

基于自适应联邦学习与 ADMM 的分布式无功优化

刘志远, 许江蛟

(上海电力大学 电气工程学院, 上海 200090)

摘要: 针对高比例分布式能源的接入背景下跨区域电网对高效可靠无功优化的需求, 以及区域间敏感运行数据无法直接共享等问题, 提出一种基于自适应联邦学习与 ADMM(交替方向乘子法)的分布式无功优化方法。首先, 通过联邦学习在各节点开展分布式训练, 以模型参数交换代替原始数据传输, 在保障数据隐私的同时完成边界量估计; 其次, 引入自适应学习率和早停策略, 动态调整学习率并终止冗余训练, 从而降低计算与通信开销; 再次, 将联邦学习的预测结果嵌入 ADMM 迭代, 利用预测量替代部分跨区域传输的边界变量, 提升收敛效率与稳定性。最后, 在 IEEE 9 节点、IEEE 33 节点和 IEEE 118 节点系统中进行仿真分析, 验证了所提方法的有效性。

关键词: 无功优化; 联邦学习; 交替方向乘子法; 隐私保护; 自适应算法

DOI: 10.19585/j.zjdl.202606007

开放科学(资源服务)标识码(OSID): 

Distributed reactive power optimization based on adaptive federated learning and ADMM

LIU Zhiyuan, XU Jiangjiao

(College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: To address the need for efficient and reliable reactive power optimization in interconnected power grids with high penetration of distributed energy resources, as well as the constraint that sensitive operational data cannot be directly shared across regions, a distributed reactive power optimization method based on adaptive federated learning (AFL) and the alternating direction method of multipliers (ADMM) is proposed. First, federated learning is employed to perform distributed training across multiple nodes, where model parameter exchange replaces raw data transmission, enabling boundary variable estimation while preserving data privacy. Second, an adaptive learning rate and an early stopping strategy are introduced to dynamically adjust the learning rate and terminate redundant training, thereby reducing computational and communication overhead. Third, the predictions obtained from federated learning are embedded into the ADMM iterative process, where the predicted values are used to replace part of the boundary variables that would otherwise require inter-regional exchange, thus improving convergence efficiency and stability. Finally, simulation studies on the IEEE 9-bus, IEEE 33-bus, and IEEE 118-bus systems verify the effectiveness of the proposed method.

Keywords: reactive power optimization; federated learning; ADMM; privacy preservation; adaptive algorithm

0 引言

智能电网作为未来电力系统的核心, 具备信息与能量的双向流动特性, 显著提升了电力分配的控制水平、效率、安全性和可靠性^[1]。无功优化是智能电网运行调控的关键环节, 通过优化无功电源出力, 可实现满足无功负荷需求、稳定母线电压、降低网络有功损耗、缓解输电阻塞等核心目标, 同时为系统提供充足的无功备用, 保障

正常运行与紧急工况下的安全稳定。自 20 世纪 60 年代以来, 无功优化便成为电力系统运行优化领域的核心研究方向, 近几十年来涌现出大量优化技术^[2-4]。然而, 传统集中式计算方法虽能有效求解无功优化问题, 但在大规模互联智能电网中, 尤其涉及跨区域传输敏感数据时, 面临可扩展性与隐私保护的双重挑战^[5-6]。因此, 如何在保障数据隐私的前提下提升计算效率, 成为智能电网亟待解决的核心问题。

为应对智能电网规模化带来的挑战, 分布式方法被提出并广泛应用于无功优化问题^[7-8]。文献[9]提出完全去中心化的 ADMM(交替方向乘子

法), 仅需交换相邻子系统边界母线的有限信息, 即可有效降低信息传输与计算负担, 为分布式优化提供了核心框架; 文献[10]构建适用于大规模电力系统的双层ADMM框架, 缓解大规模场景下收敛困难的问题; 文献[11]结合二阶锥规划与共识ADMM, 解决配电网无功优化的非凸求解与计算耗时问题。然而, 这些方法未能充分考虑数据隐私, 在节点间交换原始数据, 在涉及敏感信息的场景下存在数据泄露风险。

针对数据隐私问题, 近年来提出DP(差分隐私)方法^[12]和HE(同态加密)方法^[13]。文献[14]提出了DP-ADMM, 通过增广拉格朗日与时变高斯噪声注入, 解决了在隐私保护下效率低的问题。文献[15]提出原始-对偶增广拉格朗日法, 以拉普拉斯噪声扰动实现DP, 解决多智能体分布式优化中的敏感信息泄露和计算负担问题。文献[16]提出带拉普拉斯平滑的DP随机ADMM框架, 通过方差缩减和拉普拉斯噪声提升效用。然而, DP法向共享变量添加随机扰动, 这可能会影响到最优解的准确性。文献[17]将HE算法与ADMM相结合, 在优化过程中确保隐私, 取得了较好的优化效果。文献[18]提出了一种基于HE和ADMM的完全分布式算法, 实现了网络化微电网集群中的能源共享和公平分配, 同时保障了系统的隐私安全。然而, 基于HE的方法需要频繁进行加密和解密过程, 这会占用大量计算资源, 从而降低收敛速度。综上, 现有方法在隐私保护方面取得了进展, 但未能有效平衡计算效率与数据隐私保护。

FL(联邦学习)作为新兴的隐私保护框架, 为不直接共享原始数据的分布式计算提供了有效解决方案, 已在医学^[19]、金融^[20]、智能交通^[21]等领域应用; 在电力系统中用于负荷预测、需求响应和故障检测等任务^[22-24]。然而, 现有的FL方法缺乏对不同节点训练进度的自适应调整机制, 导致训练效率低下, 且未充分利用节点的计算资源。

基于以上分析, 本文提出融合AFL(自适应联邦学习)与ADMM的分布式无功优化方法。该方法引入FL框架, 通过在本地训练并交换模型参数(而非原始数据), 从而避免敏感信息的泄露; 利用ADMM处理无功优化问题中的约束条件, 确保算法的收敛性和稳定性。为提高求解效率, 本文还引入了自适应学习率机制, 通过动态调整学习

率以适应各节点的训练进度。该机制能够加速模型收敛, 减少冗余计算, 降低通信开销。仿真结果表明, AFL-ADMM算法在IEEE 9节点、IEEE 33节点以及IEEE 118节点系统中, 在保证数据隐私的同时, 显著提升了求解精度和收敛速度, 表现出良好的鲁棒性, 验证了该方法在大规模电网中的优越性。

1 分布式无功优化模型

1.1 潮流模型

对于径向网络各支路潮流方程如下:

$$P_{n+1} = P_n - r_n \frac{P_n^2 + Q_n^2}{V_n^2} - p_{n+1} \quad (1)$$

$$Q_{n+1} = Q_n - x_n \frac{P_n^2 + Q_n^2}{V_n^2} - q_{n+1} \quad (2)$$

$$V_{n+1}^2 = V_n^2 - 2(r_n P_n + x_n Q_n) + K_n \quad (3)$$

$$|S_{n-1}| \leq S_{n-1}^{\max} \quad (4)$$

$$p_{n+1} = P_{nL} - P_{nG} \quad (5)$$

$$q_{n+1} = Q_{nL} - Q_{nG} \quad (6)$$

式中: n 为节点编号; P_n 和 Q_n 分别为从节点 n 流向节点 $n+1$ 的有功、无功潮流; V_n 为节点 n 处的电压幅值; r_n 和 x_n 分别为节点 n 和节点 $n+1$ 之间的电阻、电抗; S_{n-1} 为节点 $n-1$ 到 n 传输的视在功率; $S_{n-1}^{\max}$ 为节点 $n-1$ 到 n 传输的最大视在功率容量; $K_n = (r_n^2 + x_n^2) \frac{P_n^2 + Q_n^2}{V_n^2}$ 为电压降的二次修正项; p_{n+1} 和 q_{n+1} 分别为节点 $n+1$ 处的有功功率、无功功率; P_{nL} 为节点 n 处负载消耗的有功功率; Q_{nL} 为节点 n 处负载消耗的无功功率; P_{nG} 为节点 n 处 DG(分布式电源)输出的有功功率; Q_{nG} 为节点 n 处 DG 输出的无功功率。

为满足实时无功优化的要求, 本文假定在优化过程中, 有功功率维持不变。规定节点 n 对应的负载有功功率 P_{nL} 、DG 的有功功率 P_{nG} 及负载无功功率 Q_{nL} 均为固定量, 仅 DG 的无功功率 Q_{nG} 可在其允许限值范围内调节。初始节点 1 的电压 V_1 为固定值, 终端节点 n 的有功功率 P_n 和 Q_n 均取零。

1.2 无功优化模型

分布式无功优化通常以最小化系统运行成本为目标, 在满足各种约束的基础上, 通过调整系统中的控制变量(如发电机输出功率、无功电源等), 实现电力系统的经济运行。本文的目标是通

由于ADMM在每次迭代中仅需获取下一轮迭代所需的数据,因此利用前3次迭代的数据足以有效捕捉系统的变化并进行预测。此外,本文采用

的XGBoost模型能够高效地从电力系统时序性优化问题中提取前3步数据所蕴含的复杂非线性模式。选择3个时间步的数据不仅能够保证预测精度,还能显著提高模型的训练效率。为加速模型收敛并提升训练效率,本文对功率数值进行归一化处理:

$$\tilde{X}_{nk} = \frac{X_{nk} - \min(X_n)}{\max(X_n) - \min(X_n)} \quad (20)$$

式中: X_{nk} 为原始数据; $\tilde{X}_{nk}$ 为归一化后的数据; $\min(X_n)$ 和 $\max(X_n)$ 分别为节点 n 对应数据的历史最小值、最大值。

节点 n 输入的数据如下:

$$I_n = [\tilde{P}_{nk}, \tilde{Q}_{nk}, \tilde{V}_{nk}] \quad (21)$$

选用XGBoost作为预测模型,该模型对稀疏电力数据适配性强、收敛速度快,目标函数可平衡预测精度与模型复杂度,公式为:

$$L(\theta) = \sum_{i=1}^N l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (22)$$

式中: θ 为模型参数; y_i 为真实值; $\hat{y}_i$ 为预测值; $\Omega(f_k)$ 为正则项,用于防止模型的过拟合。

训练好的模型参数打包成参数集合 θ_n , 传递到相邻节点,完成底层ADMM的优化。

2.2 AFL-ADMM

ADMM是求解大规模带耦合约束优化问题的迭代算法,其通过引入增广拉格朗日函数实现分解求解:

$$\mathcal{L}_\rho(x, z, y) = f(x) + g(z) + y^T(x - z) + \frac{\rho}{2} \|x - z\|^2 \quad (23)$$

式中: x 和 z 为待优化变量,可通过约束关联; $f(x)$ 和 $g(z)$ 为两个可分离的目标函数; y 为拉格朗日乘子; ρ 为惩罚参数。

ADMM通过交替更新变量实现优化,核心的3步迭代如下所示:

$$x^{k+1} = \underset{x}{\operatorname{argmin}} \left[f(x) + y^{kT}(x - z^k) + \frac{\rho}{2} \|x - z^k\|^2 \right] \quad (24)$$

$$z^{k+1} = \underset{z}{\operatorname{argmin}} \left[g(z) + y^{kT}(x^{k+1} - z) + \frac{\rho}{2} \|x^{k+1} - z\|^2 \right] \quad (25)$$

$$y^{k+1} = y^k + \rho(x^{k+1} - z^{k+1}) \quad (26)$$

重复上述3步,直到满足收敛判据:

$$\|x^{k+1} - z^{k+1}\| \leq \epsilon_{\text{pri}} \quad (27)$$

$$\|\rho(z^{k+1} - z^k)\| \leq \epsilon_{\text{dual}} \quad (28)$$

式中: ϵ_{pri} 和 ϵ_{dual} 为误差容忍阈值,当相邻两次迭代的差值小于阈值时,认为迭代已足够接近最优解,可终止计算。

为确保数据隐私,ADMM不再直接接收相邻节点的原始数据,而是在每轮迭代开始前接收相邻节点的模型参数。在迭代过程中,各节点通过模型预测来估算必要的数值,为后续迭代步骤提供数据支持。结合式(12)和式(23)得到的拉格朗日函数为:

$$\begin{aligned} \mathcal{L}_n(X_n) = & F(\bar{Q}_{n-1}) + y_n(\bar{Q}_{n-1} - Q_n^{\text{pred}}) + \\ & y_n^+(\bar{Q}_{n+1}^{\text{pred}} - Q_n) + \frac{\rho}{2} \|\bar{Q}_{n-1} - Q_{n-1}^{\text{pred}}\|_2^2 + \\ & \frac{\rho}{2} \|\bar{Q}_{n+1}^{\text{pred}} - Q_n\|_2^2 \end{aligned} \quad (29)$$

式中: $\bar{Q}_{n+1}^{\text{pred}}$ 和 Q_{n-1}^{pred} 分别为节点 $n+1$ 到节点 n 和节点 $n-1$ 到节点 n 的无功功率局部变量预测值、全局变量预测值,这两个变量均由节点 n 基于模型推算得到; $\bar{Q}_{n-1}$ 和 Q_n 分别为节点 n 到节点 $n-1$ 和节点 n 到节点 $n+1$ 的无功功率的局部变量、全局变量,这两个变量是节点 n 本身的变量,不需要预测。

对于第 k 次迭代,由式(29)推导出改进的ADMM迭代公式如下:

$$X_n(k+1) = \underset{x_n}{\operatorname{argmin}} \{ \mathcal{L}_n(X_n) | I(X_m) \leq 0, E(X_m) = 0 \} \quad (30)$$

$$Q_n(k+1) = \frac{1}{2} (\bar{Q}_{n+1}^{\text{pred}}(k+1) + \bar{Q}_n(k+1)) + \frac{1}{\xi_n} y_n^+(k) \quad (31)$$

$$y_n(k+1) = y_n(k) + \rho(Q_{n-1}(k+1) - Q_{n-1}^{\text{pred}}(k)) \quad (32)$$

$$y_n^+(k+1) = y_n^+(k) + \rho(\bar{Q}_{n+1}^{\text{pred}}(k+1) - Q_n(k)) \quad (33)$$

式中: $\frac{1}{\xi_n}$ 为节点 n 的迭代因子。

AFL-ADMM的求解过程如下:通过分层协作框架,FL层首先在各节点本地训练预测模型,并通过交换模型参数实现隐私保护,避免原始数据的直接传输;在此基础上,ADMM利用模型提

供的预测结果(如 Q_{n-1}^{pred} 、 $\bar{Q}_{n+1}^{\text{pred}}$)替代需跨区域交换的边界变量, 驱动优化过程; 最终通过各节点并行求解本地优化子问题, 协同输出全局最优解。值得注意的是, 在每次迭代中, 节点基于离线训练的模型自动估算邻节点信息, 该过程几乎不产生额外计算开销, 可提升算法的整体效率。算法求解流程如图2所示。




图2 AFL-ADMM算法流程

Fig.2 Flowchart of the AFL-ADMM algorithm

3 AFL训练加速

在大规模分布式环境中, 由于节点数量庞大且每个节点均需独立训练模型, 训练过程将消耗大量计算资源, 进而影响整体训练效率。本文采用自适应学习率机制, 动态调整各节点的学习率, 以便根据每个节点的实际训练进度进行优化。

3.1 自适应学习率

第 k 轮树迭代的学习率 η_i 由初始学习率与余弦

衰减因子共同决定, 公式如下:

$$\eta_i = \eta_0 \cos\left(\frac{\pi k}{2K}\right) \quad (34)$$

式中: η_i 为第 i 棵树的学习率; η_0 为初始学习率; k 为当前迭代轮次 ($k=1, 2, \dots, K$), 每轮对应一个新树的生成; K 为预设最大树的数量。

该策略借助余弦函数的平滑衰减特性, 实现学习率的分阶段优化: 早期迭代阶段 ($k \ll K$) 学习率较大, 可快速捕捉数据主分布模式以加速收敛; 后期迭代阶段 ($k \rightarrow K$) 学习率逐渐衰减, 避免模型因过度拟合噪声而振荡, 保障精度。

3.2 模型更新过程

本文将自适应学习率融入 XGBoost 的迭代过程, 第 k 轮模型更新公式修正为:

$$f_k(x) = f_{k-1}(x) + \eta_k h_k(x) \quad (35)$$

式中: $f_k(x)$ 为第 k 轮迭代后模型的预测函数, 输出对样本 x 的预测结果; $f_{k-1}(x)$ 为第 $k-1$ 轮迭代后的模型, 作为当前轮次的基础模型; $h_k(x)$ 为第 k 轮新生成的决策树, 通过梯度下降优化当前模型的残差得到。

3.3 早停终止机制

为避免达到最大树数量 K 前的无效迭代, 本文设计了基于验证集损失的早停条件:

$$\min_{t=k-S+1, \dots, k} L_{\text{val}}(f_t) \geq L_{\text{val}}(f_{k-S}) - \epsilon \quad (36)$$

式中: $L_{\text{val}}(f_t)$ 为第 t 轮模型在验证集上的损失; S 为早停窗口(连续监测的轮次); ϵ 为损失最小改进阈值, 损失提升小于该值, 视为模型性能无显著优化。

若连续 S 轮验证集损失满足式(36), 则终止训练。早停机制在模型通过早期大学习率快速收敛至稳定状态后, 及时终止训练, 减少冗余树的生成, 从根本上缩短训练时间。

4 算例仿真

本文采用 IEEE 9 节点、IEEE 33 节点以及 IEEE 118 节点系统进行算例仿真分析, 风力发电机和光伏发电机分别安装于指定位置, 如图3—5所示。实验采用的计算机配置为 AMD Ryzen 7 4800H CPU 和 16 GB 内存, 相关算法程序通过 Python 3.12.3 开发。

为验证 AFL-ADMM 的性能优势, 本文选取




图3 IEEE 9节点系统

Fig.3 IEEE 9-bus system




图4 IEEE 33节点系统

Fig.4 IEEE 33-bus system




图5 IEEE 118节点系统

Fig.5 IEEE 118-bus system

FL-ADMM、ADMM、GA(遗传算法)、DP-ADMM以及HE-ADMM作为对比算法。其中,GA、DP-ADMM、HE-ADMM的关键参数设置如表1所示。

4.1 求解速度分析

本节将分析AFL-ADMM在不同规模电网系

表1 关键参数设置

Table 1 Key parameter settings

算法	关键参数设置
GA	种群规模: 200; 交叉概率: 0.8; 变异概率: 0.05
DP-ADMM	隐私预算 $\epsilon=1.0$; 噪声分布: 拉普拉斯; 惩罚参数 $\rho=1.5$
HE-ADMM	加密方案: Paillier; 密钥长度: 1 024位; 惩罚参数 $\rho=1.2$

统中的求解速度表现,并与上述主流优化算法进行对比。特别地,本文将Gurobi求解器作为集中式精确求解的基准,以评估本文算法在计算效率和性能上的优势。实验结果见表2—4。

表2 IEEE 9节点系统中不同算法的性能比较

Table 2 Performance comparison of different algorithms in the IEEE 9-bus system

算法	平均训练 轮次	平均训练时间 /s	收敛时间 /ms	有功损耗 /MW
AFL-ADMM	55	27.3	98.24	0.160
FL-ADMM	100	50.5	128.9	0.161
DP-ADMM	—	—	182.90	0.163
HE-ADMM	—	—	320.50	0.163
ADMM	—	—	86.87	0.161
GA	—	—	1 914.98	0.161
Gurobi	—	—	581.54	0.158

表3 IEEE 33节点系统中不同算法的性能比较

Table 3 Performance comparison of different algorithms in the IEEE 33-bus system

算法	平均训练 轮次	平均训练时间 /s	收敛时间 /ms	有功损耗 /MW
AFL-ADMM	70	59.8	238.15	0.123
FL-ADMM	150	151.5	312.47	0.124
DP-ADMM	—	—	349.16	0.128
HE-ADMM	—	—	776.94	0.127
ADMM	—	—	230.10	0.126
GA	—	—	2 219.71	0.124
Gurobi	—	—	1 085.13	0.121

表4 IEEE 118节点系统中不同算法的性能比较

Table 4 Performance comparison of different algorithms in the IEEE 118-bus system

算法	平均训练 轮次	平均训练 时间/s	收敛时间 /ms	有功损耗 /MW
AFL-ADMM	87	70.1	298.10	1.049
FL-ADMM	170	136.2	391.13	1.053
DP-ADMM	—	—	437.05	1.058
HE-ADMM	—	—	972.50	1.057
ADMM	—	—	300.64	1.051
GA	—	—	5 695.43	1.064
Gurobi	—	—	3 811.54	1.046

AFL-ADMM和FL-ADMM在上层包含了模型训练过程,AFL-ADMM采用离线训练策略,各节点仅从离线训练的模型中获取预测数据,几乎不消耗额外的计算时间。其他未引入预测模型

的算法(如ADMM、DP-ADMM、HE-ADMM、GA和Gurobi),不涉及训练过程,无训练轮次和训练时间的统计。由表2—4可知,AFL-ADMM在不同规模电网系统中均表现出显著的性能优势。从上层FL模型的训练速度来看,AFL-ADMM在IEEE 9节点、33节点和118节点系统中各节点的平均训练时间分别为27.3 s、59.8 s和70.1 s,而FL-ADMM分别为50.5 s、151.5 s和136.2 s,表明AFL-ADMM的训练效率更高。在收敛性能方面,AFL-ADMM同样优于其他对比算法,其收敛时间和功率损耗均更低,且结果接近Gurobi求解器的表现,这进一步验证了AFL-ADMM在计算效率与优化精度上的优势。

在隐私保护方面,虽然DP-ADMM添加了噪声保护数据,但噪声会降低优化精度;HE-ADMM使用HE,虽然能保护隐私,通过解密仍可恢复原始数据,但消耗大量计算资源;ADMM、GA、Gurobi未采用加密机制,直接处理原始数据。相比之下,AFL-ADMM将原始数据转化为模型参数,避免了解密过程,从而有效保障数据隐私。

4.2 收敛性能分析

实验以系统总有功损耗作为核心评价指标。一方面,有功损耗最小化是无功优化问题的核心经济目标,其值直接反映了算法的优化精度;另一方面,有功损耗在迭代过程中的变化轨迹能够有效体现算法的收敛速度与稳定性。因此,通过观察有功损耗的变化,不仅能直观比较各算法在不同阶段的优化效果,还能从经济性和收敛性两个维度全面评估算法性能。各算法的收敛特性如图6—8所示。

如图6—8所示,在IEEE 9节点系统和IEEE 33节点系统中,各算法的收敛特性与优化性能存在显著差异:ADMM初期收敛较快,50次迭代内有功损耗从0.21 MW降至约0.16 MW,但后期出现收敛停滞;GA前期收敛速度较慢,迭代过程波动明显,稳定性差且最终精度最低;DP-ADMM因噪声扰动导致收敛曲线振荡显著,隐私保护与收敛性能之间存在明显的权衡矛盾;HE-ADMM受加密计算开销影响,收敛速度略低于ADMM,曲线略有波动,但整体趋于稳定;FL-ADMM性




图6 IEEE 9节点系统中不同算法的收敛性能对比
Fig.6 Convergence comparison of different algorithms in the IEEE 9-bus system




图7 IEEE 33节点系统中不同算法的收敛性能对比
Fig.7 Convergence comparison of different algorithms in the IEEE 33-bus system




图8 IEEE 118节点系统中不同算法的收敛性能对比
Fig.8 Convergence comparison of different algorithms in the IEEE 118-bus system

能优于GA和DP-ADMM,但其收敛速度与稳定性逊色于引入自适应机制的本文算法;本文提出的AFL-ADMM收敛最快且曲线最平滑,150次迭代内即可达到与ADMM相当的精度,最终有功损耗与ADMM、HE-ADMM等相近(约0.12~0.16 MW)。

此外,本文对 IEEE 118 节点系统进行实验分析,验证了 AFL-ADMM 在大规模系统中的表现。图 8 展示了在该系统中的收敛性能,结果与其他系统实验一致。在大规模系统中,集中式 GA 收敛较慢, AFL-ADMM 能够达到与其他分布式算法相似的表现(约 1.049 MW),显示出其在大规模系统中的有效性。

该算法在平衡收敛速度、优化精度与隐私保护方面表现最佳,尤其适用于配电网优化场景。

4.3 稳定性分析

本节验证了通信故障对算法性能的影响,并对比 AFL-ADMM 与传统 ADMM 的表现。通信故障通常由网络不稳定引发,表现为数据包在传输过程中以一定概率丢失。为模拟实际系统中的典型轻度通信故障场景,本文在邻近节点间的每次通信交互中引入独立发生概率为 2% 的随机丢包,不同算法的稳定性对比如图 9—11 所示。




图 9 IEEE 9 节点系统中不同算法的稳定性对比
Fig.9 Stability comparison of different algorithms in the IEEE 9-bus system




图 10 IEEE 33 节点系统中不同算法的稳定性对比
Fig.10 Stability comparison of different algorithms in the IEEE 33-bus system




图 11 IEEE 118 节点系统中不同算法的稳定性对比
Fig.11 Stability comparison of different algorithms in the IEEE 118-bus system

从图 9—11 可见, AFL-ADMM 在通信故障情况下的稳定性表现优异。传统 ADMM 需交换大量数据, 容易受到通信故障影响, 从而导致迭代不稳定和优化误差增加。AFL-ADMM 仅交换部分参数, 且关键数据来自模型, 显著降低了通信开销, 提高了对网络故障的鲁棒性。因此, 即便在通信故障情况下, AFL-ADMM 仍能高效优化, 减少与全局最优解的偏差。

在 IEEE 9 节点系统中, AFL-ADMM 功率损耗为 0.161 MW, 较传统 ADMM 降低 0.001 5 MW, 表明其在小规模系统中同样保持稳定, 并可减少因通信故障引发的波动。该结果进一步验证了 AFL-ADMM 在不同规模系统中, 特别是在通信故障环境下的稳定性优势。

在 IEEE 33 节点系统中, AFL-ADMM 将功率损耗降至 0.123 MW, 比传统 ADMM 降低了 0.001 83 MW, 表明其在通信不稳定环境下仍能维持低功率损耗, 可保证电网运行效率。相比之下, 传统 ADMM 因交换原始数据而导致性能下降, 功率损耗较高。

在 IEEE 118 节点系统中, AFL-ADMM 在面对通信故障时, 收敛波动更小, 能够保持稳定收敛, 而 ADMM 则出现明显的振荡。

5 结论

本文提出一种基于 AFL-ADMM 的分布式无功优化方法, 通过仿真分析得到如下结论:

1) AFL-ADMM 能够在不交互原始敏感运行数据的前提下, 通过预测数据实现电力系统分布

式无功优化求解。该算法在保证计算精度的同时,保护了敏感数据的隐私。

2) 自适应学习率机制的引入使得 AFL-ADMM 能够根据每个节点的训练进度动态调整学习率,从而优化训练过程中的计算效率。该机制不仅减少了训练轮次,还显著提升了模型性能。

3) AFL-ADMM 在隐私保护的无功优化问题中具有可行性,可有效降低网络损耗,减少收敛波动,且在不同规模系统中均表现良好。

本文算法在多种分布式优化场景、系统规模及通信环境下均展现出良好的适应性、灵活性与可扩展性,尤其适用于高比例分布式能源接入的跨区域电网、数据敏感应用场景及通信受限环境。需要指出,本文工作仅为初步探索,后续研究将重点分析网络攻击等因素对算法性能的影响。

参考文献

- [1] 邵海明,王家福,李传生,等.面向新型电力系统的高电压计量技术研究进展及展望[J].高电压技术,2026,52(2):493-508.
SHAO Haiming, WANG Jiafu, LI Chuansheng, et al. Review and prospect on the research status of high-voltage metrology technology for new-type power systems [J]. High Voltage Engineering, 2026, 52(2): 493-508.
- [2] PESCHOL J, PIERCY D, TINNEY W, et al. Optimum control of reactive power flow [J]. IEEE Transactions on Power Apparatus and Systems, 1968, PAS-87(1): 40-48.
- [3] ZHAO B, GUO C X, CAO Y J. A multiagent-based particle swarm optimization approach for optimal reactive power dispatch [J]. IEEE Transactions on Power Systems, 2005, 20(2): 1070-1078.
- [4] TAKAHASHI N, HAYASHI Y. Centralized voltage control method using plural D-STATCOM with controllable dead band in distribution system with renewable energy [C]//2012 3rd IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe). October 14-17, 2012, Berlin, Germany. IEEE, 2012: 1-5.
- [5] 金煜,焦康威.智能用电互动模式及安全性研究[J].电工技术,2025(16):174-183.
JIN Yu, JIAO Kangwei. Research on intelligent electricity interaction mode and security [J]. Electric Engineering, 2025(16): 174-183.
- [6] 李忠凡,陈曦,黄海涛.基于多智能体分层强化学习的多园区综合能源系统优化运行[J].浙江电力,2025,44(9):46-57.
LI Zhongfan, CHEN Xi, HUANG Haitao. Optimal operation of MPIESs based on hierarchical multi-agent reinforcement learning [J]. Zhejiang Electric Power, 2025, 44(9): 46-57.
- [7] 刘海天,郭焱,石剑涛,等.分布式优化在互联电网中的应用分析及展望[J].电力系统自动化,2024,48(22):22-42.
LIU Haitian, GUO Ye, SHI Jiantao, et al. Application analysis and prospect of distributed optimization in interconnected power grid [J]. Automation of Electric Power Systems, 2024, 48(22): 22-42.
- [8] 王江,杨军,骆亚帅,等.考虑分区规模平衡性的主动配电网无功电压优化方法[J].浙江电力,2025,44(9):81-91.
WANG Jiang, YANG Jun, Luo Yashuai, et al. A reactive voltage optimization method for active distribution networks considering partition size balancing [J]. Zhejiang Electric Power, 2025, 44(9): 81-91.
- [9] WANG Y M, WU L, WANG S X. A fully-decentralized consensus-based ADMM approach for DC-OPF with demand response [J]. IEEE Transactions on Smart Grid, 2017, 8(6): 2637-2647.
- [10] SUN K Z, SUN X A. A two-level ADMM algorithm for AC OPF with global convergence guarantees [J]. IEEE Transactions on Power Systems, 2021, 36(6): 5271-5281.
- [11] OH B, LEE D H, JEONG W C, et al. Distributed optimal power flow for distribution system using second order cone programming and consensus alternating direction method of multipliers [J]. Journal of Electrical Engineering & Technology, 2022, 17(2): 999-1008.
- [12] 陈池瑶,苗世洪,姚福星,等.基于多智能体算法的多微电网-配电网分层协同调度策略[J].电力系统自动化,2023,47(10):57-65.
CHEN Chiyao, MIAO Shihong, YAO Fuxing, et al. Hierarchical cooperative dispatching strategy of multi-microgrid and distribution networks based on multi-agent algorithm [J]. Automation of Electric Power Systems, 2023, 47(10): 57-65.
- [13] 郭庆来,田年丰,孙宏斌.支撑能源互联网协同优化的隐私计算关键技术[J].电力系统自动化,2023,47(8):2-14.
Guo Qinglai, Tian Nianfeng, Sun Hongbin. Key technologies of privacy computation supporting collaborative optimization of energy Internet [J]. Automation of Electric Power Systems, 2023, 47(8): 2-14.
- [14] HUANG Z H, HU R, GUO Y X, et al. DP-ADMM: ADMM-based distributed learning with differential privacy [J]. IEEE Transactions on Information Forensics and Security, 2020, 15: 1002-1012.
- [15] LV Y W, YANG G H, SHI C X. Differentially private distributed optimization for multi-agent systems via the augmented Lagrangian algorithm [J]. Information Sciences, 2020, 538: 39-53.

- [16] LIU Y Y, GENG J C, SHANG F H, et al. Laplacian smoothing stochastic ADMMs with differential privacy guarantees [J]. IEEE Transactions on Information Forensics and Security, 2022, 17: 1814-1826.
- [17] WU T, ZHAO C H, ZHANG Y A. Privacy-preserving distributed optimal power flow with partially homomorphic encryption [J]. IEEE Transactions on Smart Grid, 2021, 12 (5): 4506-4521.
- [18] YUAN Z P, LI P, LI Z L, et al. A fully distributed privacy-preserving energy management system for networked microgrid cluster based on homomorphic encryption [J]. IEEE Transactions on Smart Grid, 2024, 15 (2): 1735-1748.
- [19] 管桂林, 陶政坪, 支婷, 等. 面向医疗场景的去中心化联邦学习隐私保护方法 [J]. 计算机应用, 2024, 44 (增刊2): 112-117.
- GUAN Guilin, TAO Zhengping, ZHI Ting, et al. Decentralized federated learning privacy protection method for medical scenarios [J]. Journal of Computer Applications, 2024, 44 (S2): 112-117.
- [20] 郑润达, 张维, 张永杰, 等. 金融领域中的联邦学习研究 [J]. 数智技术研究与应用, 2025, 1 (1): 1-17.
- ZHENG Runda, ZHANG Wei, ZHANG Yongjie, et al. Research on federated learning in the field of finance [J]. SmartTech Innovations, 2025, 1 (1): 1-17.
- [21] 智慧, 段苗苗, 杨利霞, 等. 一种基于区块链和联邦学习融合的交通流预测方法 [J]. 电子与信息学报, 2024, 46 (9): 3777-3787.
- ZHI Hui, DUAN Miaomiao, YANG Lixia, et al. A traffic flow prediction method based on the fusion of blockchain and federated learning [J]. Journal of Electronics & Information Technology, 2024, 46 (9): 3777-3787.
- [22] 王蓓蓓, 朱竞, 王嘉乐, 等. 电表数据隐私保护下的联邦学习行业电力负荷预测框架 [J]. 电力系统自动化, 2023, 47 (13): 86-93.
- WANG Beibei, ZHU Jing, WANG Jiale, et al. Federated-learning based industry load forecasting framework under privacy protection of meter data [J]. Automation of Electric Power Systems, 2023, 47 (13): 86-93.
- [23] 郭光华, 亓新宏, 王瑞琪, 等. 基于联邦学习的综合能源系统集成需求响应机制 [J]. 电力自动化设备, 2023, 43 (8): 33-39.
- GUO Guanghua, QI Xinhong, WANG Ruiqi, et al. Integrated demand response mechanism for integrated energy system based on federated learning [J]. Electric Power Automation Equipment, 2023, 43 (8): 33-39.
- [24] 郭方洪, 刘师硕, 吴祥, 等. 基于联邦学习的含不平衡样本数据电力变压器故障诊断 [J]. 电力系统自动化, 2023, 47 (10): 145-152.
- GUO Fanghong, LIU Shishuo, WU Xiang, et al. Federated learning based fault diagnosis of power transformer with unbalanced sample data [J]. Automation of Electric Power Systems, 2023, 47 (10): 145-152.
- [25] TURITSYN K, SULC P, BACKHAUS S, et al. Local control of reactive power by distributed photovoltaic generators [C] // 2010 First IEEE International Conference on Smart Grid Communications. October 4-6, 2010, Gaithersburg, MD, USA. IEEE, 2010: 79-84.

收稿日期: 2025-11-08; 修回日期: 2026-03-14

作者简介:

刘志远(2000), 男, 硕士研究生, 研究方向为智能电网与分布式优化。

许江蛟(1988), 男, 博士, 讲师, 研究方向为人工智能前沿技术应用、新能源预测、需求侧能源管理、分布式最优潮流计算、配电网故障分析与处理等。(通信作者)

(本文编辑: 张瑞敏)