

DOI: 10. 20040/j. cnki. 1000-7709. 2023. 20230949

# 基于 BRICH 聚类 and Copula-Monte Carlo 模拟的光伏发电功率概率预测

黄牧涛<sup>1a</sup>, 高素花<sup>1b</sup>, 汪 旻<sup>2</sup>, 曾令康<sup>2</sup>, 魏聪颖<sup>2</sup>, 陈兴邦<sup>1a</sup>

(1. 华中科技大学 a. 电气与工程学院; b. 土木与水利工程学院, 湖北 武汉 430074;  
2. 国家电网有限公司华中分部调度控制中心, 湖北 武汉 430077)

**摘要:** 光伏发电功率受气象的混沌特性影响, 其随机性、波动性、间歇性对电力系统的运行影响较严重。针对原始光伏发电数据维度大及发电功率易受天气状况影响的问题, 提出了基于主成分分析和 BRICH 聚类的数据处理方法, 从而降低模型输入变量维度, 易于统计建模; 其次, 搭建了基于 Copula-Monte Carlo 的光伏发电功率概率预测模型, 计算光伏出力在给定未来点预测值的情况下实际出力的概率区间预测, 并基于区间覆盖率、预测区间平均宽度对模型进行评价。最后, 以实际光伏电站夏季数据为例进行验证分析。结果表明, Copula-Monte Carlo 方法可直观展示光伏发电功率的波动区间和期望值, 且优于其他功率预测模型。

**关键词:** 概率预测; 光伏发电功率; BRICH 聚类; Copula 函数; Monte Carlo 模拟; 天气分型

**中图分类号:** TM73

**文献标志码:** A

**文章编号:** 1000-7709(2023)12-0220-05

## 1 引言

光伏功率的预测精度依赖于天气模态和气候条件等因素, 确定性的功率点预测结果直接明确, 但包含的可用信息有限, 因此实用性相对不高<sup>[1]</sup>。相比之下, 光伏概率预测将光伏出力视作随机变量, 给出预测时刻所有可能的光伏出力的期望值及概率分布信息, 从而能更好地描述光伏发电功率波动范围、不确定性、未来变化趋势<sup>[2]</sup>, 可为电网调度、电能分析和风险评估提供科学决策信息。概率预测方法主要分为参数法和非参数法, 参数化方法的预测结果依赖于假定分布的参数, 简化了模型、降低了运算成本, 但也导致拟合能力不足, 难以准确描述预测对象在待预测时刻的高维统计特征<sup>[3-4]</sup>。非参数法有效避免了参数法中对于预测分布刻画不合理的问题, 但仍可能会出现“分位点交叉”等降低预测质量的情况<sup>[5]</sup>。而 Copula 函数能灵活、准确地刻画高维随机变量间的概率分布, 且具备易于构造联合分布模型的独特优势, 这些良好的性质将有利于解决现有方法存在的缺点<sup>[6]</sup>。目前基于非参数法的光伏概率预

测研究十分有限。为提高光伏功率概率预测的精准性, 仍需找到更有效的天气类型划分方法, 降低输入变量维度, 提供更高质量的数据来提升模型预测的效果。鉴此, 本文提出一种基于 BRICH 聚类和 Copula-Monte Carlo 模拟的光伏发电功率概率预测方法, 并与隐马尔可夫模型(HMM)和梯度提升回归树模型(GBRT)功率预测模型结果进行了对比分析, 验证了所提方法的有效性。

## 2 基于 BRICH 聚类分析的天气分型

光伏发电功率受天气影响严重, 基于季节对天气进行聚类分型, 然后针对每个季节的不同天气类型训练模型参数, 可有效提高模型的预测效果。首先对含 22 个特征值的高维 NWP 数据采用主成分分析进行降维, 然后将降维后的主成分送入 BRICH 聚类算法进行天气分型。BRICH 聚类主要通过构建聚类特征树(CF-tree)进行聚类, 算法执行过程中只需一次扫描原始数据就可完成聚类, 适用于大规模、多分类的数据, 具备计算速度快、能识别数据噪音的优点<sup>[7]</sup>。基于 BRICH 聚类分析的天气分型计算步骤如下。

**收稿日期:** 2023-06-04, **修回日期:** 2023-07-13

**基金项目:** 国家电网有限公司科技项目资助(SGHZ0000DKJS2200330)

**作者简介:** 黄牧涛(1973-), 女, 博士、研究员, 研究方向为新型电力系统精准预测与优化调度、能源博弈论、智慧综合能源系统规划与调控等, E-mail: huangmutao@hust.edu.cn

**步骤 1** 构建聚类特征树(CF-tree)。确定 CF-tree 的三个参数  $B$ 、 $L$ 、 $T$  ( $B$  为每个内部节点的最大  $C_F$  数;  $L$  为叶节点允许包含的最大  $C_F$  个数;  $T$  为叶节点每个  $C_F$  的最大样本半径阈值)。其中  $C_F = (N, L_S, S_S)$  表示聚类特征三元数组,  $N$  为每个  $C_F$  含有的样本个数;  $L_S$  为此  $C_F$  中所有样本点的各特征值的和向量;  $S_S$  为此  $C_F$  中各特征值的平方和。  $L_S$ 、 $S_S$  的计算方法分别为:

$$L_S = \sum_{n=1}^N \mathbf{x}_n = \left( \sum_{n=1}^N x_{n1}, \sum_{n=1}^N x_{n2}, \dots, \sum_{n=1}^N x_{nM} \right)^T \quad (1)$$

$$S_S = \sum_{n=1}^N \sum_{m=1}^M x_{nm}^2 \quad (2)$$

式中,  $\mathbf{x}_n$  为第  $n$  个样本向量;  $x_{nm}$  为第  $n$  个样本点的第  $m$  个特征值;  $M$  为样本点中数据的特征数。

**步骤 2** 读入样本点。将样本点逐个送入 CF-tree, 寻找与新样本点最近的叶节点  $A$ , 并计算若将新样本点加入后叶节点  $A$  的族半径  $R$ , 计算方法为:

$$R = \sqrt{\frac{1}{N} \sum_{n=1}^N (\mathbf{x}_n - \mathbf{x}_0)^2} \quad (3)$$

**步骤 3** 插入样本点: ①Step1。若  $R \leq T$ , 则更新 CF-tree 路径上的所有  $C_F$  元组并转入 Step3; 否则转入 Step2。②Step2。判断叶节点  $A$  的  $C_F$  个数是否达到最大  $L$ 。若小于  $L$ , 则创建一个新的  $C_F$  节点存放新样本并更新 CF-tree 路径上的所有  $C_F$  元组; 否则, 选取叶节点  $A$  中所有  $C_F$  元组中超球体半径距离最远的两个  $C_F$  作为新的叶节点  $A'$  和  $A''$  代替原来的叶节点  $A$ , 将其余  $C_F$  元组和新样本元组按距离的远近依次放入新叶节点  $A'$  和  $A''$ 。③Step3。自下而上检查父节点是否需分裂。如果需分裂, 就按与叶节点相同的方式进行分裂, 直到根节点。

**步骤 4** 优化 CF-tree。采用 K-means 聚类算法对所有  $C_F$  元组进行二次聚类, 以消除因  $L$  限制导致的 CF-tree 分裂和样本点按顺序读入导致的分类偏差。

## 3 基于 Copula-Monte Carlo 的光伏发电功率概率预测方法

### 3.1 建模原理

对于  $N$  个随机变量的联合分布函数, 可将其分解为这  $N$  个随机变量各自的边缘累积分布函数和一个 Copula 函数, 随机性由各自的边缘累积分布函数进行描述, 耦合性由 Copula 联合分布函

数进行描述。以二维情况为例, Copula 函数可作如下定义, 设  $H$  为二元随机变量  $(X, Y)$  的联合分布函数,  $F_X(x)$ 、 $F_Y(y)$  为其边缘累积分布函数, 则存在一个定义在  $[0, 1]^2 \rightarrow [0, 1]$  的二元 Copula 函数  $C$ :

$$H(x, y) = C(F_X(x), F_Y(y)) \quad (4)$$

当  $F_X(x)$ 、 $F_Y(y)$  为连续函数时,  $C$  可唯一确定, 否则  $C$  在  $\text{Ran}F \times \text{Ran}G$  上唯一确定 ( $\text{Ran}F$  为累积分布函数  $F$  的取值范围)。Copula 函数实际是一个定义在  $[0, 1] \times [0, 1]$  上的二维分布函数, 其边缘分布是  $[0, 1]$  上的均匀分布。

Copula-Monte Carlo 模拟主要步骤是先建立历史光伏发电功率实际值与预测值的 Copula 函数, 然后基于建模的 Copula 函数采用 Monte Carlo 模拟出大量的光伏发电功率实际值和预测值样本  $(x_m, y_m)$ , 最后依据大数定律和条件概率求解在已知光伏发电功率点预测值  $\hat{y}$  的情况下光伏发电功率实际值  $x$  的条件概率<sup>[8-9]</sup>。

Copula 函数中变量  $X$  在给定  $Y \leq \hat{y}$  下的条件分布函数计算方法<sup>[10]</sup>为:

$$C(u | \hat{v}) = C(u, \hat{v}) / \hat{v} \quad (5)$$

$$\hat{v} = F_Y(\hat{y}) \quad (6)$$

则条件概率密度函数由式(4)关于随机变量  $x$ 、 $y$  求二阶导数可得:

$$h_{X|Y}(x | \hat{y}) = \frac{c(u, \hat{v}) f_X(x) f_Y(\hat{y})}{f_Y(\hat{y})} =$$

$$c(u, \hat{v}) f_X(x) \quad (7)$$

$$c(u, \hat{v}) = \partial^2 C(u, \hat{v}) / \partial u \partial \hat{v} \quad (8)$$

式中,  $c(u, \hat{v})$  为 Copula 概率密度函数;  $f_X(x)$ 、 $f_Y(y)$  分别为实际功率  $X$ 、预测功率  $Y$  的边缘概率密度函数。

### 3.2 计算流程

**步骤 1** 光伏发电功率相关性分析。光伏发电功率受多种因素影响, 首先剔除夜间数据、对异常数据进行识别和修正, 确保输入数据的有效性和可信度, 然后基于对测光数据与光伏发电功率数据进行相关性分析, 筛选出对光伏发电功率影响大的因素作为光伏功率预测模型的输入变量。

**步骤 2** 基于 NWP 数据的天气分型。采用主成分分析法 PCA 对含 22 个特征值的高维 NWP 数据进行降维, 采用 BRICH 聚类对筛选出的主成分按各季节进行天气聚类分型。

**步骤 3** 光伏发电功率点预测值计算。按天气分型结果, 针对各季节天气类型, 将对光伏预测精度影响较大的总辐照度、水平面散射辐照度和

直射辐照度作为输入因子用长短期记忆神经网络(LSTM)进行点预测,得到光伏发电功率的点预测值。

**步骤 4** 估计边缘函数。针对每种天气类型下的历史光伏发电功率样本点(包含历史发电功率实际值和预测值),基于 Matlab 内置函数 Ksdensity 采用高斯核光滑估计得到边缘分布函数估计  $F_X$ 、 $F_Y$  和边缘密度函数估计  $f_X(x)$ 、 $f_Y(y)$  [11]。

**步骤 5** 选择 Copula 函数。采用基于边缘分布最大似然法估计 Copula 函数的参数,计算各 Copula 分布函数  $C(u, \hat{v})$  和经验 Copula 函数  $\hat{C}(u, \hat{v})$  的欧氏距离,选择欧氏距离最小的阿基米德 Copula 函数对光伏发电实际功率和预测功率的联合分布函数进行建模。

**步骤 6** Monte Carlo 模拟。设置蒙特卡罗抽样次数为 8 000,得到每季度每种天气类型下的光伏发电功率样本点  $(x_m, y_m)$ 。

**步骤 7** 计算条件概率。根据完成建模的 Copula 函数模型,利用式(5)、(7)计算在已知未来点预测功率  $\hat{y}$  条件下光伏发电实际功率  $X_m$  的条件概率  $h_{X_m|Y}(x_m | \hat{y})$  并进行黎曼积分获得  $X_m$  的条件分布  $H_{X_m|Y}(x_m | \hat{y})$ 。

**步骤 8** 计算预测区间。根据步骤 5 所得的条件分布,计算名义置信水平为  $(1-\alpha)\%$  的光伏发电功率预测区间为:

$$\begin{cases} P(x_{ml} \leq X_m) = H_{X|Y}(x_{ml} | \hat{y}) = \alpha/2 \\ P(x_{mu} \leq X_m) = H_{X|Y}(x_{mu} | \hat{y}) = 1 - \alpha/2 \end{cases} \quad (9)$$

基于 BRICH 聚类和 Copula-Monte Carlo 模拟的光伏发电功率概率预测方法计算流程见图 1。

### 3.3 评价指标

(1)区间覆盖率( $P_{PICP}$ )。是指在预设一个名义置信水平  $(1-\alpha)\%$  的情况下实际光伏发电功率落入预测区间的概率,反映了概率预测的准确度 [12]。 $P_{PICP}$  计算方法为:

$$P_{PICP} = \frac{1}{N} \sum_{i=1}^N c_i \quad (10)$$

$$c_i = \begin{cases} 1 & x \in [x_{ml}^{(i)}, x_{mu}^{(i)}] \\ 0 & x \notin [x_{ml}^{(i)}, x_{mu}^{(i)}] \end{cases} \quad (11)$$

式中, $N$  为预测光伏发电功率的时间点数, $i=1, 2, \dots, N$ ;  $c_i$  为示性函数,当预测时刻的光伏发电功率实际落入预测区间时, $c_i$  取 1,否则  $c_i$  为 0;  $[x_{ml}^{(i)}, x_{mu}^{(i)}]$  为第  $i$  个时间点预测功率的名义置信水平为  $(1-\alpha)\%$  的预测区间。

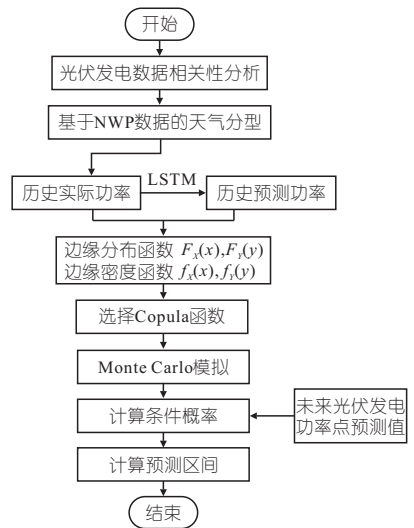


图 1 Copula-Monte Carlo 光伏发电功率概率预测计算流程  
Fig. 1 Copula-Monte Carlo photovoltaic power generation probability prediction calculation process

(2)预测区间平均宽度( $P_{PINAW}$ )为预测区间的整体宽窄程度,为所有预测区间的区间左侧  $x_{mu}$  与区间右侧  $x_{ml}$  之差的平均值。在满足一定的  $P_{PICP}$  时,要力求平均宽度  $P_{PINAW}$  尽可能小,  $P_{PINAW}$  越小,表明预测区间与实际发电功率的值越贴近,计算方法为:

$$P_{PINAW} = \frac{1}{N} \sum_{i=1}^N (x_{mu}^{(i)} - x_{ml}^{(i)}) \quad (12)$$

## 4 算例分析

光伏发电数据采用某光伏电站 2019~2020 年共计 731 d 的实际测光数据、NWP 数据和光伏发电功率数据,数据时间尺度均为 15 min。以夏季为例,针对晴天、多云、雨雪天气 3 种天气类型的光伏发电数据,设置 80% 的数据为训练集,20% 的数据为测试集送入模型进行概率预测。分别计算了 Copula-Monte Carlo 模型、隐马尔科夫模型 HMM、梯度提升回归树 GBRT 这 3 种模型在名义区间覆盖率为 90% 情况下的  $P_{PICP}$ 、 $P_{PINAW}$ 。

### 4.1 NWP 数据的 PCA 降维

表 1 为光伏板测光数据和光伏发电功率的皮尔逊相关系数 PCCs 计算结果。选择夏季与光伏发电功率数据相关性系数均大于 0.5 的总辐照度、水平面散射辐照度和直射辐照度作为功率预测模型的输入变量。

表 1 测光数据与光伏发电功率皮尔逊相关系数

Tab. 1 Pearson correlation coefficient between photometric data and PV power

环境变量	PCCs	环境变量	PCCs
总辐照度	0.97	气温	0.21
法向直射辐照度	0.73	气压	-0.04
水平面散射辐照度	0.73	相对湿度	-0.32

将含有 22 个特征值的 NWP 数据进行 PCA 降维。夏季的计算结果见图 2。由图 2 可看出,夏季的前 5 个主成分的累计贡献率均超过了 80%,而为了充分保留原始 NWP 数据信息,选择累计贡献率超过 85% 且特征值均大于 1 的前 5 个主成分作为聚类算法的输入变量进行天气分型。




图 2 夏天 PCA 结果

Fig. 2 Summer PCA results

### 4.2 BRICH 聚类分析

设置  $B = 50, L = 50, T = 0.5$ , 对 NWP 数据降维后的主成分进行 BRICH 聚类。选择轮廓系数和 Calinski-Harabasz(CH) 分数作为聚类效果评价指标,最终优选聚类簇数  $n = 3$ 。各种天气类型的样本数均超过了 20 日。

### 4.3 光伏功率预测结果对比分析

夏季各天气类型下的评价指标见表 2。由表 2 可知,3 种模型的预测结果为 Copula-Monte Carlo 最优,GBRT 次之,HMM 最差。

表 2 夏天评价指标

Tab. 2 Evaluation indicators of summer

名义区间 覆盖率/%	天气	指标	Copula-Monte		
			Carlo	HMM	GBRT
90	类型 1	$P_{PICP}/\%$	94.30	82.00	82.30
		$P_{PINAW}/MW$	21.60	24.28	22.50
	类型 2	$P_{PICP}/\%$	90.00	85.60	85.30
		$P_{PINAW}/MW$	9.53	15.42	9.48
	类型 3	$P_{PICP}/\%$	94.70	85.70	85.70
		$P_{PINAW}/MW$	25.94	32.13	26.03

注:类型 1,2,3 分别为晴天、多云、雨雪天气。

为了更直观地展现 Copula-Monte Carlo 概率预测性能的优越性,绘制夏天每种天气类型下各 3 d 的光伏发电功率实际值及概率区间预测结果,见图 3。由图 3 可看出:①天气类型 1。光伏发电功率连续性强、发电功率高,早晚的预测区间宽度窄,午间发电高峰时预测区间的宽度变得更窄,这也导致当午间高峰光伏发电功率出现轻微波动时,存在因预测区间较窄导致无法覆盖实际发电功率的情况。②天气类型 2。光伏发电功率连续性差、发电功率水平为 3 种天气状况中最低,早晚预测区间宽度变得更宽,预测区间的整体宽度也相对变得更宽,随着发电功率的波动性增强预测区间的宽度明显增加。③天气类型 3。光伏

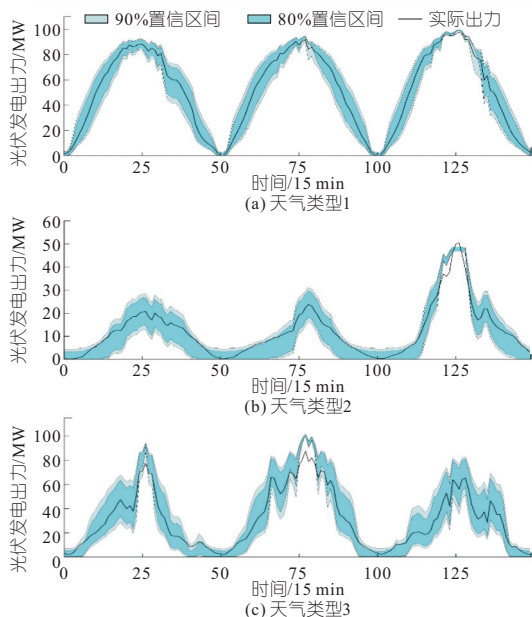


图 3 夏天概率区间预测结果

Fig. 3 Probability interval forecast results of summer

发电功率波动性最强、发电功率处于中高水平,早晚的预测区间宽度相对天气类型 2 变窄,可明显看到当出力出现较大波动时预测区间宽度增加,午间发电高峰时当发电功率在较高水平发生波动时同样会出现预测区间变窄无法覆盖实际发电功率的情况。

综上所述,从天气类型 1 到类型 3,随着发电功率水平降低,发电功率连续性下降,预测区间变宽;随着午间高峰发电功率水平的增加,预测区间宽度会减小。但 3 种情况下的预测区间均能很好地覆盖光伏发电功率实际值,且  $P_{PICP}$  越大,预测区间宽度越大、预测区间覆盖面积越大,表明 Copula-Monte Carlo 概率预测模型确实具有良好的可靠性和稳定性。

## 5 结论

提出了基于主成分分析和 BRICH 聚类的天气分型方法,搭建了基于 Copula-Monte Carlo、HMM 和 GBRT 的 3 种光伏发电功率概率预测模型,预测光伏发电出力的概率分布,并通过算例验证 Copula-Monte Carlo 方法预测效果最优。

### 参考文献:

[1] 万灿,崔文康,宋永华. 新能源电力系统概率预测:基本概念与数学原理[J]. 中国电机工程学报, 2021, 41(19): 6493-6509.

[2] SONG H, AL KHAFAF N, KAMOONA A, et al. Multitasking recurrent neural network for photovol-

taic power generation prediction [J]. Energy reports, 2023, 9(S3): 369-376.

[3] TIANZE L, SHUSEN L, SHUNJIANG W, et al. Short-term photovoltaic power prediction based on MDCM-GA-LSTM model[J]. The journal of engineering, 2022, 2022(10): 994-1005.

[4] 周帆, 郑常宝, 胡存刚, 等. 基于高斯混合模型的光伏发电功率概率区间预测[J]. 科学技术与工程, 2021, 21(24): 10284-10290.

[5] 刘洁, 林舜江, 梁炜焜, 等. 基于高阶马尔可夫链和高斯混合模型的光伏出力短期概率预测[J]. 电网技术, 2023, 47(1): 266-275.

[6] 许彪, 徐青山, 黄煜, 等. 基于藤 copula 分位数回归的光伏功率日前概率预测[J]. 电网技术, 2021, 45(11): 4426-4435.

[7] 张虎, 陈建斌, 魏欢. 一种改进的 BRICH 算法及其应用[J]. 软件导刊, 2015, 14(10): 45-47.

[8] NELSEN R B. An introduction to copulas[M]. New York: Springer, 1999.

[9] LANDAU D P, BINDER K. A guide to Monte Carlo simulations in statistical physics (4th ed.) [M]. Cambridge: Cambridge University Press, 2014.

[10] CHEN Y D, ZHANG Q, XIAO M, et al. Probabilistic forecasting of seasonal droughts in the Pearl River basin, China[J]. Stochastic environmental research and risk assessment, 2016, 30(7): 2031-2040.

[11] AGOUA X G, GIRARD R, KARINIOTAKIS G. Probabilistic models for spatio-temporal photovoltaic power forecasting[J]. IEEE transactions on sustainable energy, 2019, 10(2): 780-789.

[12] HE Y, QIN Y, WANG S, et al. Electricity consumption probability density forecasting method based on LASSO-Quantile Regression Neural Network[J]. Applied energy, 2019, 233: 565-575.

## Photovoltaic Power Probabilistic Prediction Based on BRICH Clustering and Copula-Monte Carlo Simulation

HUANG Mu-tao<sup>1a</sup>, GAO Su-hua<sup>1b</sup>, WANG Yang<sup>2</sup>, ZENG Ling-kang<sup>2</sup>, WEI Cong-ying<sup>2</sup>, CHEN Xing-bang<sup>1a</sup>  
 (1a. School of Electrical and Electronic Engineering; 1b. School of Civil and Hydraulic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China; 2. Dispatching and Control Center of Central China Branch of State Grid Corporation of China, Wuhan 430077, China)

**Abstract:** Photovoltaic power generation is affected by the chaotic characteristics of meteorology, and its stochastic, volatile and intermittent characteristics affect the operation of power systems seriously. Aiming at the problem of large dimension of original PV power generation data and the vulnerability of power generation to weather conditions, a data processing method based on Principal Component Analysis (PCA) and BRICH clustering was proposed to reduce the dimensionality of model input variables and facilitate statistical modeling. Secondly, a Copula-Monte Carlo-based probabilistic PV power probabilistic prediction model was constructed to calculate the probabilistic interval prediction of PV power output given the future point prediction values. The model was evaluated based on interval coverage and average width of prediction interval. Finally, the summer data of the actual photovoltaic power station were taken as an example for verification analysis. The results show that the Copula-Monte Carlo method can intuitively show the fluctuation range and expected value of photovoltaic power generation, and is superior to other power prediction models.

**Key words:** probabilistic prediction; PV power generation; BRICH clustering; Copula function; Monte Carlo simulation; weather fractal



(上接第 228 页)

[6] 丁立国, 申彦波, 马勋丹, 等. FY-4A 地面太阳辐射产品在贵州高原山区的适用性研究[J]. 高原气象, 2022, 41(4): 1041-1050.

[7] 王林, 陈正洪, 唐俊. 太阳能光伏发电预报方法的应用效果检验与评价[J]. 气象, 2014, 40(8): 1006-1012.

[8] 彭继达, 程兴宏, 孙治安, 等. 两种不同初始场对太阳辐射模拟效果的影响[J]. 高原气象, 2014, 33(5): 1352-1362.

## Inspection and Evaluation of CMA-WSP Ground Radiation Forecast Products

ZHU Yan<sup>1</sup>, WANG Ming<sup>1,2</sup>, XU Pei-hua<sup>1</sup>, MENG Dan<sup>1</sup>, CHEN Zheng-hong<sup>1</sup>

(1. Hubei Meteorological Service Center, Wuhan 430205, China; 2. Hubei Key Laboratory for Heavy Rain Monitoring and Warning Research, Institute of Heavy Rain, China Meteorological Administration, Wuhan 430205, China)

**Abstract:** Based on the ground radiation observation data of Hubei Huashi photovoltaic power station from April to September in 2022, the forecast accuracy of the ground radiation products of Wind Energy and Solar Energy Forecasting System of China Meteorological Administration (CMA-WSP) was evaluated. Overall, the correlation coefficient between ground solar radiation and observation in the next 5 days predicted by CMA-WSP is between 0.85 and 0.91, and the forecast effect on the first day is the best. With the increase of forecast time, the forecast accuracy gradually decreases. From the perspective of month-by-month effect, the CMA-WSP has the best effect on ground radiation forecasting in August and September, and the forecast accuracy rate in May and June is relatively low. In terms of daily changes, the CMA-WSP has a relatively poor forecasting effect on ground radiation at 10:00~16:00, and is better in other periods. The prediction of ground radiation by CMA-WSP has strong seasonality. The forecast results of different times in spring are quite different, and are relatively stable in summer. The forecast effect in autumn is the most stable, and the correlation coefficient between the prediction results and observation can reach 0.92. In general, the CMA-WSP has a good effect on the ground radiation forecasting in Hubei Province, which can provide good support for the short-term forecasting of photovoltaic resources in Hubei Province.

**Key words:** CMA-WSP; photovoltaic power plant; ground solar radiation; forecast inspection