

# 基于 TOPSIS-GRNN 的机理-数据混合驱动 光伏电站功率预测

柳 想<sup>1</sup>, 陈春玲<sup>1</sup>, 王 慧<sup>1</sup>, 陈浩楠<sup>2</sup>

(1.沈阳农业大学 信息与电气工程学院, 辽宁 沈阳 110866; 2.国网辽宁电力有限公司大连供电公司, 辽宁 大连 116011)

**摘 要:** 针对传统光伏功率预测精度比较低的问题,文章提出了基于 TOPSIS-GRNN 的机理-数据混合驱动光伏电站功率预测模型。首先,对多个气象指标和光伏电站的输出功率进行了相关性分析,并选取了相关度较高的气象数据作为模型的输入因子,利用 TOPSIS 算法选择出最优相似日;然后,将光伏电站输出功率理论值和气象数据建立 GRNN 预测模型;最后,结合 DKASC 网站上的历史气象数据和功率数据,对该模型进行了仿真试验并验证。试验结果得出功率预测精度 RMSE 平均值为 0.826 9 kW,MAPE 平均值为 3.45%,MAE 平均值为 0.019 5 kW。该预测方法的预测精度明显高于单一预测模型,具有一定的理论和实用价值。

**关键词:** 光伏功率预测; TOPSIS 法; 最佳相似日; GRNN

**中图分类号:** TK511 **文献标志码:** A **文章编号:** 1671-5292(2024)04-0471-08

## 0 引言

国家能源局数据显示,截至 2021 年,全国光伏发电累计装机量约为 3.1 亿 kW,同比增长 20.9%。光伏发电技术已经比较成熟,且得到了广泛的应用<sup>[1]</sup>。但是与传统的燃煤电站相比,光伏发电出力仍然存在着很大的随机性和波动性,影响系统的稳定运行,给电网的规划和调度带来了很大困难。解决这个问题的方法之一是预测太阳能光伏发电系统的输出功率,因此光伏功率预测在理论和实际上具有重要的意义。

目前研究人员对于大型并网光伏电站发电功率预测多采用复杂物理模型方法<sup>[2]</sup>。物理模型法结合光伏组件本身特性和损耗建立数学模型,但是光伏组件的具体参数和经验参数很难把控,预测精度相对较低;而中小型光伏电站短期光伏功率预测总是采用智能统计方法。杨茂研究了气象因素与光伏电站功率的差异性和关联性,选择出合适的光伏出力匹配方法<sup>[3]</sup>。Martin J M 采用数值天气预报(Numerical Weather Prediction,NWP)数据对光伏电站进行日功率的预测,以最佳方法实现了从一个混合物理和机器学习的辐照度到光伏电站功率的转换,但需要保证预先假设数据

是正确的<sup>[4]</sup>。彭周宁采用灰色关联分析方法筛选出最佳相似日,构建灰色关联分析-广义回归神经网络预测模型,但是在评价指标较多时,进行归一化会使某些指标变得很小,降低了这些指标的作用<sup>[5]</sup>。Hussein S 介绍了多种基于机器学习的时序预测方法,并与传统的预测方法进行对比,探讨了不同预测时间区间对各算法结果的影响<sup>[6]</sup>。目前研究人员多使用历史数据,采用支持向量机、人工神经网络计算法、灰度预测等建模方法<sup>[7]</sup>,但这些方法对历史数据精确度要求较高,具有统计泛化风险<sup>[8]</sup>。

本文提出一种历史数据和机理拟合模型类预测方法,选取高度相关的数据进行预测,通过光伏电站的地理位置信息和数值天气预报数据进行数据的采集与筛选。采用最小二乘法对光伏电站功率机理值进行计算,对各个指标进行相关性分析。在此基础上,通过 TOPSIS 算法确定待预测日的 9 个最佳相似日,这些相似日与待预测日的气象信息匹配度最高。再将最佳相似日的光伏电站输出功率理论值与气象数据作为广义回归神经网络模型的输入参数,预测出各个时间点的输出功率。

收稿日期: 2023-01-18。

基金项目: 辽宁省科学研究经费项目(LJKZ0681)。

通信作者: 陈春玲(1971-),女,博士,教授,主要从事农业电气化与信息化方面的研究工作。E-mail:chenchunling@syau.edu.cn

### 1 光伏电站功率的影响因素

本文首先分析了气象条件对光伏电站出力的影响。气象因子一般包括风速、环境温度、相对湿度、太阳辐射强度等。这些气象因子与光伏电站功率之间存在着一定的相关性<sup>[9]</sup>。本文利用澳大利亚 DKASC 太阳能中心网站上澳洲光伏发电站的 NWP 资料,采用皮尔逊相关系数  $R$  对其与光伏发电的关系进行研究<sup>[10]</sup>。 $R$  计算式为

$$R = \frac{N \sum XY - \sum X \sum Y}{\sqrt{N \sum X^2 - (\sum X)^2} \sqrt{N \sum Y^2 - (\sum Y)^2}} \quad (1)$$

其中:

$R=$	0.8~1.0	极强相关
	0.6~0.8	强相关
	0.4~0.6	中等程度相关
	0.2~0.4	弱相关
	0~0.2	极弱相关或无相关

式中: $N$  为 NWP 样本数量; $X, Y$  分别为气象因子和光伏发电功率。

本文对 DKASC 网站上 1 a 内的 NWP 数据和光伏发电功率进行相关性分析,得出了光伏电站功率与各气象因子之间的组合关系。表 1 为某一日的各气象因子与光伏电站功率信息。

表 1 某一日气象因子与光伏电站功率数据

Table 1 Data sheet on meteorological factors and PV plant power for a given day

时刻	全球水平 辐射/W·m <sup>-2</sup>	扩散水平 辐射/W·m <sup>-2</sup>	漫反射 辐射/W·m <sup>-2</sup>	环境温度 ℃	相对湿度 %	风速 m/s	风向 (°)	光伏电站 功率/kW
0:00	2.67	1.10	1.85	17.18	87.10	2.42	186.94	0.00
1:00	2.76	1.17	1.67	16.48	93.84	3.35	191.10	0.00
2:00	2.34	0.79	1.80	16.41	98.42	3.02	204.93	0.00
3:00	2.49	1.06	1.39	16.31	99.34	3.06	202.85	0.00
4:00	2.26	0.74	1.20	16.45	99.14	2.26	193.60	0.00
5:00	2.33	0.77	1.24	16.44	99.88	2.55	200.23	0.00
6:00	3.38	1.74	2.27	16.55	99.73	2.57	207.81	0.00
7:00	34.07	32.51	29.37	16.62	100.40	3.01	208.17	0.23
8:00	65.97	63.85	69.11	17.43	93.72	1.70	212.28	0.56
9:00	181.51	176.20	155.18	17.95	86.86	3.32	210.19	1.73
10:00	304.81	289.76	271.12	19.19	78.78	3.92	195.64	2.98
11:00	724.78	610.57	500.34	20.94	71.37	4.98	188.25	6.04
12:00	956.85	607.86	621.82	22.56	66.69	5.46	199.01	7.96
13:00	896.39	512.46	493.02	24.24	62.27	4.07	196.25	7.15
14:00	525.31	453.13	456.09	24.77	58.85	4.34	185.06	5.06
15:00	1057.47	237.26	246.11	26.02	53.41	5.74	184.21	8.21
16:00	724.39	129.15	143.88	26.46	51.15	5.15	180.59	6.40
17:00	485.09	86.00	80.64	26.76	46.25	6.67	181.91	4.30
18:00	239.20	103.13	113.19	24.80	56.11	5.74	172.52	1.87
19:00	47.31	30.91	32.94	22.82	63.03	4.96	162.38	0.23
20:00	2.90	1.39	2.15	21.02	71.00	4.51	168.25	0.00
21:00	2.00	0.55	1.54	20.70	74.12	4.48	161.15	0.00
22:00	2.39	0.87	1.75	20.03	77.98	6.15	163.66	0.00
23:00	3.88	2.31	2.96	19.28	85.07	2.91	160.62	0.00

#### 1.1 全球水平辐射

全球水平辐射度即为直射辐照度,代表太阳辐射直接到达光伏板表面上单位面积、单位时间内的辐射能量。通过表 1 的数据变化可知,光伏电站的输出功率与全球水平辐射变化趋势一致,两者的相关性很高。这主要因为光伏系统产生电

能几乎是和照射到光伏面板上的太阳辐射量成正比的。

#### 1.2 扩散水平辐射

扩散水平辐射为太阳辐射经过大气散射或云的反射以短波形式向下到达地面的辐射。全球水平辐射和扩散水平辐射对光伏板正面发电量影响

很大。通过表 1 数据的对比变化可知,光伏电站功率和扩散水平辐射之间存在着很高的相关关系,并且两者的整体趋势都比较接近。

### 1.3 漫反射辐射

光伏板背面发电功率主要受漫反射辐照强度影响。全球水平辐射、扩散水平辐射和漫反射辐射共同影响着太阳总辐射,这是影响光伏发电量的重要因素。通过表 1 数据的对比变化可知,光伏电站的功率和漫反射辐射之间也存在着很高的相关关系。光伏面板受到太阳直接辐射后散射的辐射对光伏面板接收到的能量仍有较大影响。

### 1.4 环境温度

由表 1 可知,随着环境温度的升高,光伏输出功率也升高。但温度达到一定程度后,输出功率反而下降。这是因为光伏板有良好的吸热性能,因此在使用过程中,当温度升高到一定程度时,降低了太阳能光伏板的效率。这表明环境温度因素对光伏电站功率的输出有较强影响。

### 1.5 相对湿度

由表 1 可知,随着相对湿度的下降,光电器件的输出功率呈现增加的趋势;随着相对湿度的增加,输出功率下降。两者呈现负相关趋势。由于空气的相对湿度升高,太阳能电池板受到的阳光照射减弱,因此降低了太阳能发电。

### 1.6 风速

由表 1 可以看出,光伏输出功率与风速具有一定相关性,8:00-12:00 光伏输出功率与风速增长趋势类似。这是因为风速对太阳能电池板的温度和粉尘的累积有一定的影响。风力会加速太阳能电池板的热量传输,从而降低面板的温度。风也影响着光伏面板上的灰尘覆盖层中沉积结构,从而影响太阳辐射接收量。

### 1.7 风向

由表 1 可以看出,光伏电站功率与风向的数据并没有明显的直接联系。

### 1.8 相关性分析

对数据进行相关性分析,通过式(1)进行运算得出光伏输出功率与气象因素的  $R$  值,如图 1 所示。光伏电站输出功率和全球水平辐射、扩散水平辐射、漫反射辐射、环境温度、相对湿度、风速及风向的  $R$  值分别为 0.996 6,0.838 3,0.994 3,0.739 4,-0.708 9,0.559 0,0.053 9。可见,光伏电站功率与




图 1 光伏电站功率与气象因子相关性热力图

Fig.1 Thermal diagram of the correlation between PV plant power and meteorological factors

全球水平辐射、扩散水平辐射和漫反射辐射的相关性为极强相关;与相对湿度和环境温度的相关性为强相关;与风速的相关性为中等程度相关;与风向的相关性为极弱相关。本文选取了中度及以上的气象因子作为预测模型的气象输入参数。

## 2 基于 TOPSIS 的最佳相似日选取方法

前人研究了短期电力功率预测后发现,如果预测日和历史日在天气状况因素比较接近时,其功率在数值上也会非常相近<sup>[1]</sup>。本文通过寻找预测日的最佳相似日进行预测,从而得到预测功率值。

TOPSIS 法作为一种针对多指标分析的方法,通过计算各数据样本与正、负理想解的距离,来确定历史日与理想解的贴切度。

正理想解是一个不存在于历史数据集  $X$  中的最优解,其各属性值为决策矩阵中的最优值,分别表示最优状况。而负理想解是最差的一个,在决策矩阵中,每一个属性都是最差的<sup>[2]</sup>。计算各个历史数据与两个理想解的距离,与正理想解越接近或与负理想解越疏远,说明该历史数据样本的综合特性越好。本文选择数据样本到正理想解和负理想解距离与待测日最相似的作为最佳相似日。

为了更详细地描述每天的气象特征,本文选取了相关性中度及以上的气象因子的最大值和最小值作为每个自然日的气象指标。

设有  $m$  个决策对象, $n$  个决策指标,其初始指标  $X=(x_{ij})_{m \times n}$  矩阵为

$$X = \begin{pmatrix} x_{11} & x_{12} & x_{13} & \cdots & x_{1n} \\ x_{21} & x_{22} & x_{23} & \cdots & x_{2n} \\ x_{31} & x_{32} & x_{33} & \cdots & x_{3n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & x_{m3} & \cdots & x_{mn} \end{pmatrix} \quad (2)$$

TOPSIS 法构造出的决策矩阵的每个指标都是递增或递减的函数,即对于 1 型指标,指标数值越大越好,例如全球水平辐射最大值。而对于 2 型指标,指标数值越小越好,例如相对湿度最大值。预处理方法<sup>[13]</sup>为

1 型指标:

$$y_{ij} = [x_{ij} - \min(x_{ij})] / [\max(x_{ij}) - \min(x_{ij})] \quad (3)$$

2 型指标:

$$y_{ij} = [\max(x_{ij}) - x_{ij}] / [\max(x_{ij}) - \min(x_{ij})] \quad (4)$$

式中: $y_{ij}$  为第  $i$  个选择方案的第  $j$  个正向化属性值; $\max(x_{ij}), \min(x_{ij})$  分别为初始指标矩阵  $X = (x_{ij})_{m \times n}$  中第  $j$  列中各元素最大、最小值,即  $j$  指标下各方案集的最大、最小数据。

针对多个指标问题,其评价标准不相同,所代表的物理意义也不一样,难以直接进行对比。因此,在进行全面评估前,应先将各项指标进行规范化。

假设有  $n$  个要评价的对象, $m$  个评价指标,已达到正向化标准,构成的标准化矩阵  $Z$  如下:

$$z_{ij} = y_{ij} / \sqrt{\sum_{i=1}^m y_{ij}^2}, i=1, 2, \dots, m; j=1, 2, \dots, n \quad (5)$$

式中: $z_{ij}$  为第  $i$  个选择方案的第  $j$  个标准化属性值。

令  $z^+ = \{z_1^+, \dots, z_j^+\}$  代表正理想解,  $z^- = \{z_1^-, \dots, z_j^-\}$  代表负理想解,则数据样本到正理想解和负理想解的距离分别为

$$D_i^+ = \sqrt{\sum_{j=1}^n (z_{ij} - z_j^+)^2}, D_i^- = \sqrt{\sum_{j=1}^n (z_{ij} - z_j^-)^2} \quad (6)$$

数据样本与待预测日距离绝对值越相近表明越接近最佳相似日。

筛选出与待预测日距离绝对值最相似的历史日数据。最佳相似日天数的选取一定程度上会影响模型的精确程度,本文选取 9 d 最佳相似日数据进行预测,效果更佳。

### 3 光伏电站功率预测模型

#### 3.1 光伏功率预测机理模型

光伏功率预测机理模型通过采集与筛选地理经、纬度、光伏面板角、倾斜角、直射辐照度、散射辐照度、反射辐照度等数据<sup>[14]</sup>,计算出光伏面板接收到的总辐照度,推导了目标函数,采用最小二乘法对目标函数进行优化求解。再通过辐照度到功率的映射模型得到光伏面板的功率输出,计算步骤如图 2 所示。

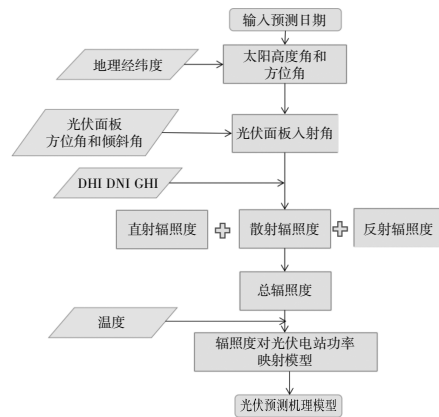


图 2 光伏功率预测机理模型流程图

Fig.2 Flow chart of PV power prediction mechanism model

一般情况下,光伏电站输出功率  $P_{pv}$  为

$$P_{pv} = \eta A_{pv} I \quad (7)$$

式中: $\eta$  为光伏阵列的转换效率,%;  $A_{pv}$  为光伏阵列面积,  $m^2$ ;  $I$  为光伏板接收到的总辐照度,  $W/m^2$ 。

$\eta$  的参数方程可表示为<sup>[15]</sup>

$$\eta(I, T) = (a_1 + a_2 I + a_3 \ln I) \cdot [1 - 0.005(T - 25)] \quad (8)$$

式中: $T$  为光伏面板运行温度,  $^{\circ}C$ ;  $a_1, a_2, a_3$  为待定系数。

将光伏面板面积系数和光伏系统效率方程中的  $a_1, a_2, a_3$  参数进行合并,形成整合后的功率映射方程:

$$P_{pv} = (a_1' + a_2' I + a_3' \ln I) \cdot [1 - 0.005(T - 25)] I \quad (9)$$

已知光伏面板辐照度  $I$  和光伏面板运行温度,可采用最小二乘法对待定系数  $a_1', a_2', a_3'$  进行估计。

通过光伏面板运行温度消去相关的温度部分和辐照度项,得到的输出功率  $P_{pv/m}$  可表示为

$$P_{pv/m} = \frac{P_{pv}}{[1 - 0.005(T - 25)] I} = a_1' + a_2' I + a_3' \ln I = [a_1' \ a_2' \ a_3'] [1 \ I \ \ln I] \quad (10)$$

为了解决传统功率预测曲线模型只考虑单一

因素对光伏系统的影响而造成的模型精度不高的问题,本文利用偏最小二乘法对 NWP 中影响输出功率最大的两个变量(温度和辐照度)进行了优化,由传统单变量功率曲线建模变为多变量功率曲线建模。对参数 $[a_1, a_2, a_3]$ 进行估计,最终获得光伏功率预测机理模型。

使用已经选取的 9 d 最佳相似日的太阳辐射强度与光伏电站输出功率数据进行优化计算。求解出光伏功率机理公式为

$$P_p = (0.0566 + 1.0385I + 0.0057 \ln I) \cdot [1 - 0.005(T - 25)]^I \quad (11)$$

根据式(11)模型得到的预测结果和实际值对比如图 3 所示。




图 3 光伏功率预测机理模型

Fig.3 Photovoltaic power prediction mechanism model

由图 3 可以看出,根据求解出的光伏功率机理公式绘制的曲线与最佳相似日的实测采样点较为吻合,光伏功率预测机理模型基本满足了传统光伏技术对光伏功率预测的要求,但是新型电力系统对光伏预测精度要求更高,采用机理法预测已经无法满足要求。

### 3.2 基于 TOPSIS-GRNN 的机理-数据混合驱动光伏电站功率预测模型

广义回归神经网络是一种类似于径向基(RBF)网络的非线性回归前馈神经网络。GRNN 以数理统计为依据,通过训练样本建立输入与输出的隐含关系。GRNN 方法收敛速度快,计算量小,能够很好地解决小样本的问题,并且在学习速度和泛化方面比普通 RBF 和 BP 神经网络都要好,且不会出现局部极小的问题,在系统辨识、控制、预测等领域中被广泛应用<sup>[16]</sup>。

本文以 DKASC 网站上的历史发电功率、气象资料和经优化后的理论发电功率数据为基础数

据集。因为其量纲不一致,所以必须对数据集进行标准化的处理<sup>[17]</sup>。输入和输出变量都是以每天 0:00-23:00、时间间隔为 1 h 进行采样。采用待测日的 9 个最佳相似日的每小时的输出功率的理论值(训练样本的 24 个功率数据,  $P$ )、日全球水平辐射最大值、日扩散水平辐射最大值、日最高环境温度、日风速最大值、日相对湿度最大值、日漫反射辐射最大值、日全球水平辐射最小值、日扩散水平辐射最小值、日最低环境温度、日风速最小值、日相对湿度最小值、日漫反射辐射最小值(训练集的 12 个气象参数数据,  $C$ )作为训练样本输入,采用待测日的最佳相似日的每小时输出功率值(训练样本的 24 个功率数据,  $P'$ )作为训练样本输出。采用 GRNN 进行训练,得到预测模型。预测模型流程如图 4 所示。

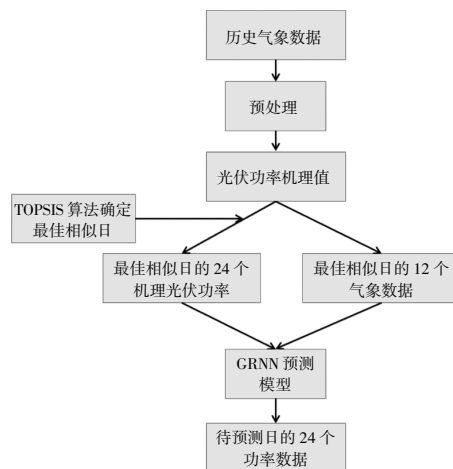


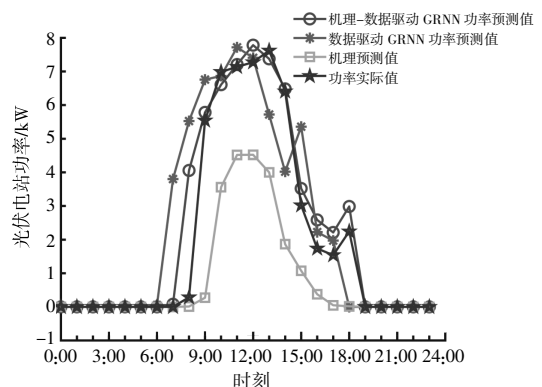
图 4 预测模型流程图

Fig.4 Predictive model flow chart

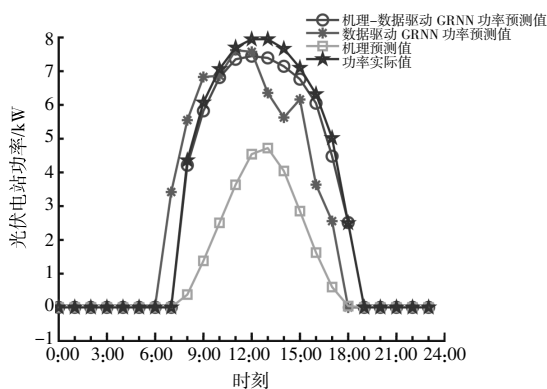
## 4 算例分析

采用 9 d 最佳相似日的历史数据,利用 TOPSIS-GRNN 模型对太阳能发电功率进行预测。因为电力系统中电力预测存在随机性问题,仅用一日的电力预测并不能充分地反映出该方法的有效性,所以本研究对 3 月 29-31 日连续 3 d 中 0:00-24:00 时段的输出功率以 1 h 作为间隔进行电力预测。


为了验证本文所建立模型的有效性,将本文的 TOPSIS-GRNN 的机理-数据混合驱动预测模型与单纯数据驱动 GRNN 预测模型、机理预测模型的 3 个待预测日的预测结果作对比,结果如图 5 所示。



(a)3月29日光伏电站功率预测对比



(b)3月30日光伏电站功率预测对比



(c)3月31日光伏电站功率预测对比

图5 3个待预测日光伏电站功率预测对比

Fig.5 Comparison of power forecasts for PV plants on three test days

本研究选择均方根误差(RMSE)、平均绝对百分比误差(MAPE)和平均绝对误差(MAE)作为评价各预测模型准确性的标准,其表达式分别为

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_p - P_r)^2} \quad (12)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{P_p - P_r}{\bar{P}_r} \right| \times 100\% \quad (13)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_p - P_r| \quad (14)$$

式中: $P_p$ 为在*i*时刻的光伏电站预测输出功率; $P_r$ 为在*i*时刻的光伏电站实际输出功率; $\bar{P}_r$ 为在*i*时刻的光伏电站实际输出功率的平均值; $N$ 为光伏输出功率的采样点个数。

光伏电站功率预测误差分析结果见表2。

表2 光伏电站功率预测误差分析对比

Table 2 Comparison table of power prediction error analysis of photovoltaic power station

指标	日期	机理-数据	数据驱动	机理值
		驱动 GRNN	GRNN	预测
RMSE/kW	3月29日	2.032 8	2.319 4	1.263 3
	3月30日	0.256 4	1.306 3	2.707 9
	3月31日	0.191 5	0.986 4	2.608 0
	平均值	0.826 9	1.537 4	2.193 1
MAPE/%	3月29日	8.470 0	92.757 2	49.203 4
	3月30日	1.068 3	26.226 1	62.242 3
	3月31日	0.797 9	18.905 4	60.703 4
	平均值	3.445 4	45.962 9	57.383 0
MAE/kW	3月29日	0.047 1	0.054 1	0.028 7
	3月30日	0.006 5	0.031 7	0.075 3
	3月31日	0.004 8	0.022 5	0.072 4
	平均值	0.019 5	0.036 1	0.058 8

由表2可知,基于TOPSIS-GRNN的机理-数据混合驱动光伏电站功率预测模型实现了对历史数据和理论值的综合学习,利用最小二乘法建立光伏预测机理模型与使用TOPSIS法选择最佳相似日的历史数据进行拟合优化,与对照模型相比,其预测准确率较高。RMSE平均值分别降低了46.22%和62.15%,MAPE平均值分别降低了42.52%和53.94%,MAE平均值分别降低了45.98%和66.84%。这说明机理数据拟合的模型比单一模型预测效果更好。

由图5与表2可知,单纯机理模型的预测性能各项指标均相较于其他方法最差;未加入机理值的预测模型拟合效果不理想;融合机理和历史数据的预测模型各项指标均优于单一模型,得到的预测曲线与实际曲线的相似度较高,虽然在某些时间点仍有偏差,但是依然可以有效的反映光伏电站输出功率的变化趋势。

### 5 结论

本文选取高相关性的气象影响因素对光伏电

站功率的机理值进行计算,提出了以 TOPSIS 算法为基础选取最佳相似日,解决了多指标权重的归一化的分配问题。选高相关性的气象因素与光伏电站功率的机理值作为建立预测模型的输入因子,对广义回归神经网络算法进行优化建模,实现了对待测日各时间点功率的预测。

通过该模型进行仿真试验并验证,得到功率预测精度 RMSE 平均值为 0.826 9 kW,MAPE 平均值为 3.45%,MAE 平均值为 0.019 5 kW。本文所提出的 TOPSIS-GRNN 的机理-数据混合驱动预测模型既考虑了光伏输出功率理论值,又兼顾了气象统计资料反映的特征信息,泛化能力强,进一步提高光伏电站功率预测稳定性及准确率,解决了天气情况随机性导致预测精度下降的问题,具有较好的预测性能,可为光伏并网畅通、发电部门合理制定发电方案、电网及时调度提供重要依据。

#### 参考文献:

- [1] 方鹏,高亚栋,潘国兵,等.基于 LSTM 神经网络的中长期光伏电站发电量预测方法研究 [J]. 可再生能源, 2022,40(1):48-54.
- [2] 龚莺飞,鲁宗相,乔颖,等.光伏功率预测技术[J].电力系统自动化,2016,40(4):140-151.
- [3] 杨茂,王凯旋.基于 MRMR 的光伏出力匹配方法研究及预测应用[J].可再生能源,2021,39(10):1314-1319.
- [4] Martin J M.Benefits of physical and machine learning hybridization for photovoltaic power forecasting [J]. Renewable and Sustainable Energy Reviews,2022,168:112772.
- [5] 彭周宁,林培杰,赖云锋,等.基于混合灰色关联分析-广义回归神经网络的光伏电站短期功率预测[J].电气技术,2019,20(10):11-18.
- [6] Hussein S,Shima H,Robert S B.Time series forecasting of solar power generation for large-scale photovoltaic plants[J].Renewable Energy,2020,150:797-807.
- [7] Lin G Q,Li L L,Tseng M L,et al.An improved moth-flame optimization algorithm for support vector machine prediction of photovoltaic power generation[J].Journal of Cleaner Production,2020,253:119966.
- [8] 尚宇炜,郭剑波,吴文传,等.数据-知识融合的机器学习(2):泛化风险[J].中国电机工程学报,2019,39(16):4641-4649,4967.
- [9] 胡雪凯,时磊,胡文平,等.光伏电站功率预测影响因素分析及准确率提升方法研究[J].河北电力技术,2020,39(2):1-6,14.
- [10] Zhou Y,Zhou N,Gong L,et al.Prediction of photovoltaic power output based on similar day analysis, genetic algorithm and extreme learning machine [J].Energy, 2020,204:117894.
- [11] 耿子惠,崔力民,舒勤,等.基于 TOPSIS 算法的电力通信网关键节点识别[J].电力系统保护与控制,2018,46(1):78-86.
- [12] 程蒙,赵双芝,吴立杰,等.基于 AHP-TOPSIS 的城市光伏发电项目综合评价[J].中国电力,2016,49(10):171-175.
- [13] 董福贵,时磊,吴南南.基于 DEA-TOPSIS-时间序列的风电绩效动态评价 [J]. 电力科学与工程,2018,34(11):20-29.
- [14] 王彪,吕洋,陈中,等.考虑信息时移的分布式光伏机理-数据混合驱动短期功率预测[J].电力系统自动化,2022,46(11):67-74.
- [15] Lorenz E,Heinemann D.Prediction of solar irradiance and photovoltaic power [J].Comprehensive Renewable Energy,2012(1):239-292.
- [16] 李啸骢,李春涛,从兰美,等.基于动态权值相似日选取算法的短期负荷预测 [J]. 电力系统保护与控制,2017,45(6):1-8.
- [17] 司志远,杨明,于一潇,等.基于卫星云图特征区域定位的超短期光伏功率预测方法 [J]. 高电压技术,2021,47(4):1214-1223.

## Power prediction of mechanism–data hybrid drive photovoltaic power plant based on TOPSIS–GRNN

Liu Xiang<sup>1</sup>, Chen Chunling<sup>1</sup>, Wang Hui<sup>1</sup>, Chen Haonan<sup>2</sup>

(1.College of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110866, China;  
2.State Grid Dalian Electric Power Supply Company, Dalian 116011, China)

**Abstract:** The article addresses the problem of relatively low accuracy of traditional PV power prediction and proposes a hybrid TOPSIS–GRNN based mechanism–data driven PV plant power prediction model. Firstly, the correlation analysis of several meteorological indicators and the output power of PV power plant is carried out, and the meteorological data with high correlation is selected as the input factor of the model. The TOPSIS algorithm was used to select the optimal similar days, and then the theoretical values of their PV plant output power and meteorological data were used to build the GRNN prediction model. Finally, the model was simulated and validated by combining the historical meteorological data and power data on the DKASC website. The final test results yielded an average power prediction accuracy of 0.826 9 kW for RMSE, 3.45% for MAPE and 0.019 5 kW for MAE. The prediction accuracy of this forecasting method is significantly higher than that of a single forecasting model and has some theoretical and practical value.

**Keywords:** photovoltaic power prediction; TOPSIS; best similar day; GRNN