

TPA改进GCN-LSTM的光伏电站 群调群控优化策略研究

商立群¹,王硕^{1,2}

(1.西安科技大学 电气与控制学院,陕西 西安 710054;

2.国网驻马店供电公司,河南 驻马店 463000)

摘要:随着光伏装机容量占比逐年提高,准确预测光伏出力,实现光伏群调群控至关重要。提出基于图卷积神经网络(GCN)、长短期记忆网络(LSTM)和时间模式注意力机制(TPA)集成深度融合的多站光伏出力预测方法。首先,以图结构形式转化多站光伏出力时序曲线及数值天气预报数据的输入特征,建立GCN-LSTM模型,提取光伏集群间隐藏的时空依赖性。其次,引入时间模式注意力机制加权修正输入数据特征,提高关键数据价值。然后,设定反映集群内电压变化的节点为主导节点,基于光伏集群间时空预测结果,将灵敏反映集群电压变化的节点设定为主导节点,建立区域所有节点的电压在安全范围运行和最小系统网损为目标的群间协调优化策略。接着,根据协调优化策略结果构建群内节点电压在安全范围内稳定运行、最小化集群网损的自治优化调控策略,实现分布式光伏最大化就地消纳。最后,实际多站光伏集群出力数据的仿真结果表明,所提方法能够高效提取不同光伏电站间的时空关联性,降低光伏出力预测误差,有效提高光伏集群的安全性和经济性。

关键词:光伏出力预测;图卷积神经网络;邻接矩阵自适应;时间模式注意力机制

中图分类号:TM615 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqcd26187

Group Control Strategy of Photovoltaic Power Station Based on TPA Improved GCN-LSTM

SHANG Liqun¹, WANG Shuo^{1,2}

(1.School of Electrical and Control, Xi'an University of Science and Technology, Xi'an 710054, Shaanxi, China;

2.State Grid Zhumadian Electric Power Company, Zhumadian 463000, Henan, China)

Abstract:As the proportion of installed photovoltaic (PV) capacity increases year by year, accurate prediction of PV output and the realization of group control and management of PV clusters become crucial. A multi-site PV output prediction method that integrates deep fusion of graph convolutional neural network (GCN), long short-term memory (LSTM), and temporal pattern attention (TPA) was proposed. First, the input features of multi-site PV output time series curves and numerical weather forecast data were transformed into a graph structure to establish a GCN-LSTM model, which extracts the hidden spatio-temporal dependencies among PV clusters. Second, an attention mechanism was introduced to weight and correct input data features, enhancing the value of key data. Then, based on the spatio-temporal prediction results of the PV clusters, dominant nodes that sensitively reflect the voltage changes of the cluster were selected, and an inter-cluster coordinated optimization strategy was constructed with the goals of ensuring no voltage limit violations in the entire regional nodes and minimizing the system's network losses. Following that, an intra-cluster autonomous optimization and control strategy was constructed within the cluster based on the coordinated optimization strategy results, aiming for the safe operation of cluster node voltages, minimum cluster network losses, and maximum local consumption of distributed PVs. Finally, simulation results of actual multi-site PV cluster output data show that the proposed method can efficiently extract the spatio-temporal correlations between different PV stations, reduce the prediction error of PV output, and

基金项目:陕西省自然科学基金基础研究计划(2021JM393)

作者简介:商立群(1968—),男,博士,教授,主要研究方向为电力系统运行与控制,Email:zhsnegta@163.com

通讯作者:王硕(1992—),女,硕士研究生,主要研究方向为电力系统控制与保护,Email:dnhxyw@163.com

effectively improve the safety and economy of PV clusters.

Key words: PV output prediction; graph convolutional neural network (GCN); adaptive adjacency matrix; temporal pattern attention (TPA)

随着新能源技术的迅速发展,电网内的光伏机组装机容量在近几年增长势头迅猛。高比例的光伏装机使得电网更加清洁与环保,但与此同时,光伏出力的随机性也为电网的安全带来了新挑战^[1-4]。准确预测光伏机组出力对电力系统群调群控运行与新能源消纳具有重要意义^[5-7]。

根据光伏出力预测建模方式的差异,光伏出力预测方法可以分为物理方法与数据驱动方法^[8-10]。物理方法是基于太阳辐射方程、光伏组件运行方程构建预测模型,可解释性强,但预测误差较大,目前已很少使用;数据驱动方法是基于环境变量与光伏出力的统计关系,直接建立从输入特征到光伏出力的非线性映射模型,无需描述具体物理过程^[11-12]。深入挖掘光伏出力时序曲线及天气时间特征能够提高光伏出力预测精度。文献[13]提出利用多种深度学习算法共同提取光伏出力特征。采用智能方法预测前对光伏出力时序曲线进行预分解^[14]或利用极端梯度提升模型初步预测^[15]也能有效提高光伏出力预测精度。文献[16]建立了基于并联卷积神经网络与双向LSTM结合的预测模型,在传统LSTM的基础上进一步学习数据的反向时间规律,提升了预测精度。上述研究从光伏出力时间特征提取角度对提高光伏出力预测精度做出了巨大贡献,但并未面向多站光伏出力预测场景,难以充分利用多站间的空间分布特征。如何进一步挖掘时空关联性,是提高多站光伏出力预测精度的关键之一。为此,文献[17]提出LSTM与图卷积的区域内多个电站间的光伏输出功率预测模型;文献[18]则提出图卷积自编码器模型,提高了区域太阳辐照度预测的预测精度。

为解决光伏高比例接入引起的配电网运行安全与效率问题,研究者提出了众多优化调控策略,确保电压稳定、能源利用最大化的同时降低系统网损。文献[19]对含分布式电源的配网进行区域划分,建立划分区域运行成本最小的优化模型,通过近端策略优化算法训练求解区域优化模型,以达到各个区域协同运行经济性最优的目标。文献[20]提出了配电网和单个光伏电站双层迭代的分层分布式优化方法,通过调整光伏逆变

器跟踪优化后的无功曲线进行无功出力调整,保证配电网全局节点电压安全。上述研究主要集中在局部的优化控制策略。对分布式电源高比例接入的跨群体协调控制和群体内部自主响应优化策略的相关研究还相对较少。

因此,本文提出一种基于GCN-LSTM-TPA的光伏集群群调群控策略。首先,运用GCN和LSTM建立时空图卷积神经网络,提取空间特征,挖掘光伏电站间隐藏的空间依赖性。其次,基于历史数据自动学习不同电站间的空间关联性,引入TPA改进GCN-LSTM的预测模型,改善模型对时序特征重要程度差异性的建模能力,提高关键数据价值。然后,基于光伏集群间时空预测结果,选取能灵敏反映集群电压变化的主导节点,以系统的网损最小为目标构建群间协调优化策略。接着,根据协调优化策略结果,构建群内节点电压安全稳定运行和最小化集群网损的自治优化调控策略,实现分布式光伏最大化就地消纳。最后,进行仿真验证,证明所提方法能有效提高光伏出力预测精度,所提出的群控群调策略有效提升了光伏电站的经济性。

1 光伏出力预测模型

1.1 GCN-LSTM预测模型

基于图卷积网络把卷积网络泛化为非结构化特征空间,实现对任意形状的图结构数据进行处理。本文采用图卷积转化光伏出力数据及天气预报数值特征为图节点参数,通过图卷积层对光伏电站出力时序曲线隐藏的空间关联性进行学习。设 \mathbf{V} , \mathbf{E} 和 \mathbf{A} 分别表示点集、边集、邻接矩阵,模型可表示为 $\mathbf{G} = (\mathbf{V}, \mathbf{E}, \mathbf{A})$,卷积范围如下式所示:

$$B(v_i) = \{v_j | d(v_j, v_i) \leq D\} \quad (1)$$

式中: $B(v_i)$ 为节点 v_i 的邻域; $d(v_j, v_i)$ 为图节点 v_i 与图节点 v_j 的最短距离; D 为最大的卷积邻域。

则图卷积层的前向传播公式可表示为

$$f(\mathbf{A}, \mathbf{X}) = \sigma[\hat{\mathbf{A}}\text{ReLU}(\hat{\mathbf{A}}\mathbf{X}\mathbf{W}_0)\mathbf{W}_1] \quad (2)$$

其中

$$\hat{\mathbf{A}} = \tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \quad (3)$$

式中: \mathbf{X} 为待预测拓扑图 \mathbf{G} 的特征矩阵; $\tilde{\mathbf{A}}$, $\hat{\mathbf{A}}$ 分别

为含自相关和规范对称后的邻接矩阵; $\sigma(\cdot)$ 为sigmoid函数; W_0, W_1 分别为从上层到图卷积层和从图卷积层到下层的权值矩阵; \tilde{D} 为节点度矩阵。

为进一步提取光伏出力曲线的时序特征,将图卷积与长短期记忆网络结合,集成为时空图卷积神经网络,以弥补传统循环神经网络在训练过程中存在的梯度消失和梯度爆炸、长期依赖问题、计算效率低的不足。时空图卷积神经网络结合了图卷积网络和长短期记忆网络的优势,能够有效处理具有复杂空间结构和时间依赖性的数据的同时捕捉时间序列的长期依赖关系和图结构数据间的空间联系,提高数据处理的精确度和预测性能。将图卷积算法引入LSTM构成时空图卷积单元,其前向传播公式如下式所示:

$$u_t = \sigma \{ W_u [f(A, X_t), h_{t-1}] + b_u \} \quad (4)$$

$$r_t = \sigma \{ W_r [f(A, X_t), h_{t-1}] + b_r \} \quad (5)$$

$$c_t = \tanh \{ W_c [f(A, X_t), (r_t \times h_{t-1})] + b_c \} \quad (6)$$

$$h_t = u_t \times h_{t-1} + (1 - u_t) \times c_t \quad (7)$$

式中: u_t, r_t, c_t 分别为单元 t 时刻的内部参数,对应更新门、重置门和当前单元状态; h_t 为在 t 时刻的单元输出值; W_u, b_u 分别为更新门的权重矩阵和偏置矩阵; W_r, b_r 分别为重置门的权重矩阵和偏置矩阵; $f(A, X_t)$ 为 t 时刻模型输入的图卷积操作,见式(2)。

在时空图卷积神经网络的网络单元输入图结构数据,通过图卷积方法进行输入特征空间关联性的提取,再基于LSTM单元结构提取时间关联性,最后,将提取的特征经过全连接层与输出

层,即可得到光伏出力预测结果。

1.2 TPA改进光伏出力预测模型

在时间序列数据分析中,不同时间点特征具有不同重要性。例如,在天气预测时的异常天气特征往往比正常天气特征更为关键;在电力负荷预测时的异常高峰时段数据特征通常比平常运行时段数据特征更为重要^[21-22]。由于传统GCN-LSTM模型难以体现短期内不同特征对负荷需求量的影响程度,导致模型对其特征的重要性进行了错误评估或直接忽略,降低了预测精度。为解决此问题,本文在GCN-LSTM模型中引入TPA,提高关键特征对模型的影响程度,如图1所示,计算公式如下式所示:

$$\alpha_r = \text{softmax} \left(\frac{X^T Q}{\sqrt{D_T}} \right) \quad (8)$$

式中: T 为时间点; $\text{softmax}(\cdot)$ 为激活函数; α_r 为特征权重向量; Q 为光伏出力值; D_T 为输入特征总长度。

通过GCN和TPA可以分别提取输入特征的空间关联性和时间关联性。GCN将输入数据构建为以节点代表光伏站点、边代表空间联系的图结构,并赋予节点初始特征,GCN通过卷积操作处理节点特征,聚合及更新多层邻居节点特征,捕捉空间关系。TPA计算时间序列中每个时间点的权重,运用注意力权重加权时间序列中的特征,加权的特征进一步聚合生成综合时间特征,完成时间关联性提取。

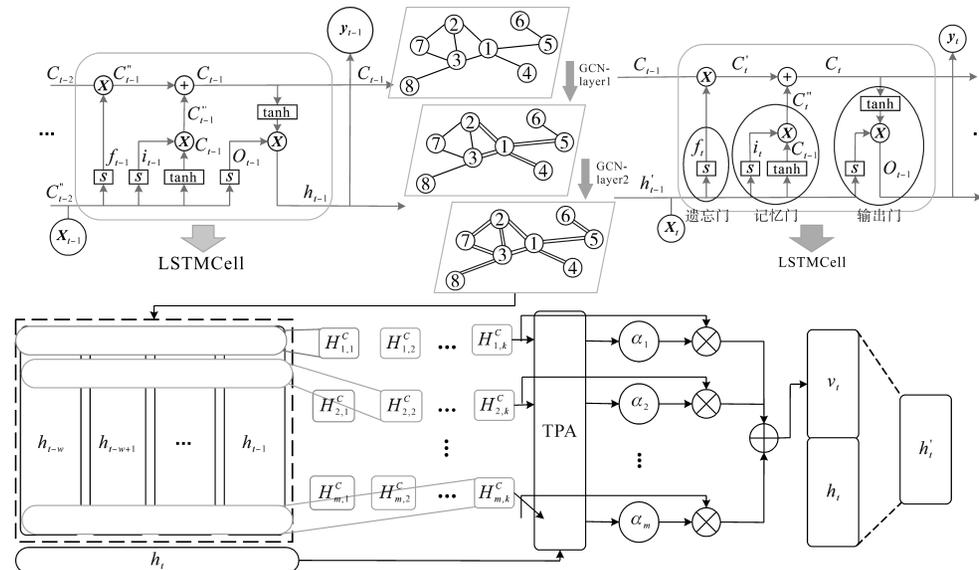


图1 TPA改进GCN-LSTM

Fig.1 GCN-LSTM improved by TPA

1.3 多站光伏出力预测模型架构

光伏出力的影响因素包括季节、天气、太阳辐照角度、设备的安装角度等诸多复杂因素^[23-24]。其中,天气等环境因素可由数值天气预报获得,并作为特征输入预测模型;设备因素则可由模型通过海量历史数据学习,反映在图卷积神经网络的权重中。因此,选择气温、湿度、气压、天空云量、空气质量、天气类型6个特征作为模型的输入特征,其中天气类型采用数字编码。为了便于训练,先标准化处理输入特征,如下式所示:

$$X_{\text{ref}} = \frac{X - X_{\text{mean}}}{X_{\text{std}}} \quad (9)$$

式中: X_{ref} , X_{mean} , X_{std} 分别为数据标准化处理之后的输入集、输入特征分量均值和输入特征分量标准差。

基于TPA改进GCN-LSTM的多站光伏出力预测模型具体流程如图2所示。详细步骤如下:

步骤1:从多个光伏站点收集历史出力数据以及与出力相关的环境因素数据,如温度、日照、风速等,并对数据进行标准化处理;

步骤2:将每个光伏站点作为一个节点,运用GCN基于站点间的相关特性定义节点、边,为每个节点分配特征向量,构建图结构;

步骤3:采用TPA模型计算每个时间序列的每个时间点的注意力得分,识别重要预测时间点,根据注意力得分加权时间序列数据,增强模型对关键时间点的敏感度;

步骤4:利用GCN处理每个节点的特征,通过学习节点间的空间关系来捕捉站点间的依赖性,对多个GCN层,更深入地集成和学习节点间复杂的空间关系;

步骤5:将经过TPA加权的时间序列特征输入到LSTM网络中,捕捉其时间依赖关系。经过LSTM网络处理整个时间序列后输出未来一段时间内光伏出力的预测;

步骤6:结合GCN和LSTM的输出特征,通过一个或多个全连接层生成最终的出力预测。

本文提出的预测模型的优点为:1)GCN-LSTM模型在提取输入特征的同时自动学习不同光伏集群间的时空关联性;2)在GCN-LSTM模型引入TPA解决了GCN-LSTM模型处理长时序数据的局限性。

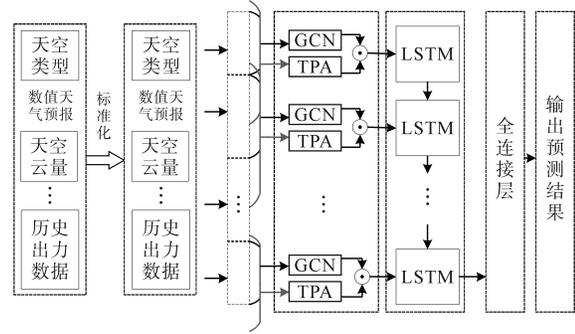


图2 基于TPA改进GCN-LSTM的多站光伏出力预测模型流程图

Fig.2 Flow chart of multi-station PV output prediction model based on TPA improved GCN-LSTM

2 基于光伏集群时空预测的群调群控策略

光伏集群内众多分布广泛的光伏电站受地理位置、环境和气候因素的影响具有不同的出力特性,为了在提升光伏集群整体调控能力的同时最大化利用能源,提出基于预测结果的光伏集群控制策略,通过协调控制集群间和集群内的出力实现全局优化和群内自治优化的目标。

2.1 群间协调优化策略

选取能够灵敏感应其他节点功率变化的节点为主导节点,通过监测主导节点掌控群内所有节点的信息。以节点电压安全范围内运行和最小网损为目标,构建经济调控和电压越限的群间紧急调控策略。

2.1.1 选取主导节点

选取与其他节点紧密连接、能够代表集群电压水平的可观和可控节点为主导节点,以消除节点电压偏差实现群内最小电压偏差。其中,可观性 S_{Gn} 、可控性 S_{kn} 和可观可控综合性 S_n 指标的计算公式如下式所示:

$$S_{Gn} = \sum_{k=1}^N \frac{\Delta U_n}{\Delta U_k} \quad (10)$$

$$S_{kn} = \sum_{k=1}^N \frac{\Delta U_n}{\Delta Q_k} \quad (11)$$

$$S_n = \delta_1 S_{Gn} + \delta_2 S_{kn} \quad (12)$$

式中: N 为集群内节点数目; ΔU_n , ΔU_k 分别为 n 和 k 节点的电压变化量; ΔQ_k 为 k 节点的无功变化量; δ_1 , δ_2 分别为可观性指标与可控性指标的权重系数。

2.1.2 目标函数及约束条件

设定群间协调优化策略的目标为集群主导节点最小电压偏差和最小网损,如下式所示:

$$\begin{cases} \min f_1 = \sum_{j=1}^J |U_j - U_0| \\ \min f_2 = \sum_{m=1}^M \frac{1}{2} \sum_{n=1}^N \sum_l i_{nl}^2 r_{nl} \end{cases} \quad (13)$$

式中: J 为主导节点数目; U_j 为主导节点 j 的电压幅值; U_0 为电压基准值,取值为1; M 为总集群数目; m 为集群; l 为与 n 节点相连的节点集合; i_{nl}, r_{nl} 分别为 n 和 l 节点相连支路的电流和电阻。

加权目标函数如下式所示:

$$\min f = \omega_1 f_1 + \omega_2 f_2 \quad (14)$$

其中, ω_1 和 ω_2 为权重系数, $\omega_1 > \omega_2$ 表示以节点电压偏差最小和电网安全运行为目标的解; $\omega_1 < \omega_2$ 表示以系统网损最小电网经济高效运行为目标的解。

约束条件为潮流约束、集群功率约束和运行安全约束,分别如下式所示:

$$\begin{cases} i_{ij}^2 u_i^2 = P_{ij}^2 + Q_{ij}^2 \\ u_j = u_i - 2(r_{ij} P_{ij} + x_{ij} Q_{ij}) + (r_{ij}^2 + x_{ij}^2) i_{ij}^2 \\ P_j = (P_{ij} - i_{ij}^2 r_{ij}) - \sum_{jl} P_{jl} \\ Q_j = (Q_{ij} - i_{ij}^2 x_{ij}) - \sum_{jl} Q_{jl} \end{cases} \quad (15)$$

$$\begin{cases} 0 \leq P_{pv,m} \leq P_{pv,m}^{\max} \\ Q_{pv,m}^{\min} \leq Q_{pv,m} \leq Q_{pv,m}^{\max} \end{cases} \quad (16)$$

$$U_j^{\min} \leq U_j \leq U_j^{\max} \quad (17)$$

式中: u_i, u_j 分别为 i 和 j 节点的电压; i_{ij} 为 i 和 j 节点相连支路的电流; P_j, Q_j 分别为 j 节点净有功负荷和净无功负荷; P_{ij}, P_{jl} 分别为 $i \rightarrow j$ 和 $j \rightarrow l$ 的有功功率; Q_{ij}, Q_{jl} 分别为 $i \rightarrow j$ 和 $j \rightarrow l$ 的无功功率; r_{ij} 为支路 $i \rightarrow j$ 电阻; x_{ij} 为支路 $i \rightarrow j$ 电抗; jl 为以 j 为起点节点、 l 为终点节点的支路集合; $P_{pv,m}, Q_{pv,m}$ 分别为 m 光伏集群的有功出力 and 无功出力; $P_{pv,m}^{\max}$ 为 m 光伏集群的最大有功出力; $Q_{pv,m}^{\min}, Q_{pv,m}^{\max}$ 分别为 m 光伏集群无功出力的上限和下限; U_j^{\min}, U_j^{\max} 分别为主导节点的上限电压和下限电压,运行范围取0.95~1.05(标幺值)。

2.2 群内自治优化策略

群内自治优化策略包含电压不越限与最小网损两个目标函数,如下式所示:

$$\begin{cases} \min f_3 = |U_n - U_0| \\ \min f_4 = \frac{1}{2} \sum_{n=1}^N \sum_l i_{nl}^2 r_{nl} \end{cases} \quad (18)$$

约束条件为潮流约束(与群间策略相同,不再重复赘述)、光伏电站功率约束、安全运行约束

和无功补偿装置运行约束,其中,后三个约束条件的计算公式分别如下:

$$\begin{cases} 0 \leq P_{pv,n} \leq P_{pv,n}^{\max} \\ P_{pv,n}^2 + Q_{pv,n}^2 \leq S_{pv,n}^2 \\ -P_{pv,n} \frac{\sqrt{1 - \cos^2 \theta}}{\cos \theta} \leq Q_{pv,n} \leq P_{pv,n} \frac{\sqrt{1 - \cos^2 \theta}}{\cos \theta} \end{cases} \quad (19)$$

$$\begin{cases} U_n^{\min} \leq U_n \leq U_n^{\max} \\ 0 \leq i_{ij} \leq i_{ij}^{\max} \end{cases} \quad (20)$$

$$Q_{SVC,n}^{\min} \leq Q_{SVC,n} \leq Q_{SVC,n}^{\max} \quad (21)$$

式中: $P_{pv,n}^{\max}$ 为光伏场站的最大有功出力; $\cos \theta$ 为最小功率因数, $\cos \theta = 0.95$; U_n^{\min}, U_n^{\max} 分别为节点电压的上限和下限,与主导节点相同; i_{ij}^{\max} 为 $i \rightarrow j$ 支路的最大电流限值; $Q_{SVC,n}^{\min}, Q_{SVC,n}^{\max}$ 分别为无功补偿装置无功出力的下限和上限; $Q_{SVC,n}$ 为无功补偿装置的无功出力。

3 算例分析

3.1 算例介绍

本算例分析选取 NVIDIA-GTX3060Ti-8G 显卡和 Intel-Core-i7-11700K 处理器进行训练,运用 Python 编译环境,在 PyTorch 上构建模型。所用光伏出力数据来自于某市 2021 年 1 月至 12 月邻近区域内 19 个光伏电站的运行数据,数值天气预报数据由站内测量装置采集。

3.2 时空图卷积神经网络预测结果

选取 19 个光伏电站中的 7 号电站光伏出力数据为预测目标建立时空图卷积神经网络,随机选取 80% 的输入数据为训练集,其余数据为测试集。时空图卷积层采用一个隐藏层,单元数为 64。全连接层含有 32 个单元,且在全连接层后加入舍弃率为 0.2 的 dropout 层。使用 Adam 算法作为训练的优化算法,初始学习率为 0.001。预测时间步长为 1 h,数据分辨率为 5 min,模型回看期为 24 h。

基于预测结果与真实值的均方根误差 RMSE、平均绝对误差 MAE 和决定系数 R^2 评估预测结果,计算公式如下式所示:

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2} \quad (22)$$

$$MAE = \frac{1}{T} \sum_{t=1}^T |y_t - \hat{y}_t| \quad (23)$$

$$R^2 = 1 - \frac{\sum_{t=1}^T (y_t - \hat{y}_t)^2}{\sum_{t=1}^T (y_t - \bar{y}_t)^2} \quad (24)$$

式中: T 为评估时间段的总长度; y_t 为光伏出力真实值; \hat{y}_t 为光伏出力的模型预测值; \bar{y}_t 为实际值的平均数。

为验证所提基于TPA改进GCN-LSTM预测模型的效果,将本文所提方法与GRU神经网络(方法1)、图卷积神经网络(方法2)、LSTM神经网络(方法3)和未引入注意力机制的GCN-LSTM神经网络(方法4)4种算法在相同测试样本上进行对比分析。不同方法的预测结果及光伏预测功率与实际功率的箱线图如图3、图4所示, $RMSE$ 和 MAE 的测试结果如表1所示。

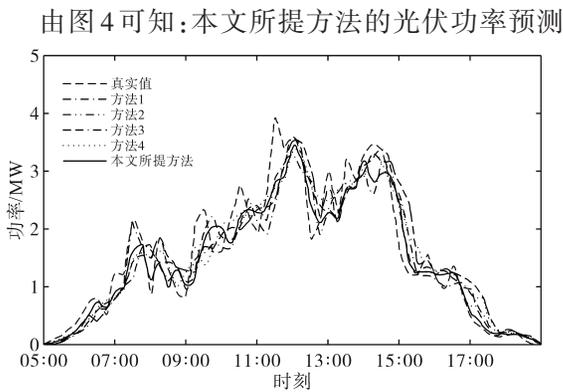


图3 不同方法下的光伏出力预测结果

Fig.3 Results of PV power prediction with different methods

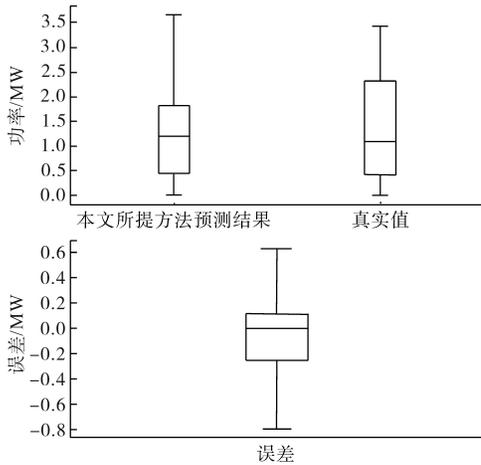


图4 光伏功率预测结果箱线图

Fig.4 Box plot of photovoltaic power prediction results

表1 不同方法下的光伏出力预测误差与精度

Tab.1 Error and accuracy of PV power prediction under different methods

方法	$RMSE/MW$	MAE/MW	R^2
方法1	0.478	0.346	0.86
方法2	0.486	0.338	0.89
方法3	0.416	0.315	0.91
方法4	0.423	0.307	0.94
本文方法	0.382	0.282	0.96

结果与实际值高度一致,预测误差小且分布集中,表现出良好的预测效果和稳定性。尽管存在少量较大的误差点,模型整体上准确且鲁棒性强,适用于实际光伏功率预测。

本文所提方法与方法1进行对比,由结果可知:GRU循环神经网络可以预测单站光伏出力,但在14:00—16:00天气发生变化时会使光伏出力突变,导致预测误差明显增高,表明方法1感知区域天气变化情况存在不足,无法充分利用空间特征。本文所提方法的平均绝对误差比方法1降低了18.5%。

本文所提方法与方法2和方法3进行对比,由结果可知:方法2的图卷积神经网络提取时间特征的能力有限,预测结果导致误差;方法3的LSTM神经网络模型具有提取输入数据的时空特征能力,提高了预测结果的准确率;本文所提方法的平均绝对误差相较于LSTM神经网络模型降低了10.5%。

本文所提方法与方法4进行对比,由结果可知:部分点的预测精度明显改善,表明TPA可以提高模型挖掘输入特征的能力,模型整体平均绝对误差降低了8.1%。

与其他4种算法比较,本文所提方法的 R^2 值为0.96,最接近1,说明模型的预测与实际值最接近,模型的预测精度最高。

为了提升预测精度,本文通过数据清洗减少异常值的影响,并可进一步引入Isolation Forest方法增强数据鲁棒性。通过特征重要性分析优化输入特征选择,减少冗余信息以提高模型泛化能力。此外,动态邻接矩阵的引入使模型能够根据实时环境调整电站间关联性,从而提高时空特性捕捉的准确性。

3.3 光伏集群群调群控结果

选用典型的IEEE 33节点系统为对象进行算例仿真,拓扑结构如图5所示。为有效验证所提群间协调控制策略和群内自治控制策略的有效性,以降低节点电压偏差和降低电力系统网损为优化目标,设置主导节点电压运行于安全范围内、主导节点电压越上限和主导节点电压越下限3个场景进行分析验证。

3.3.1 群间协调优化策略仿真结果

图6和表2分别展示了系统调节前和调节后的各节点电压幅值及偏差模值和系统网损。

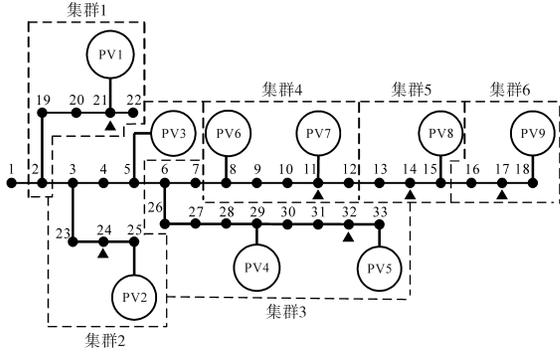


图5 典型IEEE 33节点系统拓扑结构

Fig.5 Typical topology of IEEE 33 nodes system

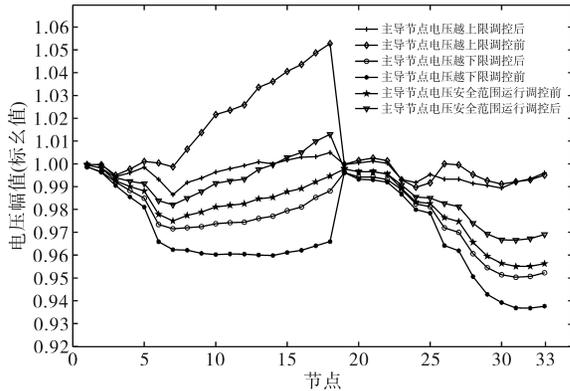


图6 系统调节前和调节后各节点电压幅值(群间)

Fig.6 Voltage magnitudes of each node before and after system regulation (between groups)

表2 节点电压偏差模值和系统网损

Tab.2 Node voltage deviation magnitude and system power loss

场景	调控前后	主导节点电压偏差模值的和(标幺值)	节点电压最大偏差模值(标幺值)	全部节点电压偏差模值的和(标幺值)	系统网损/kW
主导节点电压在安全范围内运行	前	0.106	0.046	0.605	98.54
	后	0.067	0.022	0.350	49.71
主导节点电压越上限	前	0.132	0.054	0.440	215.03
	后	0.118	0.014	0.147	271.98
主导节点电压越下限	前	0.204	0.064	1.037	96.09
	后	0.116	0.047	0.660	50.37

由图6及表2可知:调控优化后相比于调控前,主导节点电压运行于安全范围内的场景下,主导节点电压偏差模值的和下降37.24%、节点电压最大偏差模值下降52.27%、全部节点电压偏差模值的和下降42.2%,分别约为0.0394(标幺值)、0.0242(标幺值)和0.2552(标幺值),系统网损下降了49.55%,约为48.83 kW;主导节点电压越上限场景下,集群6在调节之前,由于主导节点17超过了上限值,触发了紧急调节措施,经调节优化后,集群内所有节点都能够在0.95~1.05(标幺值)的安全电压区间内运行,明显大于其他集群电压幅值的下降度。主导节点电压偏差模值的

和下降了83.75%、节点电压最大偏差模值下降了75.18%、全部节点电压偏差模值的和下降了66.68%,分别约为0.1103(标幺值)、0.0409(标幺值)和0.2936(标幺值),系统网损增加了26.48%,约为56.95 kW;主导节点电压越下限场景下,集群3在调节之前,由于主导节点32超过了下限值,触发了紧急调节措施,经调节优化后,集内所有节点都能够在0.95~1.05(标幺值)的安全电压区间内运行。主导节点电压偏差模值的和下降了42.26%、节点电压最大偏差模值下降了25.47%、全部节点电压偏差模值的和下降了36.33%,分别约为0.086(标幺值)、0.0162(标幺值)和0.3767(标幺值),系统网损增加了47.58%,约为45.72 kW。

上述3种场景调控结果表明:本文提出的群间协调优化控制策略能够有效降低系统主站网络损耗,实现经济高效运行。主导节点电压超出正常范围情况下,该策略也能确保所有节点的电压维持在安全区间,保障系统主站区的稳定性。

3.3.2 群内自治优化策略仿真结果

以整个IEEE 33节点系统为一个集群对群内自治优化进行分场景仿真分析。图7展示了系统优化前和优化后的各节点电压幅值及偏差模值系统网损情况。

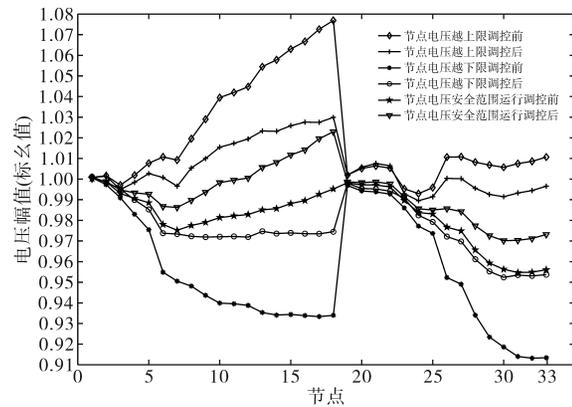


图7 系统调节前和调节后各节点电压幅值(群内)

Fig.7 Voltage magnitudes of each node before and after system regulation (inner groups)

由图7可知,调控优化后相比于调控前,节点电压运行于安全范围内场景下,节点电压偏差模值的和下降了34.7%、节点电压最大偏差模值下降了40.6%、全系统网损下降42.8%,分别约为0.210(标幺值)、0.027(标幺值)和0.4176(标幺值);节点电压越上限场景下,调控后各个节点均在安全范围内运行且均小于1.03(标幺值),节点电压

偏差模值的和下降了53.17%、节点电压最大偏差模值和下降了65.17%、系统网损分别增加了22.9%,节点电压最大偏差模值调控前和调控后由0.078 1(标么值)下降到0.027 2(标么值)。节点电压偏差模值的和调控前和调控后降低了0.363 4(标么值),系统网损增加了69.8 kW;节点电压越下限场景下,节点电压在安全范围内运行,且均大于0.95(标么值),节点电压偏差模值的和下降了47.04%、节点电压最大偏差模值下降了45.16%、系统网损下降了57.58%,分别约为0.086(标么值)、0.016 2(标么值)、0.376 7(标么值),节点电压最大偏差模值调控前和调控后由0.087 9(标么值)下降到0.048 2(标么值)。节点电压偏差模值的和调控后降低了0.071 6(标么值),系统网损降低了74.92 kW。

上述3种场景调控结果表明:本文提出的群内自治优化控制策略不仅能够确保系统在安全范围运行,还能有效降低系统网损,实现经济效益最大化;在节点电压超出正常范围时也可以使节点电压保持在安全区域稳定运行。

4 结论

本文提出了一种基于改进时空图卷积神经网络的光伏出力预测模型,提高了光伏出力预测精度的同时实现了光伏电站群的安全经济稳定运行,主要结论如下:

1)所提时空图卷积神经网络能够兼顾图卷积提取空间特征的能力与LSTM提取时间特征的能力,有效学习多站光伏出力曲线及数值天气预报数据间的隐藏时空关系,从而提高预测准确率。与仅采用GRU的单站预测模型或聚类LSTM神经网络等传统方法相比,平均绝对误差进一步降低了10.5%以上。

2)自适应邻接矩阵学习方法能够自动学习不同光伏电站的站间相关性,比使用固定参数邻接矩阵时预测误差更低。而引入注意力机制能够挖掘模型当前时刻光伏功率输出与历史关键时刻信息的关联关系,从而提高预测精度。

3)通过协调各集群和集群内各光伏场站实现了光伏集群的安全经济运行及分布式光伏的最大消纳,并在不同场景下有效降低节点电压偏差及网损。

为提升计算效率,未来将简化GCN或LSTM层数,采用轻量架构,并结合模型压缩技术与并

行计算优化模型在大规模光伏集群中的实时性能。为增强模型的泛化能力,计划在不同区域和气候条件下进行跨区域测试与优化,提升其在多场景中的鲁棒性。引入迁移学习技术,可以帮助模型快速适应新环境,提升其通用性。

参考文献

- [1] 张林,刘继春,马靖宇,等.基于函数型特征数据的光伏短期功率预测方法[J].电气传动,2021,51(12):66-73.
ZHANG Lin, LIU Jichun, MA Jingyu, et al. Short term power forecasting method of photovoltaic based on functional characteristic data[J]. Electric Drive, 2021, 51(12): 66-73.
- [2] 时培明,郭轩宇,杜清灿,等.基于TCN-BiLSTM-Attention-ESN的光伏功率预测[J].太阳能学报,2024,45(9):304-316.
SHI Peiming, GUO Xuanyu, DU Qingcan, et al. Photovoltaic power prediction based on TCN-BiLSTM-Attention-ESN[J]. Acta Energetica Solaris Sinica, 2024, 45(9): 304-316.
- [3] 董明,李晓枫,杨章,等.基于数据驱动的分布式光伏发电功率预测方法研究进展[J].电网与清洁能源,2024,40(1):8-17,28.
DONG Ming, LI Xiaofeng, YANG Zhang, et al. Research progress on data-driven prediction methods for distributed photovoltaic power generation[J]. Power System and Clean Energy, 2024, 40(1): 8-17, 28.
- [4] 阮呈隆,李康平,李正辉,等.分布式光伏集群功率短期预测的空间互补特性初探[J].电力系统自动化,2024,48(3):42-50.
RUAN Chenglong, LI Kangping, LI Zhenghui, et al. Preliminary study on spatial complementarity characteristics of short-term power prediction for distributed photovoltaic clusters[J]. Automation of Electric Power Systems, 2024, 48(3): 42-50.
- [5] 陈璨,苏紫诺,马原,等.基于分层关联性建模的分布式光伏功率超短期概率预测[J].中国电力,2024,57(12):50-59.
CHEN Can, SU Zinuo, MA Yuan, et al. Ultra-short-term probabilistic forecasting of distributed photovoltaic power based on hierarchical correlation modeling[J]. Electric Power, 2024, 57(12): 50-59.
- [6] 赵洱崇,陈建民,宋珏池,等.考虑光伏不确定性的电力调度方案构建与对比[J].现代电力,2021,38(6):591-600.
ZHAO Erdong, CHEN Jianmin, SONG Juechi, et al. Construction and comparison of power dispatched schemes considering photovoltaic uncertainty[J]. Modern Electric Power, 2021, 38(6): 591-600.
- [7] 王登海,安玥馨,廖晨博,等.基于CNN-LSTM混合神经网络的光伏发电量预测方法研究[J].西安石油大学学报(自然科学版),2024,39(1):129-134.
WANG Denghai, AN Yuexin, LIAO Chenbo, et al. Research on photovoltaic generation prediction method based on CNN-LSTM hybrid neural network[J]. Journal of Xi'an Shiyou Uni-

- versity (Natural Science Edition), 2024, 39(1): 129–134.
- [8] 周强, 张晓忠, 陈久益, 等. 基于遗传算法小波神经网络的光伏电站发电量预测方法[J]. 智慧电力, 2024, 52(4): 78–84.
ZHOU Qiang, ZHANG Xiaozhong, CHEN Jiuyi, et al. Power generation forecasting methods of photovoltaic power plants based on genetic wavelet neural network method[J]. Smart Power, 2024, 52(4): 78–84.
- [9] 张雪松, 李鹏, 周亦尧, 等. 基于贝叶斯概率的光伏出力组合预测方法[J]. 太阳能学报, 2021, 42(10): 80–86.
ZHANG Xuesong, LI Peng, ZHOU Yiyao, et al. Photovoltaic output combination forecasting method based on bayesian probability[J]. Acta Energetica Solaris Sinica, 2021, 42(10): 80–86.
- [10] 黄博阳, 何肖蒙, 肖小兵, 等. 基于FCM-WS-BP的光伏日前出力预测研究[J]. 控制工程, 2023, 30(12): 2254–2260.
HUANG Boyang, HE Xiaomeng, XIAO Xiaobing, et al. Research of photovoltaic day-ahead output power prediction based on FCM-WS-BP[J]. Control Engineering of China, 2023, 30(12): 2254–2260.
- [11] SAAD P D, STEFAN B, LUKAS W, et al. Photovoltaic yield prediction using an irradiance forecast model based on multiple neural networks[J]. Journal of Modern Power Systems and Clean Energy, 2018, 6(2): 255–267.
- [12] HU Wei, ZHANG Xinyan, ZHU Lijuan, et al. Short-term photovoltaic power prediction based on similar days and improved SOA-DBN model[J]. IEEE Access, 2021, 8: 1958–971.
- [13] WOONGHEE L, KEONWOO K, JUNSEP P, et al. Forecasting solar power using long-short term memory and convolutional neural networks[J]. IEEE Access, 2018, 6: 73068–73080.
- [14] 王福忠, 王帅峰, 张丽. 基于VMD-LSTM与误差补偿的光伏发电超短期功率预测[J]. 太阳能学报, 2022, 43(8): 96–103.
WANG Fuzhong, WANG Shuaifeng, ZHANG Li, et al. Ultra short term power prediction of photovoltaic power generation based on VMD-LSTM and error compensation[J]. Acta Energetica Solaris Sinica, 2022, 43(8): 96–103.
- [15] 谭海旺, 杨启亮, 邢建春, 等. 基于XGBoost-LSTM组合模型的光伏发电功率预测[J]. 太阳能学报, 2022, 43(8): 75–81.
TAN Haiwang, YANG Qiliang, XING Jianchun, et al. Photovoltaic power prediction based on combined XGBoost-LSTM model [J]. Acta Energetica Solaris Sinica, 2022, 43(8): 75–81.
- [16] 毕贵红, 赵鑫, 陈臣鹏, 等. 基于多通道输入和PCNN-BiLSTM的光伏发电功率超短期预测[J]. 电网技术, 2022, 46(9): 3463–3476.
BI Guihong, ZHAO Xin, CHEN Chenpeng, et al. Ultra-short-term prediction of photovoltaic power generation based on multi-channel input and PCNN-BiLSTM[J]. Power System Technology, 2022, 46(9): 3463–3476.
- [17] 刘运超, 杨宁, 崔承刚, 等. 基于时空信息的区域内光伏电站功率预测[J]. 科学技术与工程, 2023, 23(34): 14596–14602.
LIU Yunchao, YANG Ning, CUI Chenggang, et al. Power prediction of regional photovoltaic plants based on spatio-temporal information[J]. Science Technology and Engineering, 2023, 23(34): 14596–14602.
- [18] 杨锡运, 赵泽宇, 杨岩, 等. 基于时空信息组合的分布式光伏功率预测方法研究[J]. 热力发电, 2022, 51(8): 64–72.
YANG Xiyun, ZHAO Zeyu, YANG Yan, et al. Research on distributed photovoltaic power prediction method based on combination of spatiotemporal information[J]. Thermal Power Generation, 2022, 51(8): 64–72.
- [19] 柴园园, 刘一欣, 王成山, 等. 含不完全量测的分布式光伏发电集群电压协调控制[J]. 中国电机工程学报, 2019, 39(8): 2202–2212.
CHAI Yuanyuan, LIU Yixin, WANG Chengshan, et al. Coordinated voltage control for distributed PVs clusters with incomplete measurements[J]. Proceedings of the CSEE, 2019, 39(8): 2202–2212.
- [20] 黄冬梅, 余京朋, 崔承刚, 等. 多时间尺度深度强化学习光储配电网电压优化[J]. 中国电机工程学报, 2025, 45(17): 6709–6722.
HUANG Dongmei, YU Jingpeng, CUI Chenggang et al. Voltage optimization for PV-ES distribution network with multi-timescale deep reinforcement learning method[J]. Proceedings of the CSEE, 2025, 45(17): 6709–6722.
- [21] 邓序之, 刘淇, 叶傲霜, 等. 基于气象耦合特征分析及改进XGBoost算法的用户分布式光伏短期出力预测模型[J]. 南方电网技术, 2023, 17(12): 80–89.
DENG Xuzhi, LIU Qi, YE Aoshuang, et al. Short-term output forecasting model of user side distributed photovoltaic based on meteorological coupling characteristics analysis and improved XGBoost algorithm[J]. Southern Power System Technology, 2023, 17(12): 80–89.
- [22] 丁正凯, 傅启明, 陈建平, 等. 结合注意力机制与深度强化学习的超短期光伏功率预测[J]. 计算机应用, 2023, 43(5): 1647–1654.
DING Zhengkai, FU Qiming, CHEN Jianping, et al. Ultra-short-term photovoltaic power prediction by deep reinforcement learning based on attention mechanism[J]. Journal of Computer Applications, 2023, 43(5): 1647–1654.
- [23] 黎静华, 赖昌伟. 考虑气象因素的短期光伏出力预测的奇异谱分析方法[J]. 电力自动化设备, 2018, 38(5): 50–57, 76.
LI Jinghua, LAI Changwei. Singular spectrum analysis method for short-term photovoltaic output prediction considering meteorological factors[J]. Electric Power Automation Equipment, 2018, 38(5): 50–57, 76.
- [24] 王晶, 黄越辉, 李驰, 等. 考虑空间相关性和天气类型划分的多光伏电站时间序列建模方法[J]. 电网技术, 2020, 44(4): 1376–1384.
WANG Jing, HUANG Yuehui, LI Chi, et al. Time series modeling method for multi-photovoltaic power stations considering spatial correlation and weather type classification[J]. Power System Technology, 2020, 44(4): 1376–1384.

收稿日期:2024-09-23

修改稿日期:2024-10-29