

DOI: 10.19783/j.cnki.pspc.200906

# 基于 SAPSO-BP 和分位数回归的光伏功率区间预测

贾德香<sup>1</sup>, 吕干云<sup>2</sup>, 林芬<sup>3</sup>, 吴晨媛<sup>2</sup>, 章心因<sup>2</sup>

(1. 国网能源研究院有限公司, 北京 102209; 2. 南京工程学院电力工程学院, 江苏 南京 211167;  
3. 国网福建省电力有限公司, 福建 福州 350003)

**摘要:** 提出了一种基于 SAPSO-BP(模拟退火粒子群优化 BP 神经网络)和分位数回归的光伏功率区间预测方法。首先给出一种动态 SAPSO-BP 算法对光伏出力进行预测,该方法考虑 BP 的局部极小化和粒子群的早熟收敛等问题,能优化 BP 的参数设置,提高光伏功率的预测精度。在光伏功率确定性预测的基础上,通过分析不同天气类型下 SAPSO-BP 模型的预测功率误差。最后根据不确定天气因素建立分位数回归模型,实现对光伏输出功率的波动区间分析。该模型无需假设光伏预测功率误差分布,且计算方法简单,可提供在任意置信水平下,光伏预测功率的波动范围,为电力系统调度决策、运行风险评估提供更加丰富的信息。

**关键词:** 光伏功率预测; 区间预测; SAPSO-BP; 分位数回归

## Photovoltaic power interval prediction based on SAPSO-BP and quantile regression

JIA Dexiang<sup>1</sup>, LÜ Ganyun<sup>2</sup>, LIN Fen<sup>3</sup>, WU Chenyuan<sup>2</sup>, ZHANG Xinyin<sup>2</sup>

(1. State Grid Energy Research Institute Co., Ltd., Beijing 102209, China; 2. School of Electric Power Engineering, Nanjing Institute of Technology, Nanjing 211167, China; 3. State Grid Fujian Electric Power Co., Ltd., Fuzhou 350003, China)

**Abstract:** A photovoltaic power interval prediction is proposed based on an optimized Back Propagation (BP) neural network by Simulated Annealing Modified Particle Swarm Optimization (SAPSO-BP) and quantile regression. First, a dynamic SAPSO algorithm is used to predict the Photovoltaic (PV) output, taking the local minimization of BP and precocious convergence of the particle swarm into account. Then it optimizes the parameter setting of the BP neural network and improves the accuracy of prediction. From a deterministic prediction of PV power, the prediction power error of the SAPSO-BP model under different weather types is analyzed. Finally, a quantile regression model is established based on uncertain weather factors to realize the interval analysis of future power fluctuation. The model does not have to predict the distribution of the PV predicted power error, and the calculation method is simple. The fluctuation range of the predicted power of the PV can be provided at any confidence level. The model provides more abundant information for power system scheduling decision and operational risk assessment.

This work is supported by the National Natural Science Foundation of China (No. 51577086).

**Key words:** PV power prediction; interval prediction; SAPSO-BP; quantile regression

## 0 引言

随着全球化石能源短缺和环境污染问题的日益严重,光伏作为一种可再生能源,其并网容量迅速增大。然而,光伏电站的输出功率受太阳辐射、

温度等天气因素影响明显<sup>[1]</sup>,其随机性、波动性、不确定性等给电能质量、电力调度、电网的安全稳定带来严峻挑战。因此,提前对光伏出力进行预测,对于提高系统安全稳定运行、电网经济调度都有重要意义。

目前,光伏功率的确定性预测方法主要有回归模型预测方法<sup>[2]</sup>、神经网络预测方法<sup>[3-4]</sup>、支持向量机<sup>[5-7]</sup>预测方法、灰色预测方法<sup>[8]</sup>等。确定性预测模型的优劣和训练样本与预测日的相似程度密切相关,通过互信息熵<sup>[9]</sup>、灰色关联度<sup>[10]</sup>提取相似日可

**基金项目:** 国家自然科学基金项目资助(51577086);江苏“六大人才高峰”资助(2016-XNY027, TD-XNY004);国家电网公司总部科技项目资助(5400-202040230A0000);江苏省高校科研重大项目资助(19KJA510012)

提高模型匹配度,从而有效减小了不确定性影响,改善了预测精度。传统的确定性预测无法对光伏功率预测的不确定性作出有效地描述,难以满足电网调度决策和风险评估的需求,而概率预测可提供未来光伏出力的概率信息,具有更重要的工程意义。区间预测方法在风电领域应用较成熟,通过非参数核密度估计法<sup>[11]</sup>求解预测误差的概率密度函数,再计算置信区间;通过 Monte-Carlo 随机抽样的分析方法<sup>[12]</sup>,再采用非参数回归方法进行不确定性分析,计算置信区间。但是与风电区间预测不同的是,光伏区间预测的预测误差分析与光辐射强度、温度、湿度等影响因素密切相关。文献[13]在确定性预测的基础上叠加一个正态分布误差,建立一个光伏区间预测模型。文献[14]提出一种采用 Copula 函数对光伏预测出力进行分析的方法,计算出不同天气类型下预测误差概率分布,再计算其区间预测范围。文献[15]则先通过非参数核密度估计获得光伏出力的概率分布,然后利用 Copula 函数分析光伏出力与点预测的误差相关性,从而获得预测分位点下精度较高的出力区间。文献[16]应用动态贝叶斯网络理论,建立一种条件概率预测方法。以上方法都需要假设预测误差概率分布,具有一定的局限性且工程实用性弱。文献[17]提出一种基于贝叶斯模型、马尔可夫链模型和分位数回归模型的概率性预测模型,得到预测分布,提供一定概率信息。文献[18]在极限学习机预测基础上,通过误差校正有效减小风电预测的不确定性及改善误差分布特性。文献[19]先采用分位数构造区间上、下界规划模型,然后利用极限学习机有效求解预测光伏出力区间的上、下界。另外,大多基于统计机器学习预测通常适用于类似于历史数据的天气条件,文献[20]提出了一种由外部天气数据驱动的混合深度学习模型,较好地实现了复杂天气下的光伏出力不确定性预测。

本文首先依据天气数据和历史功率数据,通过改进算法对光伏功率进行确定性预测,然后采用分位数回归方法对光伏功率进行区间预测。分位数回归采用加权残差绝对值之和和估计参数,是最小二乘法的延伸,具有较好的弹性性质,并能准确反映误差分布的特性,有效考虑数据极端值的影响。本文所提出的分位数回归算法基于 t 检验和改进单纯形法,与计算预测误差概率分布相比具有更好地灵活性和置信度适应性。

## 1 分位数回归

### 1.1 分位数回归原理

分位数回归的有关定义如下<sup>[21]</sup>:

对于任意随机变量  $X$ , 其分布函数为  $F(x) = P(X \leq x)$ , 则  $\forall \tau \in (0,1)$

$$Q(\tau) = F^{-1}(\tau) = \inf \{x: F(x) \geq \tau\} \quad (1)$$

式中,  $\inf \{x: F(x)\}$  表示满足  $F(x)$  的自变量  $x$  的最小值。称  $Q(\tau)$  为  $X$  的  $\tau$  分位数,  $Q(\tau)$  之下的变量个数占总变量个数的权重为  $\tau$ 。

定义“检验函数”为

$$\rho_{\tau}(u) = \tau u I(u \geq 0) + (\tau - 1) u I(u < 0) \quad (2)$$

式中,  $I$  为指示函数。当  $u \geq 0$  时,  $\rho_{\tau}(u) = \tau u$ ; 当  $u < 0$ ,  $\rho_{\tau}(u) = (\tau - 1)u$ 。

分位数回归模型的方程式为

$$Q(\tau) = Y = X\beta + \varepsilon \quad (3)$$

式中,  $\varepsilon$  为随机变量。分位数回归采用使加权误差绝对值之和最小的方法来估计回归方程中的参数,得参数  $\beta$  的估计值为

$$\beta(\tau) = \arg \min \sum_{i=1}^n \rho_{\tau}(y_i - x_i' \beta) \quad (4)$$

该式等价于求解线性规划方程:

$$\text{Max}\{y'u \mid X'u = (1-u)X'z, u \in [0,1]^n\} \quad (5)$$

式中,  $z$  为单位向量。

### 1.2 分位数回归预测模型

区间预测是一种描述预测值不确定性的分析方法,可以基于光伏功率确定性预测结果分析其预测误差,求取任意置信度下的置信区间。

本文基于光伏点预测系统,分析其预测的相对误差  $e = (P_s - P_y) / P_s$ , 其中,  $P_s$  为光伏出力实际值,  $P_y$  为光伏出力预测值,建立分位数回归模型。预测相对误差  $e$  的分位数函数  $Q(\tau)$  的定义式为

$$Q(\tau) = \inf \{e: F(e) \geq \tau\} \quad (6)$$

式中,  $F(e)$  为  $e$  的概率分布函数。在光伏预测系统中,由于相对误差  $e$  与不确定性因素联系密切,则分位数函数可表示为

$$Q(\tau) = c_1 x_1 + c_2 x_2 + \varepsilon \quad (7)$$

式中:  $c_1$ 、 $c_2$  为参数;  $x_1$ 、 $x_2$  为不确定因素辐射和温度;  $\varepsilon$  为系统残差值。由于辐射和温度在置信度条件为 0.05 的 t 检验下, 检验值都为  $0 < 0.05$ , 说明影响显著,故采用温度和辐射作为不确定性因素,最后采用改进单纯形法估计:

$$c(\tau) = \arg \min \sum_{i=1}^n \rho_{\tau}[e_i - (c_{i,1} x_{i,1} + c_{i,2} x_{i,2})] \quad (8)$$

改进单纯形法通过旧基阵的逆计算新基阵的逆,可减少迭代累积误差,提高计算精度。通过计算出不同分位数值下的  $c_1$ 、 $c_2$  参数值,建立相关的

分位数回归模型。

## 2 区间预测模型实现

本文针对光伏出力的特点，提出基于分位数回归的 SAPSO-BP 模型对光伏出力进行区间预测，通过初期对数据的处理和分析，确定输入参数，并采用 SAPSO 算法对 BP 神经网络的权值和阈值进行寻优，减小非线性因素带来的影响。在此确定性预测的基础上，采用分位数回归模型，得到不同置信度下的区间预测模型。

### 2.1 输入参数的选取

太阳能具有间断性、分散性的弱点，由于受到昼夜、季节、地理分布等随机因素的影响，太阳能辐射和光伏发电具有间歇性、不稳定性。光伏发电输出功率可按式(9)表述。

$$p_s = \eta SI[1 - 0.005(t + 25)] \quad (9)$$

式中： $\eta$  为光伏电池转换效率； $S$  为光伏阵列面积； $I$  为太阳辐射强度； $t$  为工作环境温度。由公式更可见温度、辐照强度对光伏功率起决定性因素，本文以影响光伏出力的主要因素为参考，设置预测模型的输入参数。其主要影响因素有太阳辐射、天气类型、温度、湿度等。影响因素与光伏功率的变化关系如图 1—图 3 所示。

不同的天气类型，其曲线波动程度、预测误差效果都不一样，所以天气类型作为模型输入参考量。并且，虽然从曲线看温度、辐射与输出功率存在一

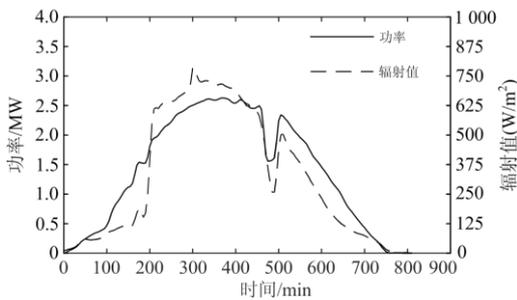


图 1 太阳辐射和光伏出力

Fig. 1 Solar radiation and photovoltaic output

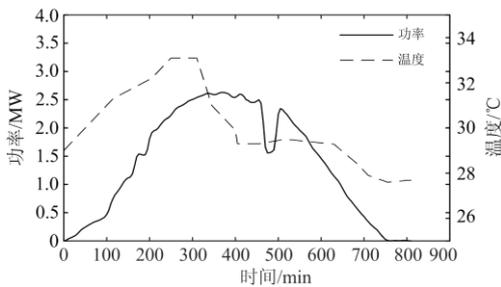


图 2 温度和光伏出力

Fig. 2 Temperature and photovoltaic output

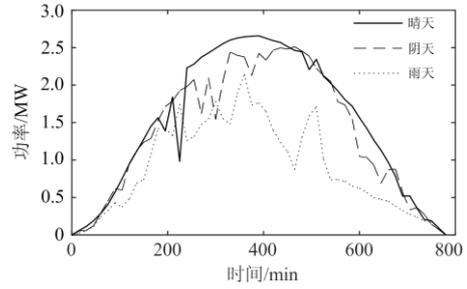


图 3 不同天气类型

Fig. 3 Different weather types

定的线性关系，但是由于实时的辐射和温度预测不能十分准确，所以本文以此为基础，采用定性的相关性分析结论判断影响因素。定性的相关性分析可以判断几种客观变量之间是否存在相关关系。线性相关系数  $r$  为

$$r = \frac{S_{xy}^2}{S_x S_y} = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}} \quad (10)$$

针对预测点光伏数据，本文对某光伏电站历史数据中的某时刻  $t$  采样点、前一个时刻  $t-1$  采样点和前两个时刻  $t-2$  采样点的多个变量与某时刻采样点的功率进行定性的相关性分析计算，得到线性相关系数  $r$  如表 1 所示。

表 1 线性相关性分析

Table 1 Linear correlation analysis

$ r $	温度	功率	辐射	大气压	湿度
$t$	0.32	—	0.95	0.15	0.2
$t-1$	0.32	0.99	0.93	0.14	0.18
$t-2$	0.23	0.99	0.93	0.14	0.15

$r$  的取值范围为 $[-1,1]$ 。 $|r|=1$ 表示完全线性相关； $|r| \leq 0.3$ 表示不存在线性相关； $0.3 \leq |r| \leq 0.5$ 表示低度线性相关； $0.5 \leq |r| \leq 0.8$ 表示显著线性相关； $|r| \geq 0.8$ 为高度线性相关。基于以上的线性分析和实时天气信息预报的误差性，本文决定采用  $t-1$  采样点太阳辐射、 $t-1$  采样点温度、 $t-2$  采样点太阳辐射、 $t-1$  采样点功率、 $t-2$  采样点功率做为输入参数，以天气类别进行分类预测。

### 2.2 基于分位数回归的 SAPSO-BP 模型

分位数回归模型一般建立在预测效果较好的预测模型上，本文提出的改进算法能提高模型预测精度。

典型的 BP 神经网络<sup>[22]</sup>由输入层、隐含层和输出层构成，BP 神经网络具有非线性映射能力、自学习和自适应能力、泛化能力等优点。但是，网络中

的权值和阈值初始值一般都是随机产生的, 之后再沿着网络误差变化的负阶梯度方向进行调整, 如果权值和阈值的取值不当, 网络将存在收敛缓慢、局部极小化、学习速度慢等问题。基于上述问题的分析, 为了进一步提高模型的可靠性, 本文将动态粒子群算法和模拟退火算法相结合, 经过不断地寻优过程得到最优解, 优化网络的初始权值和阈值, 提高其学习能力。

粒子群算法(PSO)具有计算过程简单、搜索速度快、效率高等特点, 能优化神经网络的权值和阈值、弥补网络的缺点, 但是随着迭代次数的增多, PSO的早熟收敛和局部收敛的缺点不容忽视。本文提出模拟退火的思想 and 一种动态优化对粒子群算法进行优化(SA)。该算法模拟固体物体的退火过程, 先给定初始温度  $T_0 = f_{\max} - f_{\min}$ ,  $f_{\max}$ 、 $f_{\min}$  为初始群体的最大、最小适应度, 然后以一定的概率接受或者舍弃由于降温造成的新状态, 判断最优适应度, 最终达到平衡。

由于不同天气状况下, 光伏出力波动范围和幅度不一样, 本文对天气类型进行划分, 分为晴天、阴天和雨天。预测前, 先对天气类型进行识别, 再代入相同天气类别的历史数据进行预测, 并计算出相对误差, 进行分位数回归建模, 预测模型结构图如图 4 所示。

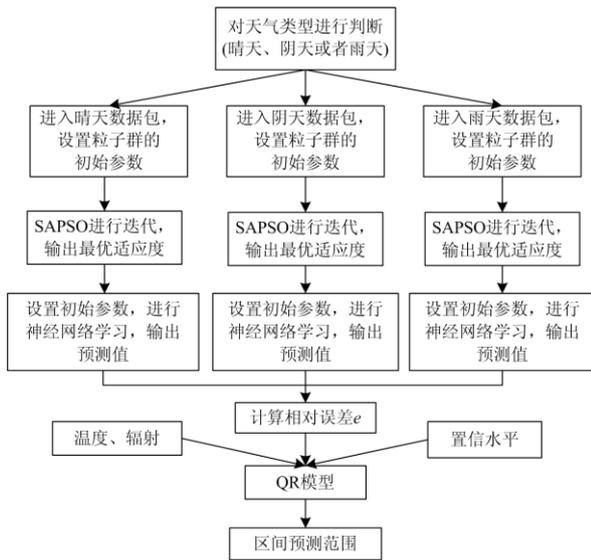


图 4 不确定功率预测模型结构图

Fig. 4 Structure diagram of uncertain power prediction

其中, SAPSO 的参数设置为: 种群规模  $s = 30$ ,

$$c_1 = \frac{2n}{n_{\max}} + 2.5, \quad c_2 = \frac{2n}{n_{\max}} + 0.5 \quad (n_{\max} \text{ 为最大迭代次数, } n \text{ 为当前迭代次数}), \text{ 迭代次数 } n = 50.$$

BP 神经网络的参数设置为: 输入层节点数为 4, 输出层

节点数为 1, 隐含层节点数计算参考公式为

$$n_y = \sqrt{n + m} + 1 \approx 3 \quad (11)$$

式中:  $n_y$  为隐含层节点数;  $n$  为输入层节点数;  $m$  为输出层节点数。

### 2.3 数据样本的预处理

由于各个输入量的数据量纲并不相同, 因此在进行网络训练前, 必须对数据进行归一化处理, 使其值限制在  $[0,1]$  内, 消除不同量纲对预测结果带来的影响, 归一化公式为

$$\bar{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (12)$$

式中:  $x_i$  为原始数据;  $x_{\max}$  为输入样本的最大值;  $x_{\min}$  为输入样本的最小值;  $\bar{x}_i$  为归一化的数据。

### 2.4 评价指标

本文采用纵向误差指标对光伏点预测模型进行分析, 如式(13)、式(14)。

$$e_{\text{MAPE}} = \left( \sum |p_s - p_y| / p_s \right) / n \quad (13)$$

$$e_{\text{RMSE}} = \sqrt{\left( \sum (p_s - p_y)^2 \right) / n} \quad (14)$$

式中:  $p_s$ 、 $p_y$  为实际功率和预测功率;  $n$  为样本数。

采用区间覆盖率和平均宽度<sup>[23]</sup>作为区间预测的评价指标。平均宽度描述概率性预测结果的波动范围。区间平均宽度的计算公式为

$$\Delta \bar{P} = \left( \sum_{i=1}^n \Delta P_i \right) / n \quad (15)$$

式中:  $\Delta \bar{P}$  为区间平均宽度;  $n$  为样本个数;  $\Delta P_i$  为第  $i$  个估计区间的带宽。

预测区间覆盖率指标反映了实际功率落在预测区间界内的概率。其计算公式为

$$P = \frac{1}{N} \sum_{i=1}^N K^{(i)} \quad (16)$$

式中:  $N$  为预测样本数;  $K$  为布尔量, 当实际功率落入区间内是,  $K$  为 1, 否则为 0。

## 3 算例分析

### 3.1 数据

本文数据来源于浙江某光伏电站, 其总装机容量为 3.6 MW。采用该光伏电站 2017 年 6 月 15 日—2017 年 10 月 31 日每日 05:30—19:00 的 15 min 天气数据和光伏输出功率数据。其中 6 月 15 日—10 月 10 日的数据作为训练数据, 10 月 11 日—10 月 31 日的数据为区间预测测试数据。训练数据中 41 天为晴天、39 天为阴天、37 天为雨天。测试数据中 9 天为晴天、6 天为阴天、7 天为雨天。

### 3.2 模型适用性分析

本文利用 BP、SAPSO-BP 算法对 9 月份中某七天进行确定性预测，预测结果如图 5 所示。

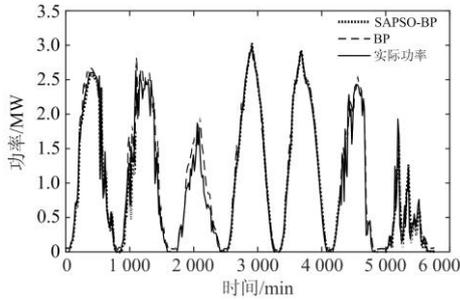


图 5 光伏功率超短期预测曲线

Fig. 5 Forecasting curve of photovoltaic power

图 5 中第 1、2、6 天为阴天；第 3、7 天为雨天；第 4、5 天为晴天，其中晴天和阴天的预测精度更高；雨天的负荷波动性强，其预测精度较低。为具体分析两种预测模型的效果，表 2 以  $e_{MAPE}$ 、 $e_{RMSE}$  指标具体评估该模型的预测能力。从表 2 可看出相同天气条件下 SAPSO-BP 预测效果更好，且相同预测方法下，晴天预测误差最小，雨天预测误差最大，但预测误差在可接受范围内，也验证了该模型的可行性。

表 2 确定性预测结果分析

Table 2 Analysis of deterministic prediction results

日类型	指标	BP	SAPSO-BP
晴天 (15 天)	MAPE	0.101	0.092
	RMSE	0.134	0.103
阴天 (13 天)	MAPE	0.113	0.105
	RMSE	0.152	0.123
雨天 (12 天)	MAPE	0.184	0.143
	RMSE	0.255	0.238

在上述确定性光伏功率预测结果基础上，计算出分位数回归的参数，并构建区间上限和下限的模型，对 10 月 11 日—10 月 31 日测试数据进行区间预测，在给定 90% 和 80% 置信水平下，三种天气类型的典型区间预测结果如图 6—图 9 所示。

由图 6—图 9 可见，SAPSO-BP 和 BP 分位数区间预测总体效果较好，其区间的上下限、功率变化

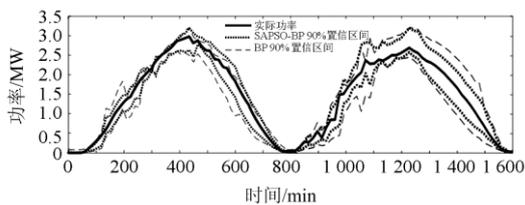


图 6 晴天 90%置信区间

Fig. 6 Confidence interval of 90% when it is sunny

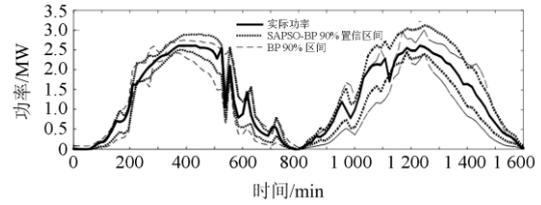


图 7 阴天 90%置信区间

Fig. 7 Confidence interval of 90% when it is overcast

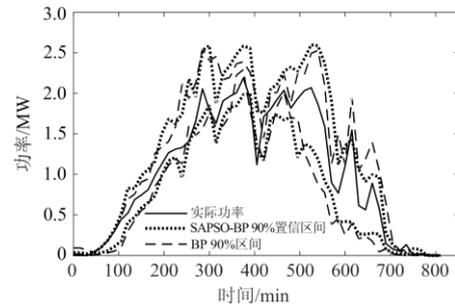


图 8 雨天 90%置信区间

Fig. 8 Confidence interval of 90% when it is rainy

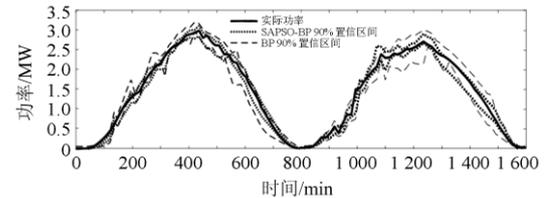


图 9 晴天 80%置信区间

Fig. 9 Confidence interval of 80% when it is sunny

趋势均与和实际功率一致，但不同天气类型下，区间预测的平均宽度相差较大。表 3、表 4 分别为 BP 和 SAPSO-BP 区间预测的评价指标结果。

表 3 BP 区间预测结果分析

Table 3 Analysis of BP interval prediction results

日类型	BP 90%置信度		BP 80%置信度	
	平均宽度	覆盖率	平均宽度	覆盖率
晴天	0.454 3	0.906 0	0.266 1	0.792 5
阴天	0.463 5	0.886 8	0.291 5	0.792 5
雨天	0.606 3	0.868 0	0.409 4	0.773 5

表 4 SAPSO-BP 区间预测结果分析

Table 4 Analysis of SAPSO-BP interval prediction results

日类型	SAPSO-BP 90%置信度		SAPSO-BP 80%置信度	
	平均宽度	覆盖率	平均宽度	覆盖率
晴天	0.387 0	0.924 5	0.220 6	0.811 3
阴天	0.438 1	0.905 6	0.248 9	0.792 4
雨天	0.580 2	0.886 8	0.383 9	0.792 4

由表 3、表 4 可知, 光伏功率区间预测平均宽度随着置信度的增加而增加, 雨天(功率波动较大)的平均宽度和覆盖率指标比晴天和阴天都较差。另外, SAPSO-BP 区间预测较 BP 区间预测指标也更优。总体而言, 当光伏功率输出波动强、受天气等不确定因素影响时, 预测功率波动范围也会发生偏差, 但区间预测结果与置信水平基本一致, 算例结果验证了本文提出模型的可靠性和有效性。与文献[24]中的混合 tLocation-scale 相比, 本文通过不同天气的分析以及利用分位数回归弹性大的方法, 带宽要优于混合 tLocation-scale 同置信度下的带宽, 尤其表现在天气晴朗的情况下。

为了更好地验证本文方法的效果, 我们将分位数回归与正态分布模型进行了对比, 结果如表 5 所示。在雨天(输出功率波动较大)的情况下, 本文提出的模型能更准确地反映出覆盖率, 基于正态分布的区间预测在 90%置信度下的覆盖率仅 0.81, 平均带宽 0.57, 而分位数回归模型覆盖率达 89%, 显然后者能提供更为有效的置信区间, 具有较高的工程实用价值。

表 5 区间预测分析

Table 5 Interval prediction analysis

日类型	分位数回归(90%)		正态分布(90%)	
	平均宽度	覆盖率	平均宽度	覆盖率
晴天	0.387 0	0.924 5	0.420 0	0.912 0
阴天	0.438 1	0.905 6	0.442 0	0.906 0
雨天	0.580 2	0.886 8	0.570 0	0.810 0

## 4 结论

本文提出一种动态粒子群和模拟退火算法结合的优化方法, 优化 BP 神经网络得到最优权值和阈值, 提高光伏功率预测精度。在此光伏确定性预测的基础上, 本文运用分位数回归方法建立了超短期光伏区间预测模型。得到如下结论:

(1) 确定性预测的效果间接影响区间预测模型的预测效果。相对于经典 BP 算法, 本文提出的模拟退火和一种动态 PSO 结合优化的 BP 算法, 在不同的天气类型下能提高其预测精度。

(2) 由于不同天气状况下, 光伏出力的波动情况也不一样, 其预测误差也不同。本文依据满足 t 检验的天气数据作为预测误差的不确定性因素来源, 确定分位数回归模型输入参数, 并提供给定置信度下的预测功率波动范围。

(3) 分位数回归模型无需预设光伏确定性功率预测的概率误差分布, 能准确反映光伏功率误差分布实际情况, 且模型简单, 适用范围较广, 具有更

好的工程意义。

## 参考文献

- [1] 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): 2-14. DING Ming, WANG Weisheng, WANG Xiuli, et al. A review on the effect of large-scale PV generation on power system[J]. Proceedings of the CSEE, 2014, 34(1): 2-14.
- [2] 万昆, 柳瑞禹. 区间时间序列向量自回归模型在短期电力负荷预测中的应用[J]. 电网技术, 2012, 36(11): 77-81. WAN Kun, LIU Ruiyu. Application of interval time-series vector autoregressive model in short-term load forecasting[J]. Power System Technology, 2012, 36(11): 77-81.
- [3] ALMONACID F, RUS C, PEREZ P J, et al. Estimation of the energy of a PV generation using artificial neural network[J]. Renewable Energy, 2009, 34(12): 2743-2750.
- [4] 王新普, 周想凌, 邢杰, 等. 一种基于改进灰色 BP 神经网络组合的光伏出力预测方法[J]. 电力系统保护与控制, 2016, 44(18): 81-87. WANG Xinpu, ZHOU Xiangling, XING Jie, et al. A photovoltaic output prediction method based on improved gray BP neural network combination[J]. Power System Protection and Control, 2016, 44(18): 81-87.
- [5] 黄磊, 舒杰, 姜桂秀, 等. 基于多维时间序列局部支持向量回归的微网光伏发电预测[J]. 电力系统自动化, 2014, 38(5): 19-24. HUANG Lei, SHU Jie, JIANG Guixiu, et al. Photovoltaic generation forecast based on multidimensional time-series and local support vector regression in microgrids[J]. Automation of Electric Power Systems, 2014, 38(5): 19-24.
- [6] 张雨金, 杨凌帆, 葛双治, 等. 基于 Kmeans-SVM 的短期光伏发电功率预测[J]. 电力系统保护与控制, 2018, 46(21): 124-130. ZHANG Yujin, YANG Lingfan, GE Shuangye, et al. Short-term photovoltaic power generation prediction based on Kmeans-SVM[J]. Power System Protection and Control, 2018, 46(21): 124-130.
- [7] 王继东, 宋智林, 冉冉. 基于改进支持向量机算法的光伏发电短期功率滚动预测[J]. 电力系统及其自动化学报, 2016, 28(11): 9-13. WANG Jidong, SONG Zhilin, RAN Ran. Short-term photovoltaic power generation rolling forecast based on optimized SVM[J]. Proceedings of the CSU-EPSA, 2016, 28(11): 9-13.
- [8] 王守相, 张娜. 基于灰色神经网络组合模型的光伏短期出力预测[J]. 电力系统自动化, 2012, 36(19): 37-41. WANG Shouxiang, ZHANG Na. Short-term output power forecast of photovoltaic based on a grey and neural

- network hybrid model[J]. Automation of Electric Power Systems, 2012, 36(19): 37-41.
- [9] 吉铎格, 李慧, 刘思嘉, 等. 基于 MIE-LSTM 的短期光伏功率预测[J]. 电力系统保护与控制, 2020, 48(7): 50-57.  
JI Xinge, LI Hui, LIU Sijia, et al. Short-term photovoltaic power forecasting based on MIE-LSTM[J]. Power System Protection and Control, 2020, 48(7): 50-57.
- [10] 李正明, 梁彩霞, 王满商. 基于 PSO-DBN 神经网络的光伏短期发电出力预测[J]. 电力系统保护与控制, 2020, 48(8): 149-154.  
LI Zhengming, LIANG Caixia, WANG Manshang. Short-term power generation output prediction based on a PSO-DBN neural network[J]. Power System Protection and Control, 2020, 48(8): 149-154.
- [11] 叶瑞丽, 刘建楠, 苗峰显, 等. 风电场风电功率预测误差分析及置信区间估计研究[J]. 陕西电力, 2017, 45(2): 21-25.  
YE Ruili, LIU Jiannan, MIAO Fengxian, et al. Analysis of wind power prediction error and its confidence interval estimation in wind farms[J]. Shaanxi Electric Power, 2017, 45(2): 21-25.
- [12] 王勃, 刘纯, 张俊, 等. 基于 Monte-Carlo 方法的风电功率预测不确定性估计[J]. 高电压技术, 2015, 41(10): 3385-3391.  
WANG Bo, LIU Chun, ZHANG Jun, et al. Uncertainty evaluation of wind power prediction based on Monte-Carlo method[J]. High Voltage Engineering, 2015, 41(10): 3385-3391.
- [13] ZIADI Z, OSHIRO M, SENJYU T. Optimal voltage control using inverters interfaced with PV systems considering forecast error in a distribution system[J]. IEEE Transactions on Sustainable Energy, 2014, 5(2): 682-690.
- [14] 赵唯嘉, 张宁, 康重庆, 等. 光伏发电出力的条件预测误差概率分布估计方法[J]. 电力系统自动化, 2015, 39(16): 8-15.  
ZHAO Weijia, ZHANG Ning, KANG Chongqing, et al. A method of probabilistic distribution estimation of conditional forecast error for photovoltaic power generation[J]. Automation of Electric Power Systems, 2015, 39(16): 8-15.
- [15] CHAI Songjian, NIU Ming, XU Zhao, et al. Nonparametric conditional interval forecasts for PV power generation considering the temporal dependence[C] // 2016 IEEE Power and Energy Society General Meeting, July 17-21, 2016, Boston, MA, USA: 1-5.
- [16] 董雷, 周文萍, 张沛, 等. 基于动态贝叶斯网络的光伏发电短期概率预测[J]. 中国电机工程学报, 2013, 33(增刊 1): 38-45.  
DONG Lei, ZHOU Wenping, ZHANG Pei, et al. Short-term photovoltaic output forecast based on dynamic Bayesian network theory[J]. Proceedings of the CSEE, 2013, 33(S1): 38-45.
- [17] BRACALE A, CARPINELLI G, DE FALCO P. A probabilistic competitive ensemble method for short-term photovoltaic power forecasting[J]. IEEE Transactions on Sustainable Energy, 2017, 8(2): 551-560.
- [18] LI Zhi, YE Lin, ZHAO Yongning, et al. Short-term wind power prediction based on extreme learning machine with error correction[J]. Protection and Control of Modern Power Systems, 2016, 1(1): 9-16. DOI: 10.1186/s41601-016-0016-y.
- [19] WAN Can, LIN Jin, SONG Yonghua, et al. Probabilistic forecasting of photovoltaic generation: an efficient statistical approach[J]. IEEE Transactions on Power Systems, 2017, 32(3): 2471-2472.
- [20] ZHANG Yue, QIN Chuan, SRIVASTAVA K A, et al. Data-driven day-ahead PV estimation using autoencoder-LSTM and persistence model[J]. IEEE Transactions on Industry Applications, 2020, 56(6): 7185-7192.
- [21] 陈建宝, 丁军军. 分位数回归技术综述[J]. 统计与信息论坛, 2008, 23(3): 89-96.  
CHEN Jianbao, DING Junjun. A review of technologies on quantile regression[J]. Statistics & Information Forum, 2008, 23(3): 89-96.
- [22] 袁晓玲, 施俊华, 徐杰彦. 基于 BP 神经网络的光伏发电短期出力预测[J]. 可再生能源, 2013, 31(7): 11-16.  
YUAN Xiaoling, SHI Junhua, XU Jieyan. Short-term power forecast for photovoltaic generation based on BP neural network[J]. Renewable Energy Resources, 2013, 31(7): 11-16.
- [23] 吴问足, 乔颖, 鲁宗相, 等. 风电功率概率预测方法及展望[J]. 电力系统自动化, 2017, 41(18): 167-175.  
WU Wenzu, QIAO Ying, LU Zongxiang, et al. Probabilistic prediction method of wind power and its prospect[J]. Automation of Electric Power Systems, 2017, 41(18): 167-175.
- [24] 杨宇. 基于小波包理论的光伏功率短期概率区间预测研究[D]. 吉林: 东北电力大学, 2020.  
YANG Yu. Research on PV power short-term probability interval forecast based on wavelet packet theory[D]. Jilin: Northeast Electric Power University, 2020.

收稿日期: 2020-07-29; 修回日期: 2020-11-16

作者简介:

贾德香(1971—), 男, 博士, 正高级工程师, 研究方向为能源规划、电力负荷预测; E-mail: 16702324@qq.com

吕千云(1976—), 男, 通信作者, 博士, 教授, 研究方向为电能质量分析和控制, 人工智能技术在电力系统中的应用, 分布式电源接入优化. E-mail: ganyun\_lv@njit.edu.cn

(编辑 葛艳娜)