

DOI: 10.19783/j.cnki.pspc.241078

基于 K 均值聚类的光伏集群发电功率超短期预测研究

文贤馗¹, 何明君¹, 张俊玮¹, 周科¹, 蔡永翔¹, 张凡²

(1. 贵州电网有限责任公司电力科学研究院, 贵州 贵阳 550002;

2. 南方电网人工智能科技有限公司, 广东 广州 510000)

摘要: 准确的分布式光伏超短期功率预测对于分布式光伏接入电网具有至关重要的意义, 但是当前分布式光伏功率预测中存在气象数据精度不够、功率数据不完整等问题。为此, 提出了一种基于集群划分的区域光伏预测方法。首先选择正反向电量比、功率中位数与平均数比值两个维度作为距离计算依据, 采用 K 均值聚类算法对区域中所有光伏电站进行集群划分。在集群划分的基础上, 对每个集群分别进行光伏功率预测, 然后综合所有集群的预测结果实现对分布式光伏区域预测。最后采用某区域分布式光伏发电场站数据进行了验证。结果表明: 所提算法精度较高, 所提方法能够满足现场的要求。

关键词: 分布式光伏; 集群划分; 功率预测; K 均值聚类; 长短期记忆网络

Research on ultra-short-term power forecasting of photovoltaic clusters based on K -means clustering

WEN Xiankui¹, HE Mingjun¹, ZHANG Junwei¹, ZHOU Ke¹, CAI Yongxiang¹, ZHANG Fan²

(1. Guizhou Power Grid Electric Power Science Research Institute, Guiyang 550002, China;

2. CSG Artificial Intelligence Technology Co., Ltd., Guangzhou 510000, China)

Abstract: Accurate ultra-short-term power forecasting for distributed photovoltaic (PV) systems is critically important for their integration into the power grid. However, current forecasting efforts face challenges such as insufficient accuracy in meteorological data and incomplete power data. To address these issues, this paper proposes a regional PV forecasting method based on cluster partitioning. First, two metrics, i.e., forward/reverse electricity ratio and the ratio of power median to mean, are selected as the basis for distance calculation. The K -means clustering algorithm is then used to divide all PV power plants in the region into clusters. Based on this clustering, PV power forecasting is carried out for each cluster, and the combined results from all clusters are used to produce a regional forecast for distributed PV output. Finally, data from a distributed PV power plant in a specific region is used for verification. The results show that the proposed algorithm has high accuracy and can meet the practical requirements of field applications.

This work is supported by the Science and Technology Plan Program of Guizhou Province (No. CXTD[2022]008).

Key words: distributed photovoltaics; cluster partitioning; power forecasting; K -means clustering; long short-term memory network

0 引言

光伏发电受光照、温度等气象因素的影响, 间歇性、随机性和波动性大^[1-3]。在国家有关政策的扶持下, 分布式光伏装机不断增加, 其对电网运行的影响呈现“局部向全局发展、低压占比不断提升”

的趋势。随着分布式光伏的大规模接入, 光伏发电对电力系统的影响越来越深远^[4-6]。准确预测光伏功率将有助于电力系统管理人员调整光伏电站发电计划, 或提前制定光伏就地消纳计划, 实现电网的平衡调度, 也可以为光储充一体化系统的优化运行提供底层数据^[7-9]。

短期光伏发电功率预测是目前可再生能源领域的热点之一, 深度学习的方法已广泛应用于发电预测领域^[10-11]。对于集中式光伏预测, 聚类、神经网络

基金项目: 贵州省科技计划项目资助(CXTD[2022]008); 南方电网科技项目资助(GZKJXM2022258)

等大数据与人工智能类方法^[10-13]得到广泛关注,通过不断改进气象预报质量和预测方法等措施可提高超短期预测精度^[14-16]。而对于分布式光伏预测,虽然可借鉴集中式光伏预测方法,但分布式光伏站缺少实测和预测、天气和电气等数据,例如超过80%的接入低压配电的户用光伏只有配电营销系统日电量数据,几乎所有的分布式光伏站点都没有实际测量的辐照度和天气预报数据,因此难以直接复制其成熟的技术路线^[17-19]。数据不完整使得分布式光伏不具备开展单光伏电站独立高水平短期预测的条件,一种行之有效的方法是将所有特性相似的光伏站等效成一个大型的光伏站,进而对该等效光伏站进行功率预测。所有特性相似的光伏站等效成一个大型的光伏站就是一个聚类的过程^[20-28],目前聚类的主要方法包括: *K*-means 聚类及其各类改进算法、Fast Unfolding 聚类算法、基于密度峰值的聚类算法、基于联邦学习的合成聚类算法等。

基于以上研究,本文提出了基于聚类算法的分布式光伏发电功率预测方法,并结合某区域的分布式光伏发电场站数据,采用相似发电特性的原理,使用 *K* 均值聚类算法实现集群划分并使用长短期记忆(long short-term memory, LSTM)网络模型来进行光伏发电功率预测。实验数据表明,该方法有效解决了分布式光伏的预测问题。

1 基于 *K* 均值聚类的光伏集群划分

1.1 集群划分基本思路

光伏电站的出力受到地理、气候等多种因素的影响,因此在同一区域内,不同电站的出力可能存在显著差异。为了有效管理和预测这些电站的出力,需要按照光伏电站的运行特性进行适当的集群划分,确保同一集群(相同的气象特征,例如同样的光照和温度)在同一时段具有相似的出力特性。

在满足上述条件的基础上,选择合适的聚类方法对光伏电站进行集群划分,以实现更有效的管理和预测。本文使用的 *K* 均值聚类算法是一种迭代求解的聚类分析方法。其核心思想是将数据划分为 *K* 个组,并随机选择 *K* 个对象当作初始聚类中心。

它先将所有的数据分成几个组,然后在每个组里面各选一个数据点作为中心。接下来,计算每个数据点与所有中心之间的间隔,并将每个数据点分给距离最近的中心。随着每次分配情况的变化,中心会根据分配后的结果重新计算。这一操作不停迭代,直到符合某一个终止条件。这个条件可以是每一组数据内的误差平方和(sum of squared error, SSE)达到最小,或者是中心不再变化,或者是各组分配

的数据点不再变动。算法的聚类流程如图 1 所示。

算法遵循以下步骤来划分数据:

- 1) 给每个类选择一个初始聚类中心。
- 2) 依据最小间距原则,把样本分到最近的类别。
- 3) 使用每个类别的样本均值来更新类别中心。
- 4) 重复步骤 2)和 3),直到类别中心不再发生变化。
- 5) 输出最终的类别中心和 *K* 个簇的划分。

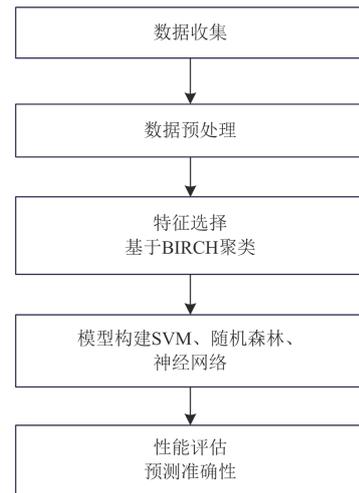


图 1 *K* 均值聚类流程

Fig. 1 *K*-means clustering process

1.2 集群划分的距离计算方法

集群划分的距离计算方法是算法的核心,选择合适的指标进行距离计算是算法的关键。计算距离的参数可以从不同角度选择,包括地理位置、气候条件、地形地貌、发电特性以及电网规划等。根据本文的研究结果,选取光伏发电客户的正反向电量比、功率中位数与平均数比值两个维度作为距离计算的参数,达到了较好的效果。

1.2.1 正反向电量比

正向电量和反向电量是分布式光伏场站能够获取的准确数据,其中两者数值上受到光伏场站出力、区域负荷变化的影响。首先求取每日的正反电量比,然后将训练期间所有有效比值相加求平均值。通过正反向电量比可以综合考虑该区域光伏和区域负荷的相对强弱,以及受到天气影响的情况。

1.2.2 功率中位数与平均数比值

选取光伏发电的正向电量,计算发电场站训练期间每日平均功率和功率中位值(功率为 0 的除外),然后计算功率中位数和平均数的比值(功率可以通过电量和时间计算得到);最后将所有有效比值相加求平均值。该比值反映了光伏发电的长时间累计特征,可以反映光伏场站的出力特性。

由于两个维度都是百分比, 具有相同的维度, 因而可以直接进行聚类分析。

1.3 K 均值聚类的 K 值确定

要实现区域内光伏聚类, 首先要确定聚成多少类。手肘法和轮廓系数法是确定集群数量的一种很好的选择。

1.3.1 手肘法

手肘法是一种用于确定 K 均值聚类算法中聚类个数的方法。它的核心指标是 SSE, 能表示所有样本的划分误差, 反映了划分效果的好坏。

SSE 的计算公式为

$$\sigma = \sum_{i=1}^k \sum_{p \in C_i} |p - m_i|^2 \quad (1)$$

式中: k 为聚类的类别数量; C_i 为第 i 个组; p 为 C_i 中的对象; m_i 为 C_i 中所有对象的平均值; σ 为所有类的 SSE, 表示聚类效果的好坏。

随着 K 值选取的增大, 对所有数据进行分类后的组别就会越多, 这会提升每一个组的聚合程度, 使 SSE 逐渐减小。在选定的 K 小于实际合适的分组数时, 增加 K 的取值会显著提升每个组的聚合程度, SSE 也会显著下降。一旦 K 的选取达到或超过合适的分组数时, 继续增加 K , 对数据的分类效果提升不大, 因此 SSE 下降也不会明显。绘制 K 和 SSE 的折线图, 可以看到图像类似一个“手肘”, 在拐点对应的 K 值就是数据的理想分组数, 如图 2 所示。本文同时使用平均离差作为指标, 它是用所有数据相对于它们的平均值的决定误差来衡量这些数据的离散程度。

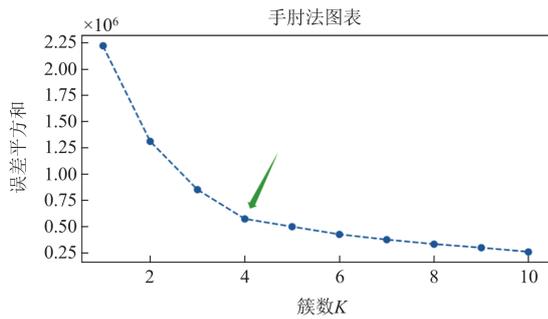


图 2 误差平方和与 K 值的关系图

Fig. 2 Relationship between SSE and K value

1.3.2 轮廓系数

轮廓系数能描述所有数据分组后的各组数据的轮廓清晰度, 是一个用于评估聚类效果的指标, 有助于判断聚类结果的质量。

轮廓系数包含两个方面。首先是内聚度, 即单

一数据点与其所属组别内其他数据点的紧密程度。然后是分离度, 即单一数据点与其他组别中数据点的间距。轮廓系数 $S(i)$ 和数据点的内聚度 $a(i)$ 的公式分别如式(2)和式(3)所示。

$$S(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (2)$$

$$a(i) = \frac{1}{n-1} \sum_{j \neq i}^n d(i, j) \quad (3)$$

式中: j 代表与数据点 i 在同一个组内的其他样本点; $d(i, j)$ 表示 i 与 j 之间的距离, $a(i)$ 越小说明该组越紧密; $b(i)$ 表示 i 到某一不包含它的簇内的所有点的平均距离, 计算方式与 $a(i)$ 类似。

轮廓系数越大越好, 越大的轮廓系数表示聚类效果越好。当 $a(i) < b(i)$ 时, 即组内的距离小于组间距离, 表示组内的数据很紧凑。轮廓系数会趋近于 1, 越趋近于 1 代表轮廓越明显。相反, 当 $a(i) > b(i)$ 时, 组内的距离大于组间距离, 说明组内的数据点很分散。在这种情况下, 轮廓系数会趋近于 -1, 表示聚类效果越差。

2 集群功率预测

2.1 LSTM 算法原理

LSTM 是一种强大的递归神经网络(recursive neural network, RNN), 特别适用于处理具有长期依赖关系的序列数据。它解决了传统 RNN 中存在的梯度消失问题, 通过引入一种控制信息流的门控机制来实现。LSTM 对于时间间隔的长度相对不敏感, 这是它的优势。它旨在为 RNN 提供一个可以持续数千个时间步的短期记忆, 因此被称为“长短期记忆”。实践表明, LSTM 在光伏功率预测中有不俗的表现。

2.2 预测评价指标

预测结果中选择平均绝对误差(mean absolute error, MAE)、均方误差(mean square error, MSE)、均方根误差(root mean squared error, RMSE)、决定系数(R^2)和平均绝对百分比误差(mean absolute percentage error, MAPE)这 5 个指标进行预测精度评价, 其计算公式分别为

$$E_{MAE} = \frac{1}{N} \sum_{i=1}^n (\hat{y}_i - y_i) \quad (4)$$

$$E_{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (5)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (7)$$

$$E_{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (8)$$

式中： \hat{y}_i 为光伏功率预测值； y_i 为光伏功率实际值； \bar{y}_i 为光伏功率的平均值； N 为该类别中样本的数量； n 为样本总数。

MAE、MSE、RMSE 和 MAPE 的范围均为 $[0, +\infty)$ 。当值为 0 时，预测值与实际值没有误差；预测值与实际值的误差随着这几个指标值的增大而增加。

3 实验设计与结果

3.1 集群预测流程

光伏电站集群功率预测是优化区域光伏发电调度的关键。为提高预测精度，在使用 K 均值聚类进行集群划分的基础上预测每一个独立的集群的发电功率，具体步骤如下。

- 1) 数据预处理。对光伏电站集群数据进行清洗，包括数据清洗和归一化处理。
- 2) K 均值聚类。采用正反向电量比、功率中位数与平均数比值两个维度作为距离计算依据，使用 K 均值聚类方法将光伏电站划分为不同的集群。
- 3) 功率预测。选取典型区域的气象信息(单一天气信息)，将同一集群类所有场站的发电功率作为数据集进行预测，设置 LSTM 网络结构和参数，并使用集群累加法进行功率预测。
- 4) 评估。计算并使用 2.2 节的评价指标对集群功率预测效果进行评估。

3.2 算例基础数据

以某地实际分布式光伏发电场站数据来验证所提集群划分算法的有效性。该组实验数据来源于 2022 年某地的分布式光伏发电场站数据，包含用户编号、用户类型、综合倍率、运行容量以及正向有功、反向有功总的累计量，地理位置分布在东经 $104.51^\circ \sim 104.67^\circ$ 、北纬 $25.53^\circ \sim 25.90^\circ$ ，时间为 2022 年 1 月到 2022 年 12 月，如表 1 所示。分布式光伏分布如图 3 所示。

根据台账信息数据及光伏分布图显示，用户数量众多且地理位置分散。将它们作为整体进行光伏发电功率的预测是相当困难的。为了提高预测精度和效率，采用聚类的方法将用户按照相似的日常条件划分为不同的集群，然后针对每个集群进行光伏

功率的预测。

表 1 分布式光伏发电场站台账信息
Table 1 Account information of distributed PV power plant platform

用户类别	所属台区	用户编号
地方电厂	磨打嘎公变	18687692、164577、22598072、160165、8848753
		14784503、14783864、41713、23539448、
地方电厂	岔河公变	22663209、0、32217、8823472、8823211、8848428、8823068
		23088203
地方电厂	磨打嘎公变	23088203
地方电厂	干田坝公变	22665323、22665437、8822938
		38663941、37410572、37123741、35542823、
光伏发电客户	未知	35541133、35540827、35530692、34979396、
		34970665、34963106、34951923、34950247、
		34899045、34896760、34891826

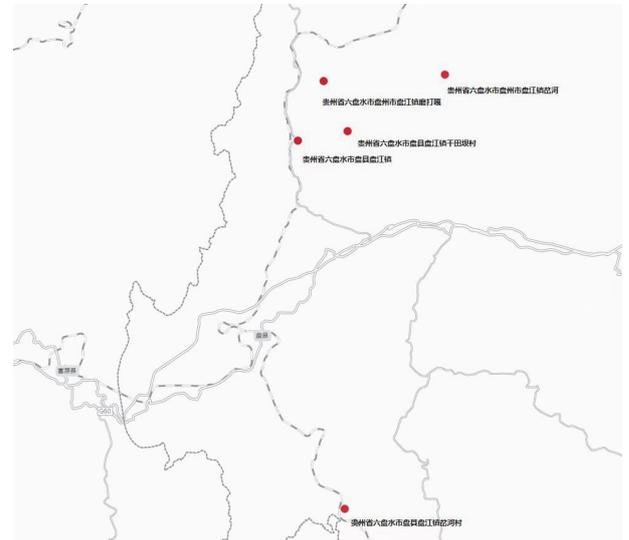


图 3 分布式光伏分布图

Fig. 3 Distribution diagram of distributed PV

3.3 数据预处理

对数据进行预处理，应尽量减少由于异常数据点对预测模型预测功率产生误差的因素。首先剔除那些可能干扰预测的异常值，对数据缺失的光伏发电用户进行适当删减，以确保模型能够更好地拟合实际数据。这里对于正向有功总功率和反向有功总功率的累计量，用后一小时的累计值减去前一小时的累计值，最终得到了 18 个分布式光伏发电场站用户 2022 年 1 月到 2022 年 12 月的正向有功功率和反向有功功率，时间间隔为 1 h。同时将 18 个分布式光伏发电场站用户 2022 年的正向有功功率和反向有功功率相加，得到年正向有功功率和年反向有功功率，如表 2 所示。

表 2 所有分布式光伏发电场站电量数据

Table 2 Data of electricity of all PV power plants

用户编号	年正向有功电度/kWh	年反向有功电度/kWh
0	235.17	1638.08
32217	1203.23	2265.88
41713	171.54	1514.17
164577	1094.94	2354.16
8822938	2845.21	1449.34
8823068	843.41	2348.93
8823211	0.04	2103.1
8823472	1013.64	1591.39
8848428	1200.51	974.13
8848753	1542.17	1784.54
14783864	0.03	2250.31
14784053	296.69	1828.02
18687692	391.37	2321.07
22598072	724.78	2424.31
22663209	1509.5	1144.81
22665323	1396.57	910.71
22665437	1337.26	1462.42
23539448	1106.12	2134.66

3.4 集群划分结果

根据正向电度和反向电度分别计算正反向电量比、功率中位数与平均数比值, 计算 SSE 与平均离差, 绘制出的手肘图如图 4 和图 5 所示。

将 K 值分别设定为 2—9 的多个数值, 计算在这几种情况下聚类后的轮廓系数。根据 K 与轮廓系数一一对应的关系, 画出的折线图如图 6 所示。

两幅手肘图中, 最明显拐点处的 K 值为 6。轮廓系数图中当轮廓系数最大时, K 值也为 6, 因此综合手肘图和轮廓系数图, 可以确定聚类的 K 值为 6。最后将 18 个分布式光伏发电场站用户划分为 6 个集群, 结果如表 3 所示。

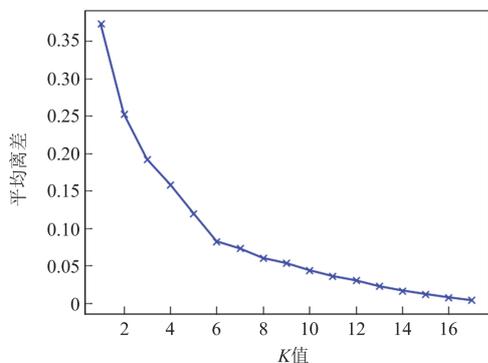


图 4 基于平均离差的手肘图

Fig. 4 Elbow diagram based on average deviation

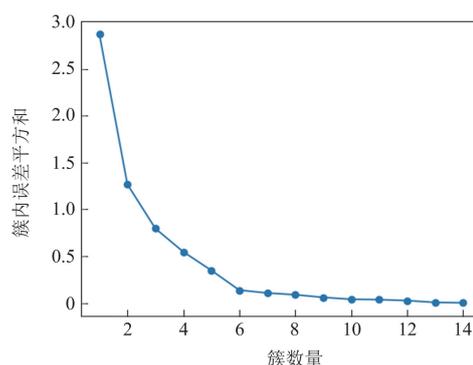


图 5 基于误差平方和的手肘图

Fig. 5 Elbow diagram based on SSE

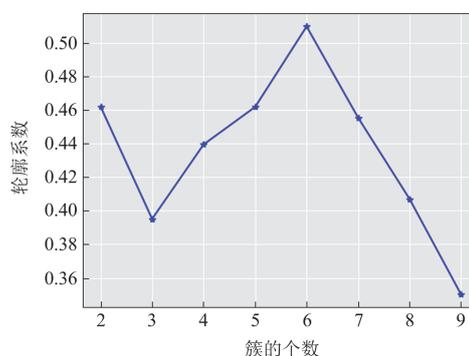


图 6 轮廓系数图

Fig. 6 Contour coefficient diagram

表 3 集群划分结果

Table 3 Cluster partitioning results

集群编号	光伏发电场站编号
集群 1	22663209、22665323、8848428
集群 2	8823211、14783864、18687692
集群 3	8823472、8848753、22665437
集群 4	8822938
集群 5	0、41713、14784053
集群 6	32217、164577、8823068、22598072、23539448

3.5 光伏功率预测结果

将 18 个分布式光伏发电场站用户划分为 6 个集群后, 使用集群累加法, 通过 LSTM 模型来进行光伏功率预测, 本文仅预测分布式光伏发电场站用户的正向有功功率。

模型所用数据为各个集群内分布式光伏发电场站用户的正向有功功率的平均值, 采样步长为 1 h。同时为了防止模型过拟合, 将数据的前 80% 作为训练集, 后 20% 作为测试集。LSTM 模型采用的是前 8 个小时的数据来预测第 12 个小时的数据, 学习率为 0.001, 衰减率为 0.8, 衰减周期为 10, 隐藏单元数为 16, 迭代 3000 次。模型训练完成后, 用测试

集的数据来进行预测, 将各个集群的原始数据与预测结果绘制成图, 将数据归一化后, 计算各自的误差。

求取 6 个集群各自的实际数据和预测结果的误差后, 再综合 6 个集群的预测误差数据, 算出全网的预测误差。每个集群以及全网的预测误差如表 4 所示。

表 4 集群的预测误差

集群编号	MAE	MSE	RMSE	R^2	MAPE/%
群 1	0.0328	0.0042	0.0654	0.9424	7.784
群 2	0.0296	0.0034	0.0584	0.9536	7.205
群 3	0.0319	0.0039	0.0628	0.9467	7.603
群 4	0.0291	0.0033	0.0582	0.9543	7.725
群 5	0.0264	0.0025	0.0507	0.9649	7.817
群 6	0.0337	0.0040	0.0635	0.9458	7.956
全网	0.0305	0.0035	0.0598	0.9512	7.682

将 18 个光伏发电用户划分成 6 个集群后, 在集群划分的基础上求取训练集的全网预测误差结果。其中 MAE 为 0.0305、MSE 为 0.0035、RMSE 为 0.0598, 均接近 0; $R^2 = 0.9512$, $0.9 < R^2 < 1$; 同时 MAPE 为 7.682%。通过训练集的预测结果表明, 模型的拟合效果好。

3.6 对比实验

为了说明本方案集群聚类的优越性, 共设置了以下 4 个方案进行集群预测方法的预测效果验证。

方案 1: 不进行集群划分, 使用单场站累加法; 预测模型使用 LSTM。

方案 2: 按照本文方法进行集群划分, 使用典型场站累加法; 预测模型使用 LSTM。

方案 3: 采用密度聚类算法(density-based spatial clustering of applications with noise, DBSCAN)集群划分, 使用典型场站累加法; 预测模型使用 LSTM。

方案 4: 采用平衡迭代缩减和聚类使用层次结构(balanced iterative reducing and clustering using hierarchies, BIRCH)集群划分, 使用典型场站累加法; 预测模型使用 LSTM。

上述方案中距离计算方式和 LSTM 参数均一致, 只是聚类方法不一样; 由于采用的聚类算法不同, 导致最后聚类的结果有少许差异。4 种方案的预测结果如表 5 所示。

实验结果表明, 采用相同的预测方案, 集群预测和单站累计预测的误差没有本质的区别, 但是相比于单场站累计法而言, 集群算法可以大幅减少预测系统的复杂度和投资成本, 有明显的优越性。

表 5 不同方案误差对比

Table 5 Error comparison between different clustering schemes

方案	MAPE/%
方案 1	7.55
方案 2	7.68
方案 3	8.41
方案 4	8.29

4 结论

本文针对基于聚类算法的分布式光伏发电功率预测, 研究了常用的聚类划分方法和光伏预测方法, 结合某区域的分布式光伏发电场站数据, 采用相似发电特性的原理, 使用 K 均值聚类算法实现集群划分。之后, 在集群划分的基础上, 提出集群累加法, 使用 LSTM 模型来进行光伏发电功率预测, 将数据划分成两部分, 分别当作训练集和测试集, 训练后的 MAE、MSE、RMSE 均接近 0, $R^2 > 0.9$, 全网的预测误差在 7%左右, 取得了较好的效果。

在使用 LSTM 进行光伏功率预测的研究中, LSTM 能完成预期的要求, 但也存在一些不足之处。LSTM 被设计用于处理长期依赖性, 但在某些情况下, 它仍然可能无法捕捉到非常长的时间跨度内的依赖关系。这会存在梯度爆炸和梯度消失两个问题。模型的训练和推理成本相对较高, 尤其是在大规模数据集上, 它需要大量的计算资源和时间, 这是后期需要解决的问题。

参考文献

- [1] 韩晓, 王涛, 韦晓广, 等. 考虑阵列间时空相关性的超短期光伏出力预测[J]. 电力系统保护与控制, 2024, 52(14): 82-94.
HAN Xiao, WANG Tao, WEI Xiaoguang, et al. Ultra short-term photovoltaic output forecasting considering spatiotemporal correlation between arrays[J]. Power System Protection and Control, 2024, 52(14): 82-94.
- [2] 刘星宇, 朱金荣, 盘瑶, 等. 基于 Fourier 拟合的光伏跟踪系统设计[J]. 南方能源建设, 2024, 11(1): 54-63.
LIU Xingyu, ZHU Jinrong, PAN Yao, et al. Design of photovoltaic tracking system based on Fourier fitting[J]. Southern Energy Construction, 2024, 11(1): 54-63.
- [3] 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.
- [4] 丁明, 王伟胜, 王秀丽, 等. 大规模光伏发电对电力系统影响综述[J]. 中国电机工程学报, 2014, 34(1): 1-14.
DING Ming, WANG Weisheng, WANG Xiuli, et al. A review on the effect of large-scale PV generation on power systems[J]. Proceedings of the CSEE, 2014, 34(1): 1-14.
- [5] 黄泽, 毕贵, 谢旭, 等. 基于 MBI-PBI-ResNet 的超短期光伏功率预测[J]. 电力系统保护与控制, 2024, 52(2): 165-176.
HUANG Ze, BI Guihong, XIE Xu, et al. Ultra-short-term PV power prediction based on MBI-PBI-ResNet[J]. Power System Protection and Control, 2024, 52(2): 165-176.
- [6] 惠慧, 李蕊, 朱逸楠, 等. 含高比例分布式光伏的配电网多目标概率规划方法[J]. 电测与仪表, 2023, 60(11): 2-10.
HUI Hui, LI Rui, ZHU Yidi, et al. Multi-objective probabilistic planning method for distribution network with high proportion of distributed photovoltaic[J]. Electrical Measurement & Instrumentation, 2023, 60(11): 2-10.
- [7] 董存, 许晓慧, 周昶, 等. 分布式电源并网及运行管理[M]. 北京: 中国水利水电出版社, 2018.
- [8] 武昭原, 刘婧宇, 周明, 等. 分散决策下分布式光伏储能系统外部性价值量化评估[J]. 电力系统自动化, 2024, 48(5): 38-47.
WU Zhaoyuan, LIU Jingyu, ZHOU Ming, et al. Quantitative evaluation of externality value for distributed photovoltaic energy storage system under decentralized decision-making[J]. Automation of Electric Power Systems, 2024, 48(5): 38-47.
- [9] 宋文乐, 张焯, 刘航旭, 等. 基于光伏组件老化特性解耦的渔光互补光伏短期出力预测方法[J]. 电力建设, 2024, 45(7): 25-33.
SONG Wenle, ZHANG Ye, LIU Hangxu, et al. Short-term output prediction method for complementary fishing and solar power decoupling the aging characteristics of photovoltaic modules[J]. Electric Power Construction, 2024, 45(7): 25-33.
- [10] TANG Z, LIU J, NI J, et al. Power prediction of wind farm considering the wake effect and its boundary layer compensation[J]. Protection and Control of Modern Power Systems, 2024, 9(6): 19-29.
- [11] 李翰章, 冯江涛, 王鹏程, 等. 基于 TDE-SO-AWM-GRU 的光伏发电功率预测模型[J]. 中国电力, 2024, 57(12): 41-49.
LI Hanzhang, FENG Jiangtao, WANG Pengcheng, et al. Photovoltaic power prediction model based on TDE-SO-AWM-GRU[J]. Electric Power, 2024, 57(12): 41-49.
- [12] 赵耀, 高少炜, 李东东, 等. 基于天气相似聚类与 QRNN 的短期光伏功率区间概率预测[J]. 电力系统自动化, 2023, 47(23): 152-161.
ZHAO Yao, GAO Shaowei, LI Dongdong, et al. Short-term interval probability prediction of photovoltaic power based on weather similarity clustering and quantile regression neural network[J]. Automation of Electric Power Systems, 2023, 47(23): 152-161.
- [13] 张海涛, 李文娟, 李雪峰, 等. 基于变分模态分解和时间注意力机制 TCN 网络的光伏发电功率预测[J]. 电测与仪表, 2024, 61(12): 156-163.
ZHANG Haitao, LI Wenjuan, LI Xuefeng, et al. Photovoltaic power forecasting based on TPA-TCN model and variational modal decomposition[J]. Electrical Measurement & Instrumentation, 2024, 61(12): 156-163.
- [14] 李民, 杨暑森, 李科锋, 等. 覆雪状态下光伏发电功率预测方法研究[J]. 高压电器, 2023, 59(9): 250-257.
LI Min, YANG Shusen, LI Kefeng, et al. Research on power prediction method of photovoltaic power generation under snow coating conditions[J]. High Voltage Apparatus, 2023, 59(9): 250-257.
- [15] 彭曙蓉, 陈慧霞, 孙万通, 等. 基于改进 LSTM 的光伏发电功率预测方法研究[J]. 太阳能学报, 2024, 45(11): 296-302.
PENG Shurong, CHEN Huixia, SUN Wantong, et al. Research on photovoltaic power prediction method based on improved LSTM[J]. Acta Energetica Solaris Sinica, 2024, 45(11): 296-302.
- [16] 张静, 熊国江. 考虑季节特性与数据窗口的短期光伏功率预测组合模型[J]. 电力工程技术, 2025, 44(1): 183-192.
ZHANG Jing, XIONG Guojiang. Short-term photovoltaic power prediction combination model considering seasonal characteristic and data window[J]. Electric Power Engineering Technology, 2025, 44(1): 183-192.
- [17] 魏伟, 余鹤, 叶利, 等. 基于 FCM-SENet-TCN 的低压台区光伏超短期功率预测方法[J/OL]. 中国电力: 1-10 [2024-12-24]. <http://kns.cnki.net/kcms/detail/11.3265.tm.20241106.1715.004.html>.
WEI Wei, YU He, YE Li, et al. Low voltage substation photovoltaic ultra short term power prediction method based on FCM-SENet TCN[J/OL]. Electric Power: 1-10 [2024-12-24]. <http://kns.cnki.net/kcms/detail/11.3265.tm.20241106.1715.004.html>.
- [18] 陈庆斌, 杨耿煌, 耿丽清, 等. 基于相似日选取和数据重构的短期光伏功率组合预测方法[J]. 中国电力, 2024, 57(12): 71-81.
CHEN Qingbin, YANG Genghuang, GENG Liqing, et al.

- Short term photovoltaic power combination prediction method based on similar day selection and data reconstruction[J]. *Electric Power*, 2024, 57(12): 71-81.
- [19] 葛亚明, 戴上, 梁文腾, 等. 基于气象融合与深度学习的分布式光伏出力区间预测[J]. *电网与清洁能源*, 2024, 40(8): 112-120.
- GE Yaming, DAI Shang, LIANG Wenteng, et al. Prediction of distributed photovoltaic output interval based on meteorological fusion and deep learning[J]. *Power System and Clean Energy*, 2024, 40(8): 112-120.
- [20] 时珉, 尹瑞, 姜卫同, 等. 分布式光伏灵活并网集群调控技术综述[J]. *电测与仪表*, 2021, 58(12): 1-9.
- SHI Min, YIN Rui, JIANG Weitong, et al. Overview of flexible grid-connected cluster control technology for distributed photovoltaic[J]. *Electrical Measurement & Instrumentation*, 2021, 58(12): 1-9.
- [21] 李楠, 刘佳佳, 赖心怡, 等. 基于时间序列神经分层插值模型的光伏功率超短期多步预测[J]. *智慧电力*, 2024, 52(4): 69-77.
- LI Nan, LIU Jiajia, LAI Xinyi, et al. Ultra-short-term multi-step forecasting of photovoltaic power based on time series neural hierarchical interpolation model[J]. *Smart Power*, 2024, 52(4): 69-77.
- [22] 雷柯松, 吐松江·卡日, 伊力哈木·亚尔买买提, 等. 基于 WGAN-GP 和 CNN-LSTM-Attention 的短期光伏功率预测[J]. *电力系统保护与控制*, 2023, 51(9): 108-118.
- LEI Kesong, TUSONGJIANG·Kari, YILIHAMU·Yaermaimaiti, et al. Prediction of short-term photovoltaic power based on WGAN-GP and CNN-LSTM-Attention[J]. *Power System Protection and Control*, 2023, 51(9): 108-118.
- [23] 董志强, 郑凌蔚, 苏然, 等. 一种基于 IGWO-SNN 的光伏出力短期预测方法[J]. *电力系统保护与控制*, 2023, 51(1): 131-138.
- DONG Zhiqiang, ZHENG Lingwei, SU Ran, et al. An IGWO-SNN-based method for short-term forecast of photovoltaic output[J]. *Power System Protection and Control*, 2023, 51(1): 131-138.
- [24] 尉同正, 杜红卫, 夏栋, 等. 基于改进 K-means 算法的分布式发电集群划分方法[J]. *华北电力大学学报(自然科学版)*, 2024, 51(6): 49-57.
- WEI Tongzheng, DU Hongwei, XIA Dong, et al. Distributed generation cluster partition method based on improved K-means algorithm[J]. *Journal of North China Electric Power University (Natural Science Edition)*, 2024, 51(6): 49-57.
- [25] 徐晓, 丁世飞, 丁玲. 密度峰值聚类算法研究进展[J]. *软件学报*, 2022, 33(5): 1800-1816.
- XU Xiao, DING Shifei, DING Ling. Research progress on density peak clustering algorithm[J]. *Journal of Software*, 2022, 33(5): 1800-1816.
- [26] 盛万兴, 季宇, 吴鸣, 等. 基于改进模糊 C 均值聚类算法的区域集中式光伏发电系统动态分群建模[J]. *电网技术*, 2017, 41(10): 3284-3291.
- SHENG Wanxing, JI Yu, WU Ming, et al. Dynamic clustering modeling of regional centralized photovoltaic power generation systems based on improved fuzzy C-means clustering algorithm[J]. *Power System Technology*, 2017, 41(10): 3284-3291.
- [27] WU N, HUANG Y, FAN S, et al. Voltage control strategy of high-penetration photovoltaic distribution network based on cluster division[C] // 2022 China Automation Congress (CAC), 2022, Xiamen, China: 5701-5706.
- [28] 任蜜蜂, 王家辉, 叶泽甫, 等. 一种适用于单/多光伏电站的迁移超短期光伏预测建模框架[J]. *太阳能学报*, 2024, 45(6): 359-367.
- REN Mifeng, WANG Jiahui, YE Zefu, et al. Transfer ultra-short term photovoltaic prediction modeling framework for single/multiple photovoltaic power stations[J]. *Acta Energetica Solaris Sinica*, 2024, 45(6): 359-367.

收稿日期: 2024-08-13; 修回日期: 2025-01-11

作者简介:

文贤旭(1972—), 男, 硕士研究生, 正高级工程师, 研究方向为储能及新能源; E-mail: 13985410224@139.com

何明君(1997—), 女, 硕士研究生, 研究方向为电力系统运行分析及电能质量分析治理; E-mail: hmj.97@foxmail.com

张俊玮(1987—), 女, 硕士研究生, 高级工程师, 研究方向为电能计量。E-mail: 282972837@qq.com

(编辑 石晋美)