

# 基于隐私保护导向与深度联邦学习的分布式光伏超短期功率预测

于骥<sup>1</sup>, 王玉庆<sup>2</sup>, 甄钊<sup>2</sup>, 王飞<sup>2,3,4</sup>

(1. 长江清源节能环保有限公司, 上海 201722; 2. 华北电力大学电力工程系, 河北 保定 071003; 3. 新能源电力系统国家重点实验室(华北电力大学), 北京 102206; 4. 河北省分布式储能与微网重点实验室(华北电力大学), 河北 保定 071003)

**摘要:** 准确的分布式光伏超短期功率预测对于分布式光伏售电参与电力现货市场起到重要的信息支撑作用。现有方法大多采用集群信息共享的建模方法以提升功率预测精度, 然而这些方法或需依赖数据直接共享, 导致严重的数据隐私问题, 或仅依赖模型交互共享, 虽保障数据隐私性但因其共享信息量薄弱导致预测效果不佳。为此, 提出了一种基于隐私保护导向与深度联邦学习的分布式光伏超短期功率预测。首先构建了基于双层信息交互的联邦学习框架, 以各站间全局模型与全局特征交互的形式实现更丰富的信息共享, 避免了数据直接交互以保障数据隐私。其次以注意力自编码作为本地预测模型挖掘功率时序特征并将其与全局特征耦合为时空关联特征, 通过有效挖掘利用时空关联信息从而提升功率预测精度。最后以河北某地区的实际分布式光伏数据进行仿真实验证明了所提方法的有效性。

**关键词:** 分布式光伏; 超短期功率预测; 时空关联信息; 数据隐私性; 联邦学习; 深度学习

## Distributed Photovoltaic Ultra-Short Term Power Forecasting Based on Privacy Protection Orientation and Deep Federated Learning

YU Ji<sup>1</sup>, WANG Yuqing<sup>2</sup>, ZHEN Zhao<sup>2</sup>, WANG Fei<sup>2,3,4</sup>

(1. Yangtze Clean Energy & Environment Co., Ltd., Shanghai 201722, China; 2. Department of Electrical Engineering, North China Electric Power University, Baoding, Hebei 071003, China; 3. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Beijing 102206, China; 4. Hebei Key Laboratory of Distributed Energy Storage and Microgrid, North China Electric Power University, Baoding, Hebei 071003, China)

**Abstract:** Accurate ultra-short-term power prediction for distributed photovoltaic (PV) systems plays a crucial supporting role in providing essential information for distributed PV electricity sellers participating in the electricity spot market. Most existing methods employ cluster-based information-sharing modeling approaches to improve prediction accuracy. However, these methods either rely on direct data sharing, leading to serious data privacy issues, or depend solely on model interaction sharing. Although data privacy is ensured, the limited amount of shared information leads to poor prediction results. To address these challenges, a privacy-preserving, deep federated learning-based approach is proposed for ultra-short-term power prediction in distributed PV systems. Firstly, a federated learning framework based on dual-layer information interaction is constructed to enable richer information sharing through global model and global feature interactions among stations, avoiding direct data exchange to protect data privacy. Secondly, an attention-based autoencoder is adopted as the local prediction model to extract temporal features of power sequences, which are then coupled with global features to form spatiotemporal correlation features. By effectively mining and utilizing spatiotemporal correlation information, the power prediction accuracy is enhanced. Finally, simulation experiments using actual distributed PV data from a region in Hebei Province demonstrate the effectiveness of the proposed method.

**Key words:** distributed photovoltaic; ultra-short-term power forecasting; spatiotemporal correlation information; data privacy; federated learning; deep learning

## 0 引言

随着“碳达峰、碳中和”目标的提出以及新型电力系统建设的推进,以分布式光伏为代表的分布式电源凭借安装灵活、投资少、就地消纳等优势得到了大力发展<sup>[1-2]</sup>。与此同时政府积极推动分布式发电市场化交易,2022年1月国家发改委和能源局发布了《关于加快建设全国统一电力市场体系的指导意见》<sup>[3]</sup>,要求完善分布式发电市场化交易机制,鼓励分布式光伏参与市场交易。在此背景下,分布式光伏所有者作为售电商参与市场竞争成为必然趋势<sup>[4-5]</sup>。考虑到分布式光伏出力具有随机性和不确定性<sup>[6]</sup>,若分布式光伏售电商能够依据实际出力情况,在现货市场中实时调整交易策略,便可提高交易灵活性,从而获取更大效益。为此,分布式光伏售电商需要精准的超短期功率预测技术,为其交易提供信息支撑<sup>[7-9]</sup>。

现有的光伏超短期功率预测方法可分为3类,分别为物理方法、统计学方法和人工智能方法<sup>[10-12]</sup>。

物理方法从光伏发电原理出发构建发电功率与气象数据或卫星遥感数据之间的转换关系<sup>[13]</sup>。统计学方法例如线性回归、自回归积分滑动平均(autoregressive integrated moving average, ARIMA)模型,通常借助历史时间序列数据以数学和统计学为依据剖析光伏出力的历史变化规律<sup>[14]</sup>。机器学习属于传统的人工智能方法,诸如支持向量机(support vector machine, SVM)<sup>[15]</sup>、反向传播神经网络(back-propagation neural network, BPNN)<sup>[16]</sup>,可直接构建输入与输出之间的非线性映射关系,对先验知识的依赖程度低且易于使用,不过其结构较为简单,效果有限。

为挖掘数据的深层特征,以长短期记忆神经网络(long short term memory, LSTM)<sup>[17]</sup>以及卷积神经网络(convolutional neural network, CNN)<sup>[18]</sup>为代表的深度学习方法目前在光伏功率预测领域得到了广泛应用,其中LSTM是处理时间序列任务的有力工具。为进一步增强LSTM的时间序列建模能力应

用了自编码模型<sup>[19]</sup>。在自编码模型中编码器提取输入各时间步的时域特征,随后解码器平等地利用各时域特征来预测未来功率。实际上,输入的不同时域特征对未来功率的影响程度存在差异,自编码模型的这种处理方式会使解码器面临特征冗余问题,该问题在处理长时间序列时尤为突出<sup>[20]</sup>。

文献[21]引入注意力机制在一定程度上解决了上述特征冗余问题从而实现了本地时序特征的有效挖掘。然而,该研究仍存在局限性,仅考虑了单一光伏自身的时序出力特性而缺乏对其周边站点关联信息的挖掘与利用。集群分布式光伏大多位置毗邻,处于相同的地理环境与气候条件之下因而其出力呈现出相似的波动模式,具备较强的时空相关性。借助周边场站数据挖掘集群关联信息是提升目标站功率预测精度的一项有效措施<sup>[22]</sup>。然而,现有的时空关联信息挖掘方法需将各分布式光伏数据汇聚起来进行统一建模,从而实现关联信息的挖掘与共享<sup>[23]</sup>。由于分布式光伏场站分属不同售电商,其数据涉及各自的核心技术、商业利益等敏感信息。各分布式光伏售电商之间直接共享数据会使数据暴露于公共环境从而面临被外部攻击者进行数据分析、行为探测等风险<sup>[24-25]</sup>,进而引发严重的数据安全问题。尤其在竞争激烈的电力市场中为避免因数据泄露导致电力交易竞争风险,分布式光伏售电商拒绝共享其全部数据<sup>[26-27]</sup>。另一方面,2021年政府正式实施的《中华人民共和国数据安全法》<sup>[28]</sup>,也从法律层面提出了数据隐私保护要求。

为此,一种基于分散式训练的联邦学习框架应运而生。在该框架下,所有原始数据都保存在本地,不会泄露给其他用户,用户只需共享本地模型,通过模型交互实现信息的交互与共享,既能保障数据安全,又能提升模型训练的效率与精度<sup>[29-30]</sup>。

但值得注意的是,模型参数所含信息有限,即便设计结构更复杂、参数量更多的模型,仅依靠模型参数信息的交互共享也难以有效发掘和表征分布式光伏站点间的空间关联信息。因此,现有的联邦学习框架虽能保障数据隐私但对功率预测精度的提升效果有限。

综上所述,现有分布式光伏集群功率预测建模方法一方面在进行集群关联信息挖掘利用时会面临严重的数据安全性问题,另一方面缺乏有效的关联

基金项目: 国家自然科学基金资助项目(52007092)。

Foundation item: Supported by the National Natural Science Foundation of China (52007092).

特征挖掘利用手段。为此,本文提出了一种基于隐私保护导向与深度联邦学习的分布式光伏超短期功率预测方法。首先,针对现有方法在保障隐私前提下关联信息挖掘利用能力有限的问题设计了一种基于双层信息交互的联邦学习框架:一方面根据各场站上传的本地模型与装机容量进行全局模型聚合,而后将全局模型下发供本地场站进行个性化训练;另一方面,聚合各场站的本地时序特征,获取全局空间特征并将其下发至本地场站。由此,通过模型交互与特征共享这种双层信息交互机制,在保证隐私性的前提下,有效挖掘空间关联信息,提升模型功率预测精度。然后,基于上述框架,考虑到现有预测建模方法缺乏有效的特征挖掘手段,提出了一种基于时空关联特征的注意力自编码模型,用于有效利用本地时序特征与全局空间特征。以注意力自编码作为本地深度学习预测模型,利用编码器提取本地站点出力时序特征,利用注意力机制依据编码器输出对本地时序特征与全局空间特征耦合生成的时空关联特征进行自适应加权,使模型聚焦对预测更关键特征,通过对时空关联特征的有效挖掘实现功率预测精度进一步提升。

## 1 分布式光伏超短期功率深度联邦学习预测方法

本文提出了一种基于隐私保护导向与深度联邦学习的分布式光伏超短期功率预测方法,如图1所示。挖掘利用集群空间关联信息是提升分布式光伏功率预测精度的一种有效措施<sup>[31]</sup>,该方法首先构建了一种基于双层信息交互的联邦学习框架。在该框架下,中央服务器一方面基于容量加权聚合汇聚的各本地预测模型,获取全局模型;另一方面,针对已有联邦学习仅依靠模型交互,导致信息共享受限问题,利用核主成分分析(kernel principal components analysis, KPCA)聚合汇聚的本地时序特征,生成含有空间相关信息的全局特征。随后,将全局模型与全局特征下发至各站点供本地模型个性化训练、挖掘时空关联信息。且在本地个性化训练过程中,为提高模型训练效率、缓解模型过拟合问题,采用仅依据全局模型更新提取通用特征的浅层网络、基于本地数据微调用于本地个性化学习的深层网络训练方式。由此通过模型信息交互与时序特征共享的双层信息共享新框架,实现对不同光伏

站点之间的关联信息的有效挖掘利用,以提升超短期功率预测精度。

随后依托基于双层信息交互的联邦学习框架,构建了基于时空关联特征的注意力自编码器,作为本地预测模型。区别于常规的自编码器结构中解码器的输入信息仅来源于单一编码器输出。为了实现时空关联信息的有效挖掘利用,该模型利用编码器从前序历史功率中提取本地时序特征,并将时序特征与中央服务器生成的全局特征耦合成时空关联特征,作为解码器输入信息源。在此基础上,将解码器与注意力机制结合,考虑近邻时段功率高度相关性,以近邻历史时段功率为参考,挖掘提取时空关联特征重对预测时段功率具有重要影响的关键部分,通过有效提取丰富的时空信息,以提升功率预测建模精度。

## 2 基于双层信息交互的联邦学习框架

针对数据隐私保护要求以及预测精度提升需求,现有的联邦学习架构虽在保障用户数据隐私的基础上推动了信息共享,但其仅借助各参与用户的模型参数交互来达成。由于模型参数本身所能承载的信息密度相对较低,单纯依靠参数交互难以有效利用邻近站点的深层关联信息,进而限制了功率预测精度的大幅提升。

本文创新性地提出了一种基于全局特征生成的联邦学习方法,通过各本地时序特征的交互共享,构建了一个更为高效的跨站点信息共享机制。同时,将基于全局特征生成的联邦学习与基于参数聚合的联邦学习相结合,构建了包含模型参数交换与时序信息交互的双层信息共享框架,以实现不同光伏站点之间关联信息的有效挖掘与利用,从而提升超短期功率预测精度。

### 2.1 基于参数聚合的联邦学习

图1为基于参数聚合的联邦学习流程图。

区别于集中式训练模型,联邦学习以一种数据分散式训练的方式进行<sup>[32]</sup>。在联邦学习框架下全局模型与本地模型遵循统一的结构设计。本地模型直接利用其本地功率数据集进行训练。而全局模型的训练则依赖于各个参与节点上传的模型训练损失信息,通过按照特定规则(如平均法等)对这些训练损失进行聚合,从而调整并优化全局模型,在不交互原始数据的情况下生成了一个由各站点共同参与训




图 1 基于参数聚合的联邦学习流程图

Fig. 1 Flowchart of federated learning based on parameters aggregation

练的全局模型。鉴于全局模型与本地模型具有同构性，二者的输入输出要素相同，所以能够将全局模型直接应用于本地功率预测任务。然而，考虑到各分布式光伏的出力特性存在差异，直接运用传统的平均化联邦聚合方式生成的全局泛化模型难以有效挖掘本地功率的个性化特征，进而导致本地预测效果欠佳。

为此，本文从两个方面做出改进：在全局参数聚合时仅对用于挖掘泛化特征的浅层网络参数进行聚合，并且在聚合过程中考虑了不同容量的贡献程度；在个性化训练时冻结浅层网络，仅依据本地数据对用于挖掘个性化特征的深层网络进行训练。由此增强了模型对泛化特征与个性化特征的提取能力，提升了模型预测的精度。具体过程如图 2 所示。

1) 全局模型初始化。利用随机初始化方式或者可获得的公共数据预训练得到初始化全局模型。

2) 模型个性化训练。 $N$  个边缘分布式光伏场站基于中央服务器下发的全局模型进行本地预测模型更新。考虑到各站点出力特性差异，仅依靠单一全局模型难以有效提取本地个性化特性并提升本地预测效果。受迁移学习启发，在个性化训练过程中冻结浅层网络，仅训练优化深层网络以进一步提升模型个性化特征挖掘能力同时避免模型过拟合。由此，各场站  $n$  在全局模型的基础上利用本地数据进行个性化训练，获取本地预测模型。模型预测过程如式(1)所示，模型深层网络参数更新过程如式(2)所示。




图 2 基于全局特征生成的联邦学习流程图

Fig. 2 Flowchart of federated learning based on the global feature generation

$$[\hat{p}_{t+1}^n, \hat{p}_t^n, \dots, \hat{p}_{t+\tau}^n] = f^n([p_{t-\sigma}^n, \dots, p_{t-1}^n, p_t^n], \theta^{n,s}, \theta^{n,d}) \quad (1)$$

$$\theta^{n,d} \leftarrow \theta^{n,d} - \gamma \frac{\partial l^n([ \hat{p}_{t+1}^n, \dots, \hat{p}_{t+\tau}^n ] - [ p_{t+1}^n, \dots, p_{t+\tau}^n ])}{\partial \theta^{n,d}} \quad (2)$$

式中： $p_t^n$ 与 $\hat{p}_t^n$ 分别为场站  $n$  在  $t$  时刻的功率预测值和真实值； $f^n(\cdot)$ 与 $l^n(\cdot)$ 分别为预测模型与损失函数； $\theta^{n,s}$ 与 $\theta^{n,d}$ 分别为模型  $f^n$  浅层与深层网络参数，其中  $s$ 、 $d$  分别为浅层网络与深层网络的代数标识符； $\gamma$  为学习率； $\tau$ 、 $\sigma$  分别为预见期长度与输入历史功率序列长度。

3) 全局模型聚合更新。考虑到大容量场站出力比重高，预测误差对总精度影响大。因其“权重”效应，提升其精度能显著减少总预测误差。同时，大容量场站具有更稳定的发电特性，其相应模型的训练效果更加可靠、泛化能力更强，有利于预测精度提升<sup>[33]</sup>，为此在全局模型生成时按照容量加权聚合，如式(3)所示。

$$[\theta^s, \theta^d] = \sum_{n=1}^N \frac{C^n}{C} [\theta^{n,s}, \theta^{n,d}] \quad (3)$$

式中： $C$ 与 $C^n$ 分别为  $N$  个场站总装机容量与场站  $n$  的装机容量； $\theta^s$ 与 $\theta^d$ 分别为全局模型的浅层与深层网络参数。

4) 停止机制。迭代步骤 2) — 3) 多次，直到模型收敛或达到最大迭代次数，获得最优的全局预测模型。为避免全局模型的泛化平均效应造成模型在部

分站点预测效果不理想的问题,再次进行各本地模型的个性化训练。最终,获取预测精度接近甚至优于集中式训练的模型,如式(4)所示。

$$|\hat{P}^{\text{Fed}} - \hat{P}^{\text{Cen}}| < \delta \quad (4)$$

式中:  $\hat{P}^{\text{Fed}}$  与  $\hat{P}^{\text{Cen}}$  分别为联邦学习和集中式功率预测结果;  $\delta$  为一个极小的正数。

## 2.2 基于全局特征生成的联邦学习

为了在保障数据隐私的前提下在预测建模中引入更丰富信息以提升功率预测效果,本文提出了一种基于全局特征生成的联邦学习框架。考虑到一方面由于集群强时空相关性,在本地功率预测建模中引入近邻站点的时序出力特征可有效提升功率预测精度,另一方面经模型提炼的特征难以逆向还原为原始数据。因此,该机制能在确保隐私安全的同时有效促进信息共享。

首先,由中央服务器汇聚各本地时序特征。在此过程中考虑到直接将所有电站的全部时序特征传输到各本地站点,并直接融入预测建模过程将会导致严重的特征冗余问题。这在加重本地模型计算负担的同时也可能对模型预测精度产生不利影响。为此,采用降维方法在保留关键信息的同时降低特征冗余度,生成蕴含空间关联信息的全局特征。随后本地用户接收中央服务器下发的全局特征,并将其与本地时序特征融合从而获得时空特征,并用于本地功率预测。

考虑到分布式光伏出力呈现高度随机性与不确定性,且同一区域分布式光伏间呈现复杂的非线性关联关系,本文采用 KPCA 生成全局特征。KPCA 能够在保留多维数据间非线性关系的同时降低数据维度<sup>[34]</sup>,因此将其用于聚合多维时序特征,生成集群空间关联关系的全局特征,具体步骤如下。

首先,利用非线性函数将  $N$  个本地站点的时序特征  $[h^1, h^2, \dots, h^N]$  映射到高维特征空间,以支撑捕捉到分布式光伏时序特征中的非线性结构和潜在的空间关联性。由此可得到高维空间的协方差矩阵  $M$  及其特征分解形式,如式(5)~(6)所示。

$$M = \frac{1}{N} \sum_{n=1}^N \phi(h^n) \phi(h^n)^T \quad (5)$$

$$\lambda v^n = M v^n \quad (6)$$

式中:  $\lambda$  与  $v$  分别为协方差特征值矩阵与特征向量;  $\phi(h^n)$  为非线性映射函数,将  $h^n$  映射到高维空间;  $n$  为本地站点序号。

考虑到在高维空间中特征向量可以用所有样本(时序特征)进行表示,可将式(6)转换为式(7)。

$$\lambda(\phi(h^n) v^n) = \frac{1}{N} \sum_{i=1}^N \alpha^i \sum_{j=1}^N (\phi(h^n) \phi(h^j)) (\phi(h^n) \phi(h^j)) \quad (7)$$

式中:  $\alpha$  为特征向量在线性组合中的系数;  $i$  为第  $i$  个站点序号。

随后,针对光伏出力间存在的复杂非线性关系,利用非线性核函数可以有效地捕捉不同站点之间的隐含空间相关性和时间模式。为此,在高维空间采用高斯核函数对式(7)进行化简,如式(8)所示。

$$N \lambda \alpha = K \alpha \quad (8)$$

式中  $K$  为核函数矩阵的特征向量。

由此,根据  $K$  的特征值选取前  $k$  个特征作为主成分以保留本地时序特征中最重要的非线性结构及空间关联性信息,实现本地时序特征融合,生成全局特征,如式(9)所示。

$$h^g = K_{\text{PCA}}([h^1, h^2, \dots, h^N]) \quad (9)$$

式中:  $h^g$  为全局特征,其中  $g$  为 global 的简称;  $h^j (j \in [1, N])$  为第  $j$  个站点的时序特征;  $K_{\text{PCA}}(\cdot)$  为核主成分分析函数。

## 3 基于时空关联特征的注意力自编码模型

图3为注意力自编码模型,图4为LSTM单元结构图。




图3 注意力自编码模型

Fig. 3 Auto-encoder model with attention

对时空关联特征的挖掘利用是提升分布式光伏功率预测的有效手段。上述联邦学习框架为本地功率预测建模提供了一种空间关联特征获取方式。基




图4 LSTM单元结构图

Fig. 4 Structure of LSTM unit

于该框架, 本节以自编码器<sup>[35]</sup>作为预测模型, 利用编码器基于本地站点历史功率提取时序特征并与蕴含空间信息的全局特征耦合形成的时空关联特征预测发电功率。考虑到时空关联特征中存在着由于目标站点连续观测数据中重复或对预测贡献小信息导致的本地时序特征冗余, 以及全局空间特征中混杂与目标站点出力特性空间相似性弱的邻近站点信息, 为有效提取时空特征中对本地功率预测更关键的信息以避免信息冗余问题, 本文将注意力机制与解码器融合使模型聚焦于时空特征中对本地功率预测更关键的部分。模型结构如图4所示。本文自编码模型主要基于LSTM<sup>[36]</sup>与全连接(fully connected, FC)网络串联作为编码器与解码器。其中, LSTM作为浅层网络用于提取通用化特征, FC作为深层网络用于进一步提取个性化特征。具体预测步骤如下。

1) 时序特征提取与时空关联特征生成。以场站  $n$  为例,  $t$  时刻执行其超短期功率预测, 首先输入该场站的前  $\sigma$  时刻历史功率序列  $\mathbf{p}_{t-\sigma:t}^n = [p_{t-\sigma}^n, \dots, p_{t-1}^n, p_t^n]$ , 编码器  $f^{\text{Enc}}(\cdot)$  根据  $i$  时刻功率以及  $i-1$  特征, 计算得到  $t$  时刻的特征向量  $\mathbf{h}_i^n (i \in [t-\sigma, t])$ , 如式(10)所示。

$$\mathbf{h}_i^n = f^{\text{Enc}}(\mathbf{p}_i^n, \mathbf{h}_{i-1}^n) \quad (10)$$

随后, 将时序特征与全局空间特征耦合, 获取时空关联特征  $\mathbf{h}_i^{\text{st},n} = [\mathbf{h}_i^n; \mathbf{h}_i^s]$ , 作为解码器输入。

2) 基于注意力机制的特征生成。在  $t$  时刻执行预测时, 为获得对被预测时段  $(t+1) \sim (t+\tau)$  功率更关键的时空关联特征, 基于短时间内功率不突变的假设, 以  $t-1$  时刻解码器输出, 即  $t \sim (t+\tau-1)$  时段功率预测值  $\hat{\mathbf{p}}_{t:t+\tau-1}^n = [\hat{p}_t^n, \hat{p}_{t+1}^n, \dots, \hat{p}_{t+\tau-1}^n]$  为查询向量, 以时空关联特征作为键值矩阵, 训练计算  $t$  时刻执行预测时的注意力权重  $a_{t+1,i}$ , 如式(11)–

(12)所示。

$$e_{t+1,i} = \mathbf{v}_s^T \tanh(\mathbf{w}_s \mathbf{h}_i^n + \mathbf{u}_s \hat{\mathbf{p}}_{t:t+\tau-1}^n + \mathbf{b}_s) \quad (11)$$

$$a_{t+1,i} = \frac{\exp(e_{t+1,i})}{\sum_{i=t-\sigma}^t \exp(e_{t+1,i})} \quad (12)$$

式中:  $e_{t+1,i}$  为注意力得分;  $\mathbf{w}_s$ 、 $\mathbf{u}_s$ 、 $\mathbf{b}_s$  与  $\mathbf{v}_s$  均为可训练参数;  $\tanh(\cdot)$  为激活函数;  $\exp(\cdot)$  为幂指数函数;  $a_{t+1,i}$  为注意力权重;  $a_{t+1,i} \in \mathbf{a}_{t+1,0}$ 。

随后, 将注意力权重矩阵与键值矩阵进行加权求和得到最终的特征矩阵  $\mathbf{s}_{t+1}^n$ , 如式(13)所示。注意力机制根据  $[\mathbf{h}_{t-\sigma}^{\text{st},n}, \dots, \mathbf{h}_{t-1}^{\text{st},n}, \mathbf{h}_t^{\text{st},n}]$  与  $\hat{\mathbf{p}}_{t:t+\tau-1}^n$  的匹配程度赋其权重, 使模型“注意力”聚焦于对目标时段功率预测关键时空关联特征以进一步提升预测精度。

$$\mathbf{s}_{t+1}^n = \mathbf{a}_{t+1} \mathbf{h}_{t-\sigma:t}^{\text{st},n} \quad (13)$$

由此基于注意力机制, 模型可在功率预测过程中根据本地实时出力特性动态调整权重, 自适应地聚焦于关键的时空特征从而提升功率预测建模的准确性。

3) 基于解码器的功率预测。将特征矩阵  $\mathbf{s}_{t+1}^n$  作为输入并利用解码器模型  $f^{\text{Dec}}(\cdot)$  计算得到未来  $t+1 \sim t+\tau$  时段的功率预测值  $\hat{\mathbf{p}}_{t+1:t+\tau}^n = [p_{t+1}^n, p_{t+2}^n, \dots, p_{t+\tau}^n]$ , 如式(14)所示。

$$\hat{\mathbf{p}}_{t+\tau}^n = f^{\text{Dec}}(\hat{\mathbf{p}}_{t+\tau-1}^n, \mathbf{s}_{t+\tau}^n) \quad (14)$$

## 4 算例仿真

### 4.1 数据介绍

本实验数据来自于河北省某地区的 20 个分布式光伏场站的发电功率数据。数据时间跨度为 2020 年 7 月 1 日到 2021 年 7 月 1 日, 数据的时间分辨率为 15 min。由于缺失数据的处理并不是本文研究重点且数据的缺失率不高, 因此对缺失值均采用了相对简单但效果不错的线性插值法进行修复。在对所有数据做归一化处理后, 将该数据按照 8 : 1 : 1 这一较常用的比例划分为训练集、验证集与测试集, 分别用于训练模型、选取最优模型参数与计算所提方法精度。

### 4.2 评价指标

本文选择标准化均方根误差  $e_{\text{NRMSE}}$  (normalized root mean square error, NRMSE) 与标准化平均绝对误差  $e_{\text{NMAE}}$  (normalized mean absolute error, NMAE) 作为功率预测精度评价指标, 计算方法分别如式

(15)—(16)所示。

$$e_{\text{NRMSE}} = \frac{1}{p_{\max}} \sqrt{\frac{1}{T} \sum_{t=1}^T (p_t - \hat{p}_t)^2} \quad (15)$$

$$e_{\text{NMAE}} = \frac{1}{T \times p_{\max}} \sum_{t=1}^T |p_t - \hat{p}_t| \quad (16)$$

式中： $p_{\max}$ 为目标分布式光伏场站出力最大值； $T$ 为预测时间长度； $\hat{p}_t$ 与 $p_t$ 分别为目标场站在 $t$ 时刻的功率真实值与预测值。

#### 4.3 算例设置

为证明本文方法的有效性，除本文所提方法外设置了另外4种模型作为对照模型。表1为各种方法在数据隐私与信息共享情况的对比。

方法1：基于传统联邦学习框架与注意力的自编码模型。

方法2：为每个场站仅依靠本地数据建立注意力自编码功率预测模型。

方法3：为每个场站仅依靠本地数据建立基于LSTM的功率预测模型。

方法4：为每个场站仅依靠本地数据建立基于ELM的功率预测模型。

表1 各种方法在数据隐私与信息共享情况的对比

Tab. 1 Comparison of various methods in data privacy and information sharing

| 数据状况 | 本文方法 | 方法1 | 方法2 | 方法3 | 方法4 |
|------|------|-----|-----|-----|-----|
| 数据隐私 | √    | √   | √   | √   | √   |
| 信息共享 | √    | √   | ×   | ×   | ×   |

注：√表示具有该功能；×表示不具有该功能。

各种方法对比如表1所示，其中方法1仅进行模型参数信息的交互，方法2—4虽然保护了数据隐私性但牺牲了信息共享。通过本文方法、方法1与方法2—4的对比，验证其在保证数据隐私的前提下获得不弱于其他方法的预测效果；通过方法2与方法3—4对比，验证注意力自编码模型的预测效果。各预测模型的输入为被预测时段前96时刻的功率，输出为被预测时段的16时刻功率，每15 min执行一次，以此实现超短期功率预测。

本文算例仿真在Python 3.8中进行，仿真平台硬件配置为Intel Core i9-9900X 3.50 GHz CPU，64 GB RAM，NVIDIA GeForce GTX 2080Ti GPU。

#### 4.4 预测方法对比分析

利用5种预测方法对各个场站进行超短期功率

预测。提前1 h~4 h时间尺度下5种预测方法在各场站的平均预测误差指标如表2—3所示，统计尺度为整个测试集。对数值最小(精度最高)的指标进行了加粗。方法4难以实现数据深层特征的有效挖掘，因此其预测效果差于其他方法。方法2预测精度高于方法3—4，与方法3相比，其在提前1 h与4 h预测时间尺度分别获得了3.77%与7.67%的NRMSE指标相对提升。这种现象说明依靠注意力自编码模型通过基于LSTM的编码与解码结构以及利用注意力机制使模型自动聚焦于对预测功率更重要的相关信息，进一步提升了时间序列特性挖掘能力，因而表现出了比LSTM及ELM这种机器学习模型更加优越的预测性能。方法2相比，方法1基于模型交互机制在一定程度上实现了空间关联信息的利用，因而在提前1 h与4 h预测时间尺度分别获得了4.02%与4.15%的NRMSE指标相对提升。

表2 各预测方法的NRMSE指标

Tab. 2 NRMSE values of various forecasting methods

| 预测时间 | 本文方法           | 方法1     | 方法2     | 方法3     | 方法4     |
|------|----------------|---------|---------|---------|---------|
| 1 h  | <b>0.092 8</b> | 0.093 0 | 0.096 9 | 0.100 7 | 0.114 3 |
| 2 h  | <b>0.102 2</b> | 0.107 9 | 0.112 6 | 0.120 9 | 0.137 7 |
| 3 h  | <b>0.109 3</b> | 0.116 0 | 0.122 4 | 0.132 1 | 0.151 6 |
| 4 h  | <b>0.114 7</b> | 0.122 3 | 0.127 6 | 0.138 2 | 0.151 0 |

表3 各预测方法的NMAE指标

Tab. 3 NMAE values of various forecasting methods

| 预测时间 | 本文方法           | 方法1     | 方法2     | 方法3     | 方法4     |
|------|----------------|---------|---------|---------|---------|
| 1 h  | <b>0.050 0</b> | 0.050 1 | 0.054 6 | 0.058 9 | 0.071 8 |
| 2 h  | <b>0.055 4</b> | 0.060 7 | 0.066 3 | 0.072 8 | 0.085 5 |
| 3 h  | <b>0.060 0</b> | 0.066 7 | 0.074 8 | 0.082 4 | 0.091 2 |
| 4 h  | <b>0.063 7</b> | 0.071 0 | 0.081 3 | 0.089 4 | 0.094 5 |

在5种方法中，本文方法展现出最佳的预测性能，与方法1相比，在提前1 h与4 h预测时间尺度分别获得了0.22%与6.21%的NRMSE指标相对提升。这说明借助双层联邦学习的模型与特征交互机制，各分布式光伏在保障数据隐私的前提下共享交互信息，实现了空间关联信息的有效挖掘利用，使功率预测精度得到提升。值得注意的是，本文为凸显深度联邦学习预测算法，并未将天气因素作为神经网络输入特征，未来将会充分考虑天气因素及相关数据信息以进一步提升预测精度。

为进一步说明本文所提方法的有效性，在3种

典型天气下对各预测方法提前 4 h 在各场站的预测误差平均值进行了统计,如表 4—5 所示。可见相较于其他预测方法本文方法在各典型天气场景下均能取得较好的预测效果。

表 4 不同天气类型下各预测方法的 NRMSE 指标

Tab. 4 NRMSE values of various forecasting method under different weathers

| 天气 | 本文方法           | 方法 1    | 方法 2    | 方法 3    | 方法 4    |
|----|----------------|---------|---------|---------|---------|
| 晴天 | <b>0.100 8</b> | 0.107 6 | 0.121 6 | 0.144 8 | 0.167 5 |
| 多云 | <b>0.130 0</b> | 0.133 4 | 0.139 0 | 0.142 4 | 0.150 6 |
| 阴雨 | <b>0.161 0</b> | 0.191 5 | 0.195 6 | 0.182 1 | 0.177 0 |

表 5 不同天气类型下各预测方法的 NMAE 指标

Tab. 5 NMAE values of various forecasting method under different weathers

| 天气 | 本文方法           | 方法 1    | 方法 2    | 方法 3    | 方法 4    |
|----|----------------|---------|---------|---------|---------|
| 晴天 | <b>0.056 5</b> | 0.064 1 | 0.076 5 | 0.094 6 | 0.107 2 |
| 多云 | <b>0.075 1</b> | 0.076 4 | 0.078 9 | 0.088 7 | 0.089 9 |
| 阴雨 | <b>0.091 7</b> | 0.108 6 | 0.119 0 | 0.112 9 | 0.100 8 |

以场站 12 为例,对比 5 种方法在 3 类天气下的预测功率(结果进行了归一化处理),提前 1 h 与 4 h 的功率预测曲线如图 5—6 所示。

晴天时分布式光伏出力稳定,各方法均能取得不错的预测效果,其中本文方法效果最优。多云天时,受云团运动等因素影响分布式光伏出力出现一定的波动性,5 种预测方法在提前 1 h 预测时均可拟合出功率曲线波动情况,但在提前 4 h 预测时仅有本文方法能更好的拟合出功率曲线趋势。雨天时,大气运动剧烈且云层遮挡情况严重,相较于晴天光伏出力短时波动剧烈、不确定性显著增加,因此对该场景下功率预测建模问题更加复杂。在较短预测时间尺度下(例如,提前 1 h 预测时),各方法可以较好地挖掘天气状态变化对光伏出力的影响,能大致拟合出曲线波动情况。然而,对于较长时间尺度(例如,提前 4 h 预测),由于仅依靠分布式光伏功率而缺乏其他观测信息(例如,数值天气预报、卫星云图等),导致模型难以快速处理和捕捉雨天下光伏发电模式的变化,出力情况拟合效果差。由此,雨天下本文方法预测精度会随着预测尺度增加而降低的现象更加明显,在雨天下提前 4 h 预测精度较低。各方法都无法拟合出曲线波动趋势。尽管如此,仍可以看出本文方法预测曲线与实际功率相




图 5 场站 12 提前 1 h 预测的功率曲线

Fig. 5 Power curves predicted 1 hour in advance at station 12

对贴合。

基于上述分析,本文方法表现出更好的拟合效果且在出力剧烈波动时更为明显。这说明:一方面,本文方法利用注意力自编码模型更优越的时间序列建模能力,实现了功率预测精度的有效提升;另一方面,本文方法考虑到分布式光伏相邻场站的信息共享是提升预测精度的有效途径,以模型参数与时序特征交互的形式实现信息共享。由此,实现了时空关联信息的有效挖掘,在仅依靠功率数据的基础上实现了功率预测精度一定程度的提升。

为进一步证明本文方法的有效性,对不同方法在各场站的预测效果进行了分析。5 种方法在各场站的提前 4 h 的预测误差如图 7 所示。

与基于 LSTM 的方法 3 相比,基于注意力自编




图6 场站12提前4 h预测的功率曲线

Fig. 6 Power curves predicted 4 hours in advance at station 12




图7 提前4 h预测下5种方法在各场站精度对比

Fig. 7 Accuracy comparison of five methods at various stations under the prediction of 4 hours in advance

码模型的方法2在大多数场站的功率预测上都表现出了更优的预测精度。方法1基于联邦学习框架的模型交互机制，在方法2的基础上提升了预测精度。本文方法在方法1的基础上通过模型与时序特征的双层信息交互机制，进一步提升了功率预测精度。值得注意的是本文方法与方法1在场站11的预测效果劣于方法2，这可能是由于场站11与其他场站出力相关性弱，使得场站11本地预测模型在联邦训练过程中融入了大量冗余信息，降低了自身模型预测精度。但总体来说，本文方法预测效果最优。

除预测精度外，计算效率对于超短期预测来说同样重要。本文方法训练过程中涉及到多个深度学习模型训练及模型与信息的交互，过程复杂且耗时，但预测过程中仅需9.13 s即可获得整个测试集的预测结果。这一时间远小于超短期每次执行预测的间隔时间15 min。为此，可以采用离线训练和在线预测的方式来满足超短期功率预测的实际应用需求。

#### 4.5 与现有方法对比分析

本文创新主要体现在对联邦学习框架的改进，本节将本文方法与现有的联邦学习建模方法进行对比。为了解决联邦学习的全局模型在挖掘本地个性化信息方面的困难，文献[37]提出了一种分层参数聚合方法，仅对提取公共特征的浅层参数进行聚合更新，而对于提取个性化特征的深层参数仅采用本地数据训练更新。文献[38]为了避免在基于全局模型的个性化训练过程中本地模型过拟合，在损失函数中引入了一个正则化项以提升本地个性化训练效果。

3种方法的评价指标见表6—7所示。

表6 各预测方法的NRMSE指标

Tab. 6 NRMSE indices of various forecasting methods

| 时间 | 本文方法           | 文献[37]         | 文献[38]  |
|----|----------------|----------------|---------|
| 1h | 0.092 8        | <b>0.089 1</b> | 0.090 9 |
| 2h | <b>0.102 2</b> | 0.102 4        | 0.102 9 |
| 3h | <b>0.109 3</b> | 0.112 1        | 0.113 8 |
| 4h | <b>0.114 7</b> | 0.122 0        | 0.122 7 |

可以看出，已有方法通过模型交互与个性化训练提升模型特征提取能力，实现了一定精度提升作用。本文方法通过模型和特征的双重信息交互实现了

表 7 各预测方法的 NMAE 指标

Tab. 7 NMAE indices of various forecasting methods

| 时间 | 本文方法           | 文献[37]         | 文献[38]  |
|----|----------------|----------------|---------|
| 1h | 0.050 0        | <b>0.048 8</b> | 0.059 1 |
| 2h | <b>0.055 4</b> | 0.056 2        | 0.056 9 |
| 3h | <b>0.060 0</b> | 0.064 7        | 0.066 8 |
| 4h | <b>0.063 7</b> | 0.066 3        | 0.067 6 |

对模型的特征提取能力的增强及关联信息的有效挖掘利用, 虽在 1 h 预测尺度下表现略差, 在 2~4 h 这一较长尺度下的预测中获得了更好效果。分析其原因是由于在较短时间尺度内本站点即时信息对于精确预测尤为关键。然而, 随着时间尺度延伸至 2~4 h 临近站点的出力趋势性信息对于目标站点的功率预测起到更有效地指导作用。因此通过对时空关联信息的有效挖掘利用本文方法整体来看预测效果最优。

#### 4.6 参与联邦训练的用户数量影响

在联邦学习的训练过程中中央服务器聚合各用户上传的本地模型形成全局模型, 而后各本地用户在全局模型的基础上进行个性化训练。可见全局模型对于各场站功率预测具有重要作用, 而全局模型的形成依赖于参与联邦训练的各个用户。在上述仿真中全部 20 个分布式光伏场站均参与到了联邦学习的训练过程中。为进一步探究参与联邦训练过程的用户数对最终预测精度的影响, 本节改变参与联邦学习训练过程的场站数量, 其中参与联邦训练过程的场站会上传本地模型进行全局模型的聚合并且基于全局模型进行本地个性化训练, 而未参与的场站利用全局模型进行本地个性化训练但无需上传本地模型。参与的场站按照 [0.2, 0.4, 0.6, 0.8, 1.0] 5 种比例随机抽取, 每种比例下重复训练与预测过程 50 次后取平均值。不同比例下各场站提前 4 h 预测的误差分布结果如图 8 所示。




图 8 不同比例下各场站误差分布图

Fig. 8 Error distribution of various stations at different proportions

随着抽取场站比例的增加所提方法的预测精度基本呈现先减小后增加再减小的趋势。这再次印证了存在与其他场站相关性差的场站, 其本地模型对其他模型造成了干扰, 影响了整体的预测效果。因此, 筛选合适的场站参与到联邦学习中有助于进一步提升所提方法的预测性能。

## 5 结论

为了在利用集群分布式光伏功率数据挖掘其出方间相关性信息来提升目标场站功率预测精度的同时保证各场站的数据隐私, 本文提出了一种基于隐私保护导向与深度联邦学习的分布式光伏超短期功率预测方法。所得结论如下。

1) 本文提出了一种双层联邦学习框架在无需各场站共享本地数据的前提下, 以各本地模型与时序特征交互的机制实现了信息共享, 避免了数据直接交互导致的数据隐私性问题。仿真结果表明, 在各预测时间尺度本文方法能在保证数据隐私的前提下在大多分布式光伏场站取得理想的功率预测精度。

2) 各场站利用注意力自编码深度学习模型作为本地预测模型, 有效挖掘利用了含有时空关联信息的全局特征。在提前 4 h 预测尺度上相较于 LSTM、ELM 等预测方法实现了 17.00 % 与 24.04 % 的 NRMSE 指标相对提升。

3) 本文方法依靠双层联邦学习的模型与特征信息交互机制提升了模型预测性能, 提高了功率预测精度。相较于现有的联邦学习方法, 本文方法在提前 4 h 预测尺度上分别实现了 6.63 % 的 NRMSE 相对提升与 10.28 % 的 NMAE 相对提升。

在未来的研究中将进一步探究更适用于分布式光伏功率特性的联邦模型聚合方法, 提升联邦学习性能。同时, 设计一种保护数据隐私性的场站筛选方法以选取合适的分布式光伏场站参与联邦训练过程, 进一步提升本文方法的性能。

## 参考文献

- [1] 王光华, 张纪欣, 崔良, 等. 基于双重注意力变换模型的分布式屋顶光伏变电站级日前功率预测[J]. 全球能源互联网, 2024, 7(4): 393-405.  
WANG Guanghua, ZHANG Jixin, CUI Liang, et al. Substation-level distributed rooftop photovoltaic power day-ahead prediction based on double attention mechanism transformer model [J]. Journal of Global Energy Interconnection, 2024, 7(4): 393-405.

- [2] 国家能源局. 国家能源局综合司关于公布整县(市、区)屋顶分布式光伏开发试点名单的通知[Z/OL]. (2021-09-08)[2022-08-01]. [http://zfxxgk.nea.gov.cn/2021-09/08/c\\_1310186582.htm](http://zfxxgk.nea.gov.cn/2021-09/08/c_1310186582.htm).
- [3] 中华人民共和国中央人民政府. 关于加快建设全国统一电力市场体系的指导意见[Z/OL]. (2022-01-08)[2023-08-01]. [https://www.gov.cn/zhengce/zhengceku/2022-01/30/content\\_5671296.htm](https://www.gov.cn/zhengce/zhengceku/2022-01/30/content_5671296.htm).
- [4] 付文杰, 杨伯青, 黄莉, 等. 考虑风光出力不确定性与相关性的混合电价机制设计[J]. 南方电网技术, 2021, 15(9): 85-92.  
FU Wenjie, YANG Boqing, HUANG Li, et al. Hybrid electricity pricing mechanism design considering uncertainty and correlation of wind and photovoltaic power output [J]. Southern Power System Technology, 2021, 15(9): 85-92.
- [5] WANG F, GE X, YANG P, et al. Day-ahead optimal bidding and scheduling strategies for DER aggregator considering responsive uncertainty under real-time pricing [J]. Energy, 2020(213): 118765.1-118765.9.
- [6] XU J, FU H, LIAO S, et al. Demand-side management based on model predictive control in distribution network for smoothing distributed photovoltaic power fluctuations [J]. Journal of Modern Power Systems and Clean Energy, 2022, 10(5): 1326-1336.
- [7] ZHANG M, ZHEN Z, LIU N, et al. Optimal graph structure based short-term solar PV power forecasting method considering surrounding spatio-temporal correlations [J]. IEEE Transactions on Industry Application, 2023, 59(1): 345-357.
- [8] LI K, WANG F, MI Z, et al. Capacity and output power estimation approach of individual behind-the-meter distributed photovoltaic system for demand response baseline estimation [J]. Applied Energy, 2019(253): 113595.1-113595.11.
- [9] 刘景青, 马伟, 贺楠, 等. 市场环境分布式光伏协调售电交易机制及策略[J]. 中国电力, 2021, 54(11): 29-36.  
LIU Jingqing, MA Wei, HE Nan, et al. Mechanism and strategy for distributed photovoltaic coordinated electricity-sale in electricity market [J]. Electric Power, 2021, 54(11): 29-36.
- [10] FU Y, CHAI H, ZHEN Z, et al. Sky image prediction model based on convolutional auto-encoder for minutely solar PV power forecasting [J]. IEEE Transactions on Industry Applications, 2021, 57(4): 3272-3281.
- [11] ZHEN Z, XUAN Z, WANG F, et al. Image phase shift invariance based multi-transform-fusion method for cloud motion displacement calculation using sky images [J]. Energy Conversion and Management, 2019(197): 111853.1-111853.8.
- [12] 邓韦斯, 孟子超, 王皓怀, 等. 新能源功率预测特性分析及精度提升措施[J]. 南方电网技术, 2023, 17(2): 11-23.  
DENG Weisi, MENG Zichao, WANG Haohuai, et al. Renewable energy power prediction characteristics analyses and accuracy improvement measures [J]. Southern Power System Technology, 2023, 17(2): 11-23.
- [13] MEER D W, WIDÉN J, MUNKHAMMAR J. Review on probabilistic forecasting of photovoltaic power production and electricity consumption [J]. Renewable and Sustainable Energy Reviews, 2018(81): 1484-1512.
- [14] 李一, 杨茂, 苏欣, 等. 基于集成聚类及改进马尔科夫链模型的光伏功率短期预测[J]. 南方电网技术, 2023, 17(10): 113-122.
- LI Yi, YANG Mao, SU Xin, et al. Short-term prediction of photovoltaic power based on integrated clustering and improved markov chain model [J]. Southern Power System Technology, 2023, 17(10): 113-122.
- [15] 王程, 雷金勇, 许爱东, 等. 基于误差分类的分布式光伏超短期功率预测[J]. 南方电网技术, 2015, 9(4): 41-46.  
WANG Cheng, LEI Jinyong, XU Aidong, et al. Ultra-short-term power output forecasting of distributed photovoltaic based on error classification [J]. Southern Power System Technology, 2015, 9(4): 41-46.
- [16] 李芬, 李春阳, 糜强, 等. 基于GRA-BPNN时变权重的光伏短期出力组合预测[J]. 可再生能源, 2018, 36(11): 1605-1611.  
LI Fen, LI Chunyang, MI Qiang, et al. The time-varying weight ensemble forecasting of short-term photovoltaic power based on GRA-BPNN [J]. Renewable Energy Resources, 2018, 36(11): 1605-1611.
- [17] 杨晶显, 张帅, 刘继春, 等. 基于VMD和双重注意力机制LSTM的短期光伏功率预测[J]. 电力系统自动化, 2021, 45(3): 174-182.  
YANG Jingxian, ZHANG Shuai, LIU Jichun, et al. Short-term photovoltaic power prediction based on variational mode decomposition and long short-term memory with dual-stage attention mechanism [J]. Automation of Electric Power Systems, 2021, 45(3): 174-182.
- [18] 杨建, 常学军, 姚帅, 等. 基于WT-CNN-BiLSTM模型的日前光伏功率预测[J]. 南方电网技术, 2024, 18(8): 61-69, 79.  
YANG Jian, CHANG Xuejun, YAO Shuai, et al. Day-ahead photovoltaic power forecasting based on WT-CNN-BiLSTM mode [J]. Southern Power System Technology, 2024, 18(8): 61-69, 79.
- [19] AHMAD T, ZHANG D. A data-driven deep sequence-to-sequence long-short memory method along with a gated recurrent neural network for wind power forecasting [J]. Energy, 2022(239): 122109.1-122109.12.
- [20] SKOMSKI E, LEE J Y, KIM W, et al. Sequence-to-sequence neural networks for short-term electrical load forecasting in commercial office buildings [J]. Energy and Buildings, 2020(226): 110350.1-110350.8.
- [21] 万安平, 杨洁, 缪徐, 等. 基于注意力机制与神经网络的热电联产锅炉负荷预测[J]. 上海交通大学学报, 2023, 57(3): 316-325.  
WAN Anping, YANG Jie, MIAO Xu, et al. Boiler load forecasting of CHP plant based on attention mechanism and deep neural network [J]. Journal of Shanghai Jiao Tong University, 2023, 57(3): 316-325.
- [22] 王玉庆, 徐飞, 刘志坚, 等. 基于动态关联表征与图网络建模的分布式光伏超短期功率预测[J]. 电力系统自动化, 2023, 47(20): 72-82.  
WANG Yuqing, XU Fei, LIU Zhijian, et al. Ultra-short-term power forecasting of distributed photovoltaic based on dynamic correlation characterization and graph network modeling [J]. Automation of Electric Power Systems, 2023, 47(20): 72-82.
- [23] LAI W, ZHEN Z, WANG F, et al. Sub-region division based short-term regional distributed PV power forecasting method considering spatio-temporal correlations [J]. Energy, 2024(288): 129716.1-129716.11.

- [24] 黄金超, 马颖华, 齐开悦, 等. 一种基于集成学习的入侵检测算法[J]. 上海交通大学学报, 2018, 52(10): 1382 – 1387.  
HUANG Jinchao, MA Yinghua, QI Kaiyue, et al. An ensemble-based intrusion detection algorithm [J]. Journal of Shanghai Jiaotong University, 2018, 52(10): 1382 – 1387.
- [25] LIN J, MA J, ZHU J. A privacy-preserving federated learning method for probabilistic community-level behind-the-meter solar generation disaggregation [J]. IEEE Transactions on Smart Grid, 2022, 13(1): 268 – 279.
- [26] DZOBO O, MALILA B, SITHOLE L. Proposed framework for blockchain technology in a decentralised energy network [J]. Protection and Control of Modern Power Systems, 2021, 6(1): 1 – 11.
- [27] LI J, GU C, XIANG Y, et al. Edge-cloud computing systems for smart grid: state-of-the-art, architecture, and applications [J]. Journal of Modern Power Systems and Clean Energy, 2022, 10(4): 805 – 817.
- [28] 全国人民代表大会常务委员会. 中华人民共和国数据安全法 [EB/OL]. 2021 – 06 – 10. [2025 – 03 – 10]. [https://www.stats.gov.cn/gk/tjfg/xgxfzg/202503/t20250310\\_1958928.html](https://www.stats.gov.cn/gk/tjfg/xgxfzg/202503/t20250310_1958928.html).
- [29] 陈明昊, 孙毅, 胡亚杰, 等. 基于纵向联邦强化学习的居民社区综合能源系统协同训练与优化管理方法[J]. 中国电机工程学报, 2022, 42(15): 5535 – 5550.  
CHEN Minghao, SUN Yi, HU Yajie, et al. The collaborative training and management-optimized method for residential integrated energy system based on vertical federated reinforcement learning [J]. Proceedings of the CSEE, 2022, 42(15): 5535 – 5550.
- [30] YANG Q, LIU Y, CHEN T, et al. Federated machine learning: concept and applications [J]. ACM Transactions on Intelligent Systems and Technology, 2019, 10(2): 1 – 19.
- [31] WANG Y, FU W, ZHANG X, et al. Dynamic directed graph convolution network based ultra-short-term forecasting method of distributed photovoltaic power to enhance the resilience and flexibility of distribution network [J]. IET Generation, Transmission and Distribution, 2024, 18(2): 337 – 352.
- [32] 郑楷洪, 肖勇, 王鑫, 等. 一个面向电力计量系统的联邦学习框架[J]. 中国电机工程学报, 2020, 40(S1): 122 – 133.  
ZHENG Kaihong, XIAO Yong, WANG Xin, et al. A federated learning framework for power grid metering system [J]. Proceedings of the CSEE, 2020, 40(S1): 122 – 133.
- [33] 郑杰, 牛哲文, 韩肖清, 等. 面向数据隐私保护的分布式风电场短期功率预测[J]. 太原理工大学学报, 2024, 55(1): 102 – 110.  
ZHENG Jie, NIU Zhewen, HAN Xiaoqing, et al. Distributed multi-wind farm short-term power prediction for data privacy-preserving [J]. Journal of Taiyuan University of Technology, 2024, 55(1): 102 – 110.
- [34] 牛东晓, 马天男, 王海潮, 等. 基于 KPCA 和 NSGA II 优化 CNN 参数的电动汽车充电站短期负荷预测[J]. 电力建设, 2017, 38(3): 85 – 92.  
NIU Dongxiao, MA Tiannan, WANG Haichao, et al. Short-term load forecasting of electric vehicle charging station based on KPCA and CNN parameters optimized by NSGA II [J]. Electric Power Construction, 2017, 38(3): 85 – 92.
- [35] ZHANG Y, LI Y, ZHANG G. Short-term wind power forecasting approach based on Seq2Seq model using NWP data [J]. Energy, 2020(213): 118371.1 – 118371.9.
- [36] WANG F, XUAN Z, Zhen Z, et al. A day-ahead PV power forecasting method based on LSTM-RNN model and time correlation modification under partial daily pattern prediction framework [J]. Energy Conversion and Management, 2020(212): 112766.1 – 112766.14.
- [37] WANG Y, JIA M, GAO N, et al. Federated clustering for electricity consumption pattern extraction [J]. IEEE Transactions on Smart Grid, 2022, 13(3): 2425 – 2439.
- [38] WANG Y, GAO N, HUG G. Personalized federated learning for individual consumer load forecasting [J]. CSEE Journal of Power and Energy Systems, 2023, 9(1): 326 – 330.

收稿日期: 2024-02-26; 网络首发日期: 2024-12-10

作者简介:

于骥(1978), 男, 工程师, 硕士, 研究方向为新能源发电、电力系统与智能微网;

王玉庆(1999), 男, 博士研究生, 研究方向为新能源功率预测、配电网运行与控制;

王飞(1973), 男, 通信作者, 教授, 博士生导师, 博士, 研究方向为新能源预测、虚拟电厂与需求响应、新型电力系统, fei-wang@ncepu.edu.cn。