

[分布式光伏]

考虑数据互相关性的广域分布式光伏发电超短期预测方法

文/苏涛 宁国强
国网浙江省温州供电公司

提出一种基于多尺度相关机制的超短期分布式光伏功率预测方法，旨在通过捕捉分布式光伏场站间的时空关联性，提高预测准确度。通过引入多层次的树状结构，该机制有效地建模光伏场站之间的空间相关性，并结合差分操作和自注意力机制，提取不同时空尺度下的功率波动特征。实验结果表明，所提出的多尺度相关机制在超短期光伏功率预测中相比LSTM和Transformer模型具有更优的预测准确度。

分布式光伏功率预测对电力调度和应对发电不确定性在电网稳定运行中的作用至关重要。由于分布式光伏场站一般地理位置较为分散、单体容量较小且成本较低，通常无法获取高准确度的就近实时气象预报数据。这严重限制光伏功率预测的准确性，最终可能导致不稳定发电，对电网造成冲击。不过光照强度与光伏发电功率有着紧密的关系，因此，分布式光伏场站的发电功率能反映其所在地区的辐照度变化和气象因素的波动。随着分布式光伏系统的增多，光伏场站本身形成一个采集光照强度的传感器网络。因此，合理运用光伏场站的数据互相关性可以提升光伏功率预测的准确度。

当前在此类相关性研究中，主要分为基于近单一场站数据和利用多个光伏场站集群数据来分析气象特征波动两种路径。针对单一场站数据的参考方法，例如文献[1]中提出，通过选择与待预测场站相关的光伏电站作为参考站，利用模型提取主从站之间的时空关联性，从而提高预测准确度。但这种方法过于依赖参考站的数据质量，特别是在样本稀少或发生功率限制时，预测准确度可能受到严重影响。为解决这一问题，文献[2]通过将大区域划分为小网格，基于曲线特征距离筛选与待预测场站最相

关的相似日，并采用三维卷积神经网络建立网格化辐照预测与光伏功率输出之间的映射关系，通过发电起止时刻校正进一步提升预测准确性。

另一类研究则集中在使用光伏场站集群数据。比如，基于变量注意力机制的风光荷联动特征提取模块构建一个能够根据不同预测任务损失权重自动优化的多任务学习模型^[3]，用于风光协同预测。然而，单纯依赖注意力机制进行自动优化，忽视了场站间地理距离对相关性的影响，可能导致模型将空间距离较远的场站误认为是高相关性场站。为解决这一问题，文献[4]结合皮尔逊相关系数、归一化欧氏距离等多种指标，更好地捕捉二维分布式光伏测量框架中的时空模式，并对不同时空模式的场站进行分类预测，从而提高预测准确度。

然而，光伏场站之间的时空关联性是不断变化的^[5]，尤其是对于光伏场站集群而言，其波动范式在一段时间内难以保持不变，且分布式光伏集群的功率波动在不同尺度表现出不同的模式^[6]，基于时空模式的划分难以实现高粒度的光伏功率准确预测。对此，本文提出多尺度相关机制，在时间和空间方面分别进行建模。空间上在注意力机制中引入多层次的树状结构，时间上通过差分提取不同尺度

光伏功率特征之间的差异性，从而捕捉不同尺度的光伏场站之间的时空相关性。

多尺度相关机制

随着光照在地表的移动，光伏场站之间的发电功率数据呈现出时空相关性，距离极近的光伏场站之间往往具有相似的波动趋势，而距离较远的场站可能表现出相反的波动趋势。这种现象表明，气象要素在分布不规则的光伏场站之间存在空间传播关系。仅通过在时间维度进行建模，难以准确捕捉和描述这种空间传播特征^[7]。

为更好地模拟这一特征变化，必须引入光伏场站之间的空间相关性。本文提出多尺度相关机制，其模型结构如图1所示。多尺度相关机制在空间和时间两方面分别进行建模，以便全面捕捉光伏场站间复杂的功率波动模式。




图1 多尺度相关机制模型结构

1. 空间相关性建模

在空间建模方面，多尺度相关机制引入多层级的树状结构来捕捉光伏场站之间的空间相关性。该结构通过自下而上聚合，使得每一层的节点表示不同的空间尺度，自底层至顶层，节点数逐层减少，从而实现空间信息的逐步汇总，并将场站间的互相关性聚焦在局部与全局的关系中。

在节点的最底层，每个节点对应一个光伏场站的信息，包含该场站的功率波动特征。随后通过对场站经纬度的聚类，将底层节点划分为子场站集群，并通过平均池化的方式提取子场站集群的共性功率特征作为父节点的特征。因此，高层节点为低层节点时序特征在更粗颗粒度空间的共性表达，其空间信息汇聚的过程如图2所示。




图2 空间节点汇聚过程

2. 时间相关性建模

在时间建模方面，多尺度相关机制通过引入父节点与子节点之间的差分操作，提取不同尺度下的时间波动信息。具体而言，时间维度的建模过程如下。

(1) 差分操作与波动提取

在每一层级，父节点与每个子节点的时间序列进行差分操作，提取出子节点在该尺度下的波动分量。通过这种方式，能够明确捕捉到每个光伏场站在不同时间尺度下对气象变化的响应特征。

其差分过程可表述为

$$\Delta x_{i,t}^k = x_{i,t}^k - \frac{1}{N} \sum_{j \in \mathcal{N}_{i,t}^k} x_{j,t}^k \quad (1)$$

式中， $\Delta x_{i,t}^k$ 为在 k 层次尺度下节点 i 的功率波动分量； $x_{i,t}^k$ 为在第 k 层次尺度下节点 i 的功率值； $\mathcal{N}_{i,t}^k$ 为光伏场站 i 在第 $k-1$ 层次尺度下的子节点集合。

(2) 功率波动特征在注意力机制中的传播

MSCM基于自注意力机制进行改进，令 $Q^k = w_1^k x_{i,t}^k$ 、 $K^k = w_2^k \Delta x_{i,t}^k$ 、 $V^k = w_3^k \Delta x_{i,t}^k$ ，其中 w_1^k 、 w_2^k 、 w_3^k 为可学习的参数，节点的功率序列和功率波动特征在注意力机制中传播，以捕捉特征在不同时空尺度的作用关系。在每一个节点层中，特征传播过程可表述为

$$O_i^k = \frac{Q^k K^k}{\sqrt{d^k}} \times V^k \quad (2)$$

式中， d^k 为 K^k 的特征维度，用于进行矩阵的归一化处理。

经过以上过程，MSCM将空间和时间两方面的建模过程相结合，进行光伏功率的特征聚合，从而赋予模型提取多场站间时空关联性的能力，显著提高超短期功率预测的准确性和鲁棒性。

实验仿真

本研究使用SolarNet2022数据集，数据集涵盖

1 023个分布式光伏场站2021—2022年的发电功率记录,时间分辨率为15 min^[8-9]。此外,数据集还记录每个光伏场站的经度和纬度。

数据集从时序上以8:1:1的比例分为训练、测试和验证集合,并配备NVIDIA GeForce GTX

3080Ti 16GB的Linux服务器上训练。

为探讨多尺度相关机制的性能,本文选取LSTM神经网络、Transformer网络、单层多尺度相关机制模块及双层多尺度相关机制模块组成的模型分别进行预测,并选取部分预测结果,如图3所示。




图3 不同模型在该数据集上的预测结果

为量化不同方案在数据集上的预测效果,误差分析阶段采用RMSE和MAE误差^[10],计算公式为

$$\begin{cases} e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_{\text{real}} - x_{\text{pre}}} \\ e_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |x_{\text{real}} - x_{\text{pre}}| \end{cases} \quad (3)$$

式中, x_{real} 为真实值; x_{pre} 为预测值; N 为接受评估的数据条数。

应用上述指标评价不同模型在测试集上的平均预测准确度得到结果见表1。

表1 不同模型预测误差对比

模型	MAE误差	RMSE误差
LSTM	0.094	0.164
Transformer	0.074	0.143
多尺度相关机制(单层)	0.071	0.131
多尺度相关机制(双层)	0.068	0.121

由表1可知,应用本文所提的多尺度相关机制后,模型预测准确度优于LSTM模型和Transformer模型。

为探究多尺度相关机制在构筑光伏集群时空相关性方面的性能,本文设计在单层多尺度相关模型中对比不同节点层数对光伏预测效果的影响。为此设计不同层数的节点组别,见表2。

表2 多尺度相关机制节点层设定

实验组别	节点设置
Node ¹	[460,132,34,10,5]
Node ²	[460,256,132,34,10,5]
Node ³	[460,256,132,34,8,10,5]
Node ⁴	[460,256,132,34,16,8,10,5]
Node ⁵	[460,256,132,64,34,16,8,10,5]

实验结果如图4所示,在超短期光伏功率预测的不同预测时间步长中,Node³组别实现了最高的综合预测准确度。这说明多尺度相关机制中,存在最合适的节点层数设定限制。在进行综合调优时,推荐采用经验法则,即子节点的尺度应设置为父节点尺度的1/3~1/2范围内,也说明了多尺度相关机制的有效性。




图4 不同组别下的预测准确度

本文提出一种基于多尺度相关机制的超短期分布式光伏功率预测方法,通过引入层次化的时空关联性建模,充分考虑光伏场站之间的地理距离和气象变化对功率波动的影响。实验结果表明,所提出的多尺度相关机制显著提高光伏功率预测的准确性和鲁棒性,相较于传统的LSTM和Transformer模型,本方法在不同时间尺度下的预测效果更为优越,尤其在光伏场站集群的时空相关性建模方面表现突出。

未来的研究可以进一步探索如何在大规模、动态变化的光伏场站网络中实现实时的功率预测,并将更多复杂的气象因素纳入考虑,进一步提升分布式光伏发电预测的准确度和实用性。这将为电力调度和电网稳定运行提供更为可靠的支持,并推动光伏发电技术的进一步发展与应用。EA

(收稿日期:2025-03-19)

参考文献

- [1] ELSINGA B, VAN Sark W. Spatial power fluctuation correlations in urban roof top photovoltaic systems[J]. Progress in Photovoltaics: Research and Applications, 2015, 23(10): 1390-1397.
- [2] 乔颖,孙荣富,丁然,等.基于数据增强的分布式光伏电站群短期功率预测(二):网格化预测[J].电网技术,2021,45(6):2210-2218.
- [3] 严华江,章坚民,胡瑛俊,等.考虑空间相关性的分布式光伏发电出力预测及误差评价指标研究[J].浙江电力,2020,39(3):54-60.
- [4] Wang Y, Fu W, Wang J, et al. Ultra-short-term distributed PV power forecasting for virtual power plant considering data-scarce scenarios[J]. Applied Energy, 2024 (373): 123890.
- [5] Wang Y, Huo C, Xu F, et al. Ultra-Short-Term Distributed Photovoltaic Power Probabilistic Forecasting Method Based on Federated Learning and Joint Probability Distribution Modeling[J]. Energies, 2025, 18(1): 197.
- [6] Fu W, Zhang X, Wang J, et al. A Spatiotemporal Federated Learning Based Distributed Photovoltaic Ultra-short-term Power Forecasting Method[C]/. 2023 IEEE/IAS 59th Industrial and Commercial Power Systems Technical Conference (I&CPS). IEEE, 2023: 1-7.
- [7] 赵洪山,孙承妍,温开云,等.基于有向图卷积循环网络的分布式光伏出力超短期预测方法[J].太阳能学报,2024,45(8):281-288.
- [8] 陈建军,李良杰,卢泽汉.基于改进LSTM-TCN模型的分布式光伏功率预测研究[J].电子设计工程,2024,32(16):187-190+195.
- [9] 刘博文.基于时序迁移学习算法的有源配电网多区域分布式光伏功率预测方法[J].长江信息通信,2024,37(8):119-121.
- [10] 赵龙,杨波,卢志鹏,等.基于谱聚类和AM-LSTM的分布式光伏集群超短期预测方法[J].供用电,2023,40(7):10-17.

