的参与度对预测结果的影响。
- 2) 在预测方法方面,在当前负荷聚合商模式下利用 LSTM 方法构建 DR 信号的负荷预测模型的基础进一步考虑数据隐私和样本不足的问题,利用联邦学习联合多地区共同进行预测,同时构建动态权重系数,建立了动态联邦学习方法 DFL,考虑了数据分布差异,使得高质量数据对全局模型贡献更大。而由于动态权重减少了无效参数更新,训练轮数减少,DFL 方法的训练轮次相比 FedAvg 减少 21.7%,训练时

间减少 29.6%，相比集中式 LSTM 减少 34.4%，DFL 方法的收敛速度更快，说明动态权重聚合能够减少无效参数更新，加快模型收敛，计算和数据通信效率更高，更适用于实际电力市场应用。

3) 对比 3 种场景下的平均值，相比集中式 LSTM，本文方法在 RMSE 误差上减少 58.9%，MAPE 误差降低 55.2%，显著提高预测准确度。相比传统联邦学习(FedAvg)，本文方法在 RMSE 误差上减少 31.2%，MAPE 误差降低 41.2%，表明 DFL 方法能够更有效地处理数据异构性。

通过实验验证，动态联邦学习算法(DFL)相比传统的集中式 LSTM 和传统的联邦学习算法，能够有效提高预测精度，减少误差，并保护数据隐私。实验结果表明，DFL 能够动态调整聚合权重，提高模型的泛化能力，尤其在多个负荷聚合商协同训练的情况下，能够显著减少误差并提升预测精度，相比传统方法，在预测误差、计算效率、数据异构性适应能力等方面均表现优越，为 LA 模式下的智能电力调度提供了可靠的技术支撑。

参考文献

- [1] 张钦, 王锡凡, 王建学, 等. 电力市场下需求响应研究综述[J]. 电力系统自动化, 2008, 32(3): 97-106.
- [2] 杨旭英, 周明, 李庚银. 智能电网下需求响应机理分析与建模综述[J]. 电网技术, 2016, 40(1): 220-226.
- [3] 唐学军, 韩佳, 苗世洪, 等. 基于需求侧响应的多类型负荷协调控制模型[J]. 电力系统保护与控制, 2017, 45(16): 116-123.
- [4] Li, B., Shen, J., Wang, X. and Jiang, C. (2016) From Controllable Loads to Generalized Demand-Side Resources: A Review on Developments of Demand-Side Resources. *Renewable and Sustainable Energy Reviews*, 53, 936-944. <https://doi.org/10.1016/j.rser.2015.09.064>
- [5] 陈丽娜, 张智晟, 于道林. 基于广义需求侧资源聚合的电力系统短期负荷预测模型[J]. 电力系统保护与控制, 2018, 46(15): 45-51.
- [6] 车亮, 徐茂盛, 崔秋实. 基于联邦学习的短期负荷预测模型协同训练方法[J]. 湖南大学学报(自然科学版), 2022, 49(8): 117-127.
- [7] Konečný, J., McMahan, H.B., Yu, F.X., et al. (2017) Federated Learning: Strategies for Improving Communication Efficiency. <https://arxiv.org/pdf/1610.05492.pdf>
- [8] 韩富佳, 王晓辉, 乔骥, 等. 基于人工智能技术的新型电力系统负荷预测研究综述[J]. 中国电机工程学报, 2023, 43(22): 8569-8592.
- [9] 孙静, 彭勇刚, 倪旖旎, 等. 基于改进联邦学习算法的电力负荷预测方法[J]. 高电压技术, 2024, 50(7): 3039-3049.
- [10] 黄一川, 宋瑜辉, 荆朝霞. 基于联邦学习的能源聚合服务商负荷预测[J]. 电力建设, 2025, 46(1): 37-47.