

DOI: 10.19783/j.cnki.pspc.191064

基于 PFA-MBAS-BP 神经网络模型的光伏发电短期预测

左远龙, 黄玉水, 杨晓辉, 伍惠铨, 刘豪

(南昌大学信息工程学院, 江西 南昌 330031)

摘要: 针对光伏发电短期预测模型的输入变量多且关系复杂、BP 神经网络稳定性差且易陷入局部最优解等问题, 建立了一种基于主因子分析法(PFA)和优化天牛须搜索算法(MBAS)的改进 BP 神经网络光伏发电短期预测模型。该模型首先对光伏历史发电数据和气象数据进行降维简化分析, 利用主因子分析法对影响光伏发电的主要因素进行相关性分析, 选取主因子作为预测模型输入量。然后利用 MBAS 算法的空间寻优搜索, 选取 BP 神经网络训练的最优权值阈值。最后, 利用实测历史数据对不同预测模型进行仿真对比。仿真结果表明, 所建立的改进模型的预测精度可达 92.5%, 图像数据拟合程度高且适用多种天气类型的光伏发电预测。

关键词: BP 神经网络; 主因子分析; 优化天牛须算法; 光伏发电; 短期预测

Short-term prediction of photovoltaic power generation based on a PFA-MBAS-BP neural network model

ZUO Yuanlong, HUANG Yushui, YANG Xiaohui, WU Huicheng, LIU Hao

(School of Information Engineering, Nanchang University, Nanchang 330031, China)

Abstract: A BP neural network has problems associated with having many input variables and complex relationships, and poor stability. It is also easy for it to fall into local optimal solution. Thus an improved BP neural network short-term prediction model for photovoltaic power generation is established, one which combines Principal Factor Analysis (PFA) and Beetle Antennae Search Algorithm Majorization (MBAS). First, the model simplifies the dimension reduction analysis of photovoltaic historical power generation data and meteorological data, and uses the principal factor analysis method to analyze the correlation of the main factors affecting photovoltaic power generation. It chooses the principal factor as the input of the prediction model. Then, the optimal weight threshold of the BP neural network training is selected by using the spatial search of the MBAS algorithm. Finally, the simulation results show that the prediction accuracy of the optimized model can reach 92.5%, the image data has a high degree of fitting and it can be used to forecast photovoltaic power generation in various weather types.

This work is supported by National Natural Science Foundation of China (No. 61563034).

Key words: BP neural network; principal factor analysis; beetle antennae search algorithm majorization; photovoltaic power generation; short-term prediction

0 引言

光伏发电具有很强的波动性和间歇性, 这对光伏发电并网和电网的安全稳定运行会产生诸多不利影响, 如何对光伏发电进行准确预测是亟需解决的问题^[1-4]。

目前国内外专家学者针对光伏发电短期预测方法研究主要有两种: 一种是建立光伏发电系统的间接预测模型^[5-6], 它对气象数据信息要求精细; 另一

种是目前研究较为广泛的直接预测法: 神经网络法、模糊聚类法和回归预测法等^[7-11], 该方法建立在历史发电数据和气象数据的基础上。文献[12]利用 4 种灰色优化模型组合训练输出求得较优权值, 使得改进的 BP 神经网络预测模型在一定程度上提高了预测精度, 但样本选择规律性较强, 不适合离散程度大的样本。在文献[13]中采用相似日搜索算法和模糊聚类法将天气类型进行细分, 利用细分的天气类型对光伏发电进行预测, 但实际中类似天气类型下数据信息可能相差不大, 增加了预测模型的复杂程度; 文献[14]利用统计法对气象和发电数据进行

基金项目: 国家自然科学基金项目资助(61563034)

分析, 建立了 6 种回归光伏预测模型, 预测结果较理想, 但当具有高相关系数的气象因素的变量数量增加时, 预测误差会变大; 文献[15]建立了一种主成分分析法结合遗传算法优化 BP 神经网络的预测模型, 通过主成分分析法选取主成分作为模型输入量, 降低了模型的维数, 但模型考虑的主要影响因素和气象数据较少, 存在一定的试验偶然性。

综合以上分析, 本文建立了一种基于主因子分析法和优化天牛须算法的改进 BP 神经网络光伏发电短期预测模型。该模型基于历史发电量和气象数据, 利用主因子分析法对原始样本降维简化, 选取关键主因子作为新的输入, 同时利用 MBAS 算法搜索寻优, 得到 BP 神经网络的最优权值阈值。通过实测数据仿真验证表明, 与 BP 神经网络预测模型相比, 改进的 PFA-MBAS-BP 模型的训练速度有明显加快, 训练过程中不易陷入局部最优解, 且在多种天气类型下能大幅度提高预测精度和预测结果的拟合程度, 为光伏并网提供了可靠的理论预测基础。

1 光伏发电的主因子分析法

1.1 主因子分析原理

主因子分析法^[16-17]是一种将多元高维数据进行降维、分解简化的统计分析方法。通过对原始变量进行有效的降维处理, 且在该过程中使得原始数据信息丢失最少, 最终分解简化得到较少个数且具有线性关系的主因子和影响很小可略去的特殊因子, 利用主因子最大限度地反映原始变量的信息, 达到降维简化数据的目的。搭建主因子分析的模型如下。

假设研究的问题中有 m 个原始样本, 且包含 p 个因子指标, 则可以建立 $m \times p$ 维的样本矩阵 \mathbf{Y} 。

(1) 对矩阵 \mathbf{Y} 标准化处理, 得到具有同一量纲等级的变量矩阵;

(2) 运用斯皮尔曼相关系数法来计算样本影响因素之间的相关系数 t , 即得到对应的相关系数矩阵 \mathbf{T} , 计算公式为

$$t = \frac{\sum_{j=1}^p (u_j - \bar{u})(v_j - \bar{v})}{\sqrt{\sum_{j=1}^p (u_j - \bar{u})^2 \sum_{j=1}^p (v_j - \bar{v})^2}} \quad (1)$$

$$\mathbf{T} = \begin{bmatrix} 1 & t_{12} & \cdots & t_{1p} \\ t_{21} & 1 & \cdots & t_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ t_{p1} & t_{p2} & \cdots & 1 \end{bmatrix} \quad (2)$$

式中: $\bar{u} = \frac{1}{p} \sum_{j=1}^p u_j$, $\bar{v} = \frac{1}{p} \sum_{j=1}^p v_j$, u_j 和 v_j 分别为对应两个不同影响因素的变量, 且 $t \in [-1, 1]$; 对矩阵 \mathbf{T} 分解化简得到 p 个特征值 λ_j 和标准化后的特征向量矩阵 \mathbf{V}_j (其中, $j=1, 2, \dots, p$), 由特征向量和特征值计算得到对应的因子载荷矩阵 \mathbf{D} 。

$$\mathbf{D} = (\sqrt{\lambda_1 V_1}, \sqrt{\lambda_2 V_2}, \dots, \sqrt{\lambda_p V_p}) \quad (3)$$

(3) 利用式(3)得到的因子载荷矩阵计算各个因子的方差贡献率, 当计算的因子载荷累计方差贡献率 $\sum_{j=1}^n \lambda_j / \sum_{j=1}^p \lambda_j \geq 85\%$ (其中, $n \leq p$) 且对应的特征值 $\lambda_j \geq 1$ 时, 可以得到 n 个主因子; 同时, 为了避免因子载荷相差较小时难以解释因子的实际意义, 利用因子正交旋转法, 使得旋转后的因子载荷趋于 1 或 0, 更容易解释主因子和原始样本之间的紧密联系; 将最终得到的 n 个主因子作为改进 BP 神经网络输入值。

$$\begin{cases} y_1 = d_{11}f_1 + d_{12}f_2 + \cdots + d_{1p}f_p + \varepsilon_1 \\ y_2 = d_{21}f_1 + d_{22}f_2 + \cdots + d_{2p}f_p + \varepsilon_2 \\ \vdots \\ y_m = d_{m1}f_1 + d_{m2}f_2 + \cdots + d_{mp}f_p + \varepsilon_m \end{cases} \quad (4)$$

式中: f_j 为对应的 p 个因子指标; d_{ij} 记为每个样本 y_i 对应的 f_j 上的因子载荷; ε_i 表示特殊因子。其中 $i=1, 2, \dots, m$, $j=1, 2, \dots, p$ 。

1.2 影响光伏发电因素的主因子选取

影响光伏发电的因素很多且它们之间的关系十分复杂, 通过查阅文献[18-22]和对 2013 至 2018 年南昌大学某宿舍楼顶 10 kW 光伏组件历史发电量和气象数据进行分析, 选取历史发电数据 C 与光照幅值 E 、辐射角 θ 、相对湿度 RH 、气温日较差 T_r 、平均气温 \bar{T} 、最高温度 T_{\max} 、最低温度 T_{\min} 共 7 个主要气象因素为原始输入变量。本文选取 2017 年夏季 6 至 8 月间楼顶 10 kW 光伏组件监测系统历史气象数据和发电量数据, 共计 50 组, 对提取的原始数据标准化处理并分析变量间的相关性, 进行主因子分析, 将得到的主因子作为新的模型输入量。

经过标准化处理后, 计算得到各个输入变量的相关系数矩阵如表 1 所示。

由表 1 可以看出各个输入变量之间有密切的相关性, 进一步利用相关系数矩阵进行主因子分析, 主因子分析结果如表 2 所示。

由表 2 可得, 前 2 个主因子特征值 >1 且累计方

差贡献率达到 85.948% > 85%，达到设定理论误差要求；同时，为了更加清晰地反映因子载荷代表的具体意义，通过极大方差正交旋转法对主因子正交旋转，得到旋转前后的因子载荷矩阵变化如表 3 所示。可以明显地看出：正交旋转后在主因子 F_1 中输入量 E 、 θ 、 RH 、 T_r 的因子载荷分别为 0.972、0.938、-0.704、0.869，表明在主因子 F_1 中可以替代变量

E 、 θ 、 RH 、 T_r 代表的实际意义；同理，主因子 F_2 可以反映变量 T_{\max} (0.983)、 T_{\min} (0.976)、 \bar{T} (0.989) 的主要信息。此外为了避免季节类型和天气类型对光伏发电的影响，在影响因素中引入可以间接反映不同天气类型的气温日较差 T_r ($T_r = T_{\max} - T_{\min}$)，确保在短期预测模型的输入量中考虑到了几乎所有的主要影响因素。

表 1 各个输入变量的相关性分析

Table 1 Relevance analysis of input variables

变量	C	E	θ	RH	\bar{T}	T_{\max}	T_{\min}	T_r
C	1	0.89	0.52	-0.39	0.25	0.45	0.10	0.68
E	0.89	1	0.61	-0.32	0.48	0.58	0.39	0.48
θ	0.52	0.61	1	-0.03	0.31	0.46	0.28	0.51
RH	-0.39	-0.32	-0.03	1	0.25	0.14	0.38	-0.34
\bar{T}	0.25	0.48	0.31	0.25	1	0.95	0.95	-0.21
T_{\max}	0.45	0.58	0.46	0.14	0.95	1	0.92	0.11
T_{\min}	0.10	0.39	0.28	0.38	0.95	0.92	1	-0.25
T_r	0.68	0.48	0.51	-0.34	-0.21	0.11	-0.25	1

表 2 各因子主因子分析结果

Table 2 Results of principal factor analysis for each factor

因子序号	特征值	初始因子载荷方差贡献率/%	累计贡献率/%	特征值	旋转后因子载荷方差贡献率/%	累计贡献率/%
1	4.322	48.653	48.653	4.210	46.580	46.580
2	3.358	37.295	85.948	3.560	39.368	85.948
3	0.751	8.298	94.246			
4	0.346	3.845	98.091			
5	0.125	1.189	99.280			
6	0.063	0.668	99.968			
7	0.028	0.320	100.000			

表 3 旋转前后因子载荷变化

Table 3 Variation of factor load before and after rotation

输入变量	未旋转时主因子成分		旋转后主因子成分	
	1	2	F_1	F_2
E	0.732	0.683	0.972	0.092
θ	0.658	0.526	0.938	0.163
RH	-0.684	0.068	-0.704	0.286
\bar{T}	-0.243	0.943	0.063	0.989
T_{\max}	-0.389	0.862	0.041	0.983
T_{\min}	-0.402	0.836	0.156	0.976
T_r	0.832	0.156	0.869	0.227

因此，选取前 2 个主因子作为预测模型新的输入量，这样使得整个输入变量矩阵的空间维数从 7 维降到 2 维，既达到了对数据的降维简化，又最大程度地保留了原始输入变量的具体信息。

2 光伏发电短期预测模型

2.1 光伏发电短期预测模型搭建流程

首先对历史气象和发电数据搜集整理，采用主因子分析法对选取的数据输入变量进行降维简化处理，对影响光伏发电的主要因素进行相关性分析，将得到的 2 个主因子作为优化预测模型的输入量；其次，利用优化天牛须(MBAS)算法对数据训练集进行搜索寻优，得到神经网络的最优初始权值和阈值，并建立光伏发电预测模型；最后将训练数据代入优化的 BP 神经网络中进行预测，输出预测结果，评估优化网络的收敛速度和预测精度。因此改进 BP 神经网络的光伏发电短期预测流程如图 1 所示。

2.2 改进的神经网络模型

目前运用于光伏发电短期预测模型的各类求解算法中，实际应用较为广泛且技术相对成熟的算法是 BP 神经网络^[23]。由于 BP 神经网络算法在初始



图 1 光伏发电优化预测模型搭建流程图

Fig. 1 Flow chart of photovoltaic power generation optimization prediction model

参数选择时存在较强的随机性, 导致算法在训练样本时稳定性较差且极易陷入局部最优解, 求得的最优解与理想最优解存在较大的偏差等缺点。因此, 有必要对传统 BP 神经网络算法进行改进, 以克服 BP 神经网络算法在选取初始参数时存在随机性的问题。

本文将 MBAS 算法与 BP 神经网络相结合, 建立基于 MBAS-BP 神经网络的光伏发电短期预测模型。初始 BAS 算法^[24]是近两年提出的一种新的智能优化算法, 它的基本寻优过程如下: 利用天牛虫的左右两须判别食物气味的强弱, 在整个空间不断搜索寻优, 直至找到食物即最优解为止。通过大量仿真试验表明, 在求解低维空间最优解问题中, BAS 算法较粒子群算法等其他智能算法具有结构简单、运算便捷的优势, 但在求解高维且峰谷值较多的最优问题中, 优化的天牛须算法能有效克服 BAS 算法在局部空间徘徊不定而陷入局部最优解的不足。

因此, MBAS-BP 神经网络模型构建步骤如下。

(1) 选择两组数据完整的训练集, 第一组用于 MABS 算法搜寻网络最优权值阈值, 将求得的最优解代入第二组中, 用于 BP 神经网络优化训练;

(2) MBAS 算法初始参数设定。求解 N 维空间气味函数 g_n 最优解, 选择 10 个个体组成的天牛群开始寻味运动, 在空间任选一个天牛起始质点 z , 天牛左右两须分别为 z_l 和 z_r , 设 z 、 z_l 和 z_r 三者的方向向量均在一条直线上, 记两须间距为 d , 则天牛随机朝向的方向向量记为 d_i , 设定初始步长为 s , 算法迭代次数不超过 200 次。则有:

天牛两须初始间距表示为

$$d = \|(z_l - z_r)\| \quad (5)$$

将天牛朝向的方向向量归一化为单位向量:

$$a = \frac{d_i}{\|d_i\|} \quad (6)$$

则左右两须 z_l 和 z_r 表示为质心的表达式为

$$\begin{cases} z_l = z^i + a \times d^i / 2 \\ z_r = z^i - a \times d^i / 2 \end{cases} \quad (7)$$

式中: z^i 表示第 i 次质点运动的位置; d^i 表示寻味运动到第 i 次时左右须的间距。

(3) 判别函数气味值大小, 确定下一步运动方向。天牛群在运动到下一点时, 随机采集多个方位的函数气味值 g_n , 当比较 5 组左右两须气味值时(避免少量个体运动的随机性差异), 综合判别前进最佳方位, 同时, 对离最佳方位偏差较大的一半个体利用单纯形法^[25]优化调整, 使得整体天牛群选择最佳方向朝前运动。那么假设:

当 $g_l^i < g_r^i$ 时, 则向左移动, 更新质心位置为

$$z^i = z^{i-1} + s^i \times a \times \text{sign}(g_l^i - g_r^i) \quad (8)$$

反之, 则向右移动, 质心位置变为

$$z^i = z^{i-1} - s^i \times a \times \text{sign}(g_l^i - g_r^i) \quad (9)$$

式中: g_l^i 、 g_r^i 分别表示运动至第 i 次左右须对应的函数值; s^i 表示运动至第 i 次天牛的对应步长; sign 为符号函数。

(4) 朝前运动后更新两须间距和步长值。更新运动至第 i 次时天牛两须的间距和对应步长分别为

$$d^i = d^{i-1} \times \text{eta_d} \quad (10)$$

$$s^i = s^{i-1} \times \text{eta_s} \quad (11)$$

式中, eta_d 和 eta_s 分别对应间距衰减系数和步长衰减系数, $0 < \text{eta_d}, \text{eta_s} < 1$, 均取 0.95。

(5) 判别终止迭代条件, 得到最优权值阈值。经过第 $i+1$ 次迭代($i+1 < 100$ 后), 达到终止条件, 输出最优解; 否则, 返回(3)、(4)重复迭代。算法终止迭代条件为

$$|g(z_i) - g(z_{i+1})| \leq 10^{-6} \quad (12)$$

(6) 将利用 MBAS 算法得到的最优权值阈值代入 BP 神经网络中, 对第二个数据集进行训练学习, 选取的主因子作为输入量, 输出层为每个时刻发电量数据, 形成改进光伏发电短期预测模型。

综上所述, MBAS-BP 模型的流程框图如图 2 所示。

基于上述理论分析, 搭建的 PFA-MBAS-BP 神经网络预测模型框图如图 3 所示。

2.3 预测模型的评估

由于太阳光照时长存在周期性和间歇性, 光伏发电输出会出现较多的零值, 为了直观地体现光伏发电模型的预测精度, 使试验结果更有说服力, 采用均方根误差 (RMSE) 和平均绝对百分比误差 (MAPE) 对预测结果进行评估。其计算公式为

均方根误差:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - y_i)^2} \quad (13)$$

平均绝对百分比误差:

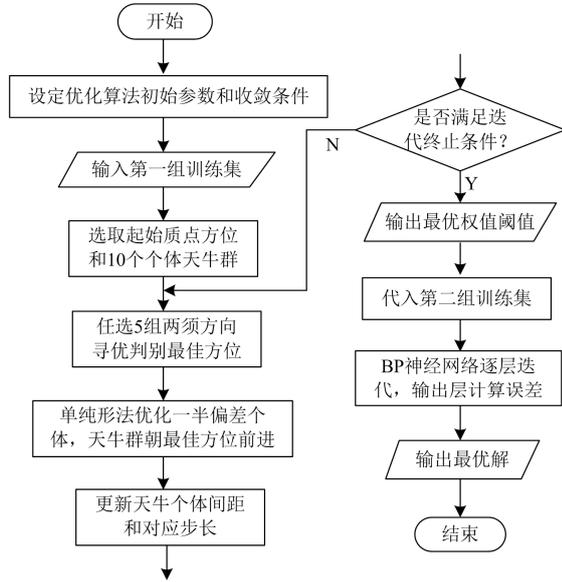


图 2 MBAS-BP 模型的流程框图

Fig. 2 Flow diagram of MBAS-BP model

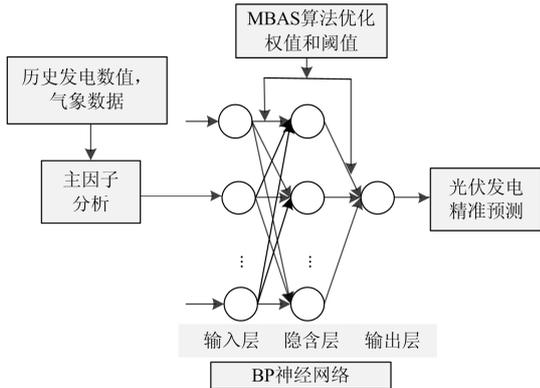


图 3 优化的 MBAS-BP 神经网络预测模型框图

Fig. 3 Optimized block diagram of MBAS-BP neural network prediction model

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{Y_i - y_i}{y_i} \right) \times 100\% \quad (14)$$

式中: n 为数据总数; Y_i 为预测发电值, y_i 为实际发电值, 单位均为 $\text{kW} \cdot \text{h}$ 。

3 预测模型仿真验证分析

利用 2018 年 8 月某几天南昌大学楼顶 10 kW 光伏组件的历史发电量数据和相关天气预报信息来验证本文提出的主因子分析结合 MBAS 的改进 BP 神经网络预测模型在晴天和非晴等突变天气类型下的预测精度。考虑夏季末日照时间普遍集中在 6:00 至 19:00, 其他时刻的光照很弱或趋近于 0, 光伏发电量也趋于 0, 剔除这些无效数据, 设置采样时间间隔为 1 h, 预测未来 1 天(包括晴天、阴天和雨天

3 种天气类型)6:00 至 19:00 共 14 个时刻的光伏发电量。同时, 为了更清楚地论证主因子分析法的降维简化效果和利用 MBAS 算法改进 BP 神经网络模型的预测精度, 构建了如表 4 所示的 4 组对比试验。算法设定的初始参数如下: 天牛群个体总数为 10, 初始步长 $s^0=1$, 衰减系数 $\text{eta}=0.95$, 算法迭代次数不超过 200 次; BP 神经网络中选取 2 个主因子作为输入量, 隐含层神经元个数为 8, 输出层为预测日 6:00~19:00 每个时刻的平均发电量数据。

表 4 预测模型组合

Table 4 Combination of forecasting models

模型	PFA	BP	MBAS-BP
Model1	×	√	×
Model2	√	√	×
Model3	×	×	√
Model4	√	×	√

图 4—图 6 分别是在晴天、阴天和雨天三种天气类型下, 四种不同预测模型每个时刻的光伏发电预测值和实际值的对比曲线图。表 5 是以晴天天气类型为例, 对比不同预测模型的寻优运行时间; 表 6 是不同模型的预测数据评估结果。

以晴天天气类型为例进行分析。由图 4、表 5 和表 6 可得, 对于 Model1 和 Model2(或者 Model3 和 Model4)来说, 采用主因子分析将原始 7 维输入量降到了 2 维, 模型的训练寻优运行时间也明显降低接近一半, 而且预测模型对应的 MAPE 值分别由 15.68%降至 11.32%(由 8.01%降至 4.89%), 预测精度明显提高; 同时, 从 Model1 和 Model3(或者 Model2 和 Model4)比较来看, 它们对应的 RMSE 值分别从 5.897 降至 2.568(从 3.620 降至 0.769), 可以看出通过优化 MBAS 算法求得的最优权值阈值, 大幅提高了 BP 神经网络模型的预测数据的准确度和稳定性, 所得数据离散程度大大降低, 图像的拟合效果更佳。从表 5 和表 6 可以看出, Model4 虽然在寻优运行时间上要高于 Model2, 但其对应的 E_{RMSE} 和 E_{MAPE} 与其他 3 种预测模型相比是最小的, 预测数据的拟合程度要优于其他 3 种模型, 这是因为 Model4 结合了主因子分析法和 MBAS-BP 模型的优势, 寻优运行时间虽有所增加, 但改进模型的预测精度有了很大程度上的提升, 且预测结果数值的离散程度明显降低。

由图 4—图 6 和表 6 可得, 晴天天气类型下的 4 种模型的预测精度和图像拟合度普遍要优于阴天和雨天突变天气类型, 这是由于在阴天和雨天等突变天气类型下, 太阳光照受到大雾、云层遮挡、雨滴和杂质颗粒物等因素影响, 导致太阳光照强度、环

境温度和湿度等有较强的波动变化, 光伏发电也随之产生较大影响, 预测难度大大增加。因此, 在突变天气类型下对光伏发电的精准预测尤为重要, Model4 在阴天和雨天光伏预测对应的 RMSE 值分别为 0.998 和 1.225, MAPE 值分别为 7.04% 和 7.49%, 可见, 预测数值之间的离散程度低且预测

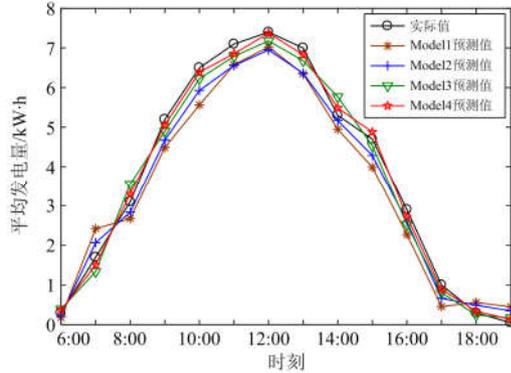


图 4 晴天天气类型下实际值与四种模型预测值对比

Fig. 4 Comparison of actual values and predicted values of four models under sunny weather types

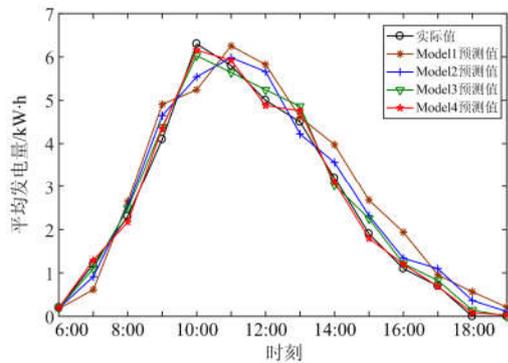


图 5 阴天天气类型下实际值与四种模型预测值对比

Fig. 5 Comparison of actual values and predicted values of four models under cloudy weather types

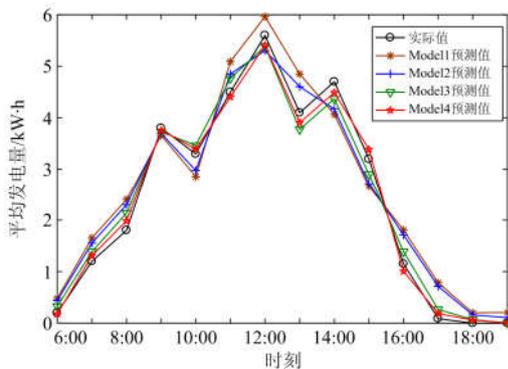


图 6 雨天天气类型下实际值与四种模型预测值对比

Fig. 6 Comparison of actual values and predicted values of four models under rainy weather types

表 5 不同预测模型的寻优运行时间(以晴天为例)

Table 5 Optimal runtime of different forecasting models (for sunny days)

预测模型	Model1	Model2	Model3	Model4
运行时间/s	21.127	10.265	95.984	49.368

表 6 不同天气类型下四种模型预测评估

Table 6 Forecast and evaluation of four models under different weather types

预测日	误差	Model1	Model2	Model3	Model4
晴天	E_{RMSE}	5.897	3.620	2.568	0.796
	E_{MAPE}	15.68%	11.32%	8.01%	4.89%
阴天	E_{RMSE}	8.029	5.361	3.223	0.998
	E_{MAPE}	19.56%	15.82%	9.46%	7.04%
雨天	E_{RMSE}	10.112	6.395	4.561	1.255
	E_{MAPE}	23.21%	17.62%	10.98%	7.49%

精度达到 92.5% 以上, 说明本文构建的 PFA-MBAS-BP 光伏发电预测模型同样适用于突变天气条件下的光伏发电预测。

4 结论

本文建立了一种主因子分析结合 MBAS 算法的改进 BP 神经网络光伏发电短期预测模型, 通过算例仿真分析得出结论如下:

(1) 通过主因子分析法选取的主因子作为模型输入量, 综合考虑了多个影响光伏发电的主要因素, 同时有效地降低了预测模型的空间维数, 最大程度地保留了原有输入量的基本信息, 加快了预测模型的训练时间;

(2) 利用 MBAS 算法对 BP 神经网络的权值阈值进行优化, 在晴天或者非晴天等突变天气类型下, MBAS-BP 光伏发电预测模型寻优运行时间虽有所增加, 但改进模型得到的预测结果在预测精度和预测曲线拟合度上都明显优于 BP 神经网络模型;

(3) 本文搭建的 PFA-MBAS-BP 光伏发电预测模型受天气变化影响较小, 特别在非晴等突变天气类型下, 优化模型的预测精度达到 92.5% 以上, 整体预测数据的拟合程度也很高, 达到理想预期效果。

因此, 本文提出的光伏发电短期预测模型适用的范围广, 具有良好的应用前景。

参考文献

- [1] 刘迎涛, 王翠敏. 光储微电网并网模式协调控制策略[J]. 电力系统及其自动化学报, 2018, 30(1): 127-132.
LIU Yingshu, WANG Cuimin. Coordinated control

- strategy for micro-grid with photovoltaic and energy storage units in grid connected operation[J]. Proceedings of the CSU-EPSC, 2018, 30(1): 127-132.
- [2] WANG J, RAN R, SONG Z, et al. Short-term photovoltaic power generation forecasting based on environmental factors and GA-SVM[J]. Journal of Electrical Engineering & Technology, 2017, 12(1): 64-71.
- [3] DABRA V, PALIWAL K K, SHARMA P, et al. Optimization of photovoltaic power system: a comparative study[J]. Protection and Control of Modern Power Systems, 2017, 2(1): 29-39. DOI: 10.1186/s41601-017-0036-2.
- [4] 黄予春, 曹成涛, 顾海. 基于 IKFCM 与多模态 SSO 优化 SVR 的光伏发电短期预测[J]. 电力系统保护与控制, 2018, 46(24): 102-109.
HUANG Yuchun, CAO Chengtao, GU Hai. Short-term photovoltaic power generation prediction based on IKFCM and multi-mode SSO optimization SVR[J]. Power System Protection and Control, 2018, 46(24): 102-109.
- [5] 杨秋霞, 刘同心, 高辰, 等. 计及光伏电站功率预测的电力系统优化分析[J]. 电力系统保护与控制, 2018, 46(2): 117-123.
YANG Qiuxia, LIU Tongxin, GAO Chen, et al. Power system optimization analysis considering power prediction of PV power station[J]. Power System Protection and Control, 2018, 46(2): 117-123.
- [6] 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.
- [7] 马斌, 张丽艳. 一种基于径向神经网络的短期风电功率直接预测方法[J]. 电力系统保护与控制, 2015, 43(19): 78-82.
MA Bin, ZHANG Liyan. A short-term wind power direct prediction method based on radial basis function neural network[J]. Power System Protection and Control, 2015, 43(19): 78-82.
- [8] 崔洋, 孙银川, 常倬林. 短期太阳能光伏发电预测方法研究进展[J]. 资源科学, 2013, 35(7): 1474-1481.
CUI Yang, SUN Yinchuan, CHANG Nilin. Research progress of short-term solar photovoltaic power generation prediction methods[J]. Resource Science, 2013, 35(7): 1474-1481.
- [9] 于秋玲, 许长清, 李珊, 等. 基于模糊聚类和支持向量机的短期光伏功率预测[J]. 电力系统及其自动化学报, 2016, 28(12): 115-118.
YU Qiuling, XU Changqing, LI Shan, et al. Short-term photovoltaic power prediction based on fuzzy clustering and support vector machine[J]. Proceedings of the CSU-EPSC, 2016, 28(12): 115-118.
- [10] 高阳, 张碧玲, 毛京丽, 等. 基于机器学习的自适应光伏超短期出力预测模型[J]. 电网技术, 2015, 39(2): 307-311.
GAO Yang, ZHANG Biling, MAO Jingli, et al. Machine learning-based adaptive very-short-term forecast model for photovoltaic power[J]. Power System Technology, 2015, 39(2): 307-311.
- [11] 张雨金, 杨凌帆, 葛双冶, 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 forecasting based on Kmeans algorithm and support vector machine[J]. Power System Protection and Control, 2018, 46(21): 124-130.
- [12] 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发电预测方法[J]. 电力系统保护与控制, 2016, 44(18): 81-87.
WANG Xinpu, ZHOU Xiangling, XING Jie, et al. A prediction method of PV output power based on the combination of improved grey back propagation neural network[J]. Power System Protection and Control, 2016, 44(18): 81-87.
- [13] 耿博, 高贞彦, 白恒远, 等. 结合相似日 GA-BP 神经网络的光伏发电预测[J]. 电力系统及其自动化学报, 2017, 29(6): 118-123.
GENG Bo, GAO Zhenyan, BAI Hengyuan, et al. PV generation forecasting combined with similar days and GA-BP neural network[J]. Proceedings of the CSU-EPSC, 2017, 29(6): 118-123.
- [14] GYU G K, JIN H C, SO Y P, et al. Prediction model for PV performance with correlation analysis of environmental variables[J]. IEEE Journal of Photovoltaics, 2019, 9(3): 832-841.
- [15] 许童羽, 马艺铭, 曹英丽, 等. 基于主成分分析和遗传优化 BP 神经网络的光伏输出功率短期预测[J]. 电力系统保护与控制, 2016, 44(22): 90-95.
XU Tongyu, MA Yiming, CAO Yingli, et al. Short term forecasting of photovoltaic output power based on principal component analysis and genetic optimization of BP neural network[J]. Power System Protection and Control, 2016, 44(22): 90-95.
- [16] 李丹, 任洲洋, 颜伟, 等. 基于因子分析和神经网络分

- 位数回归的月度风电功率曲线概率预测[J]. 中国电机工程学报, 2017, 37(18): 5238-5247.
- LI Dan, REN Zhouyang, YAN Wei, et al. Month-ahead wind power curve probabilistic prediction based on factor analysis and quantile regression neural network[J]. Proceedings of the CSEE, 2017, 37(18): 5238-5247.
- [17] 上海电力学院. 一种基于因子分析的并网光伏电站日发电量预测方法: 中国, 201410256545.9[P]. 2014-09-03. Shanghai University of Electric Power. A method for predicting daily power generation of grid-connected photovoltaic power plants based on factor analysis: CN, 201410256545.9[P]. 2014-09-03.
- [18] 初壮, 李钊, 白望望. 计及不确定性和环境因素的多类型分布式电源选址定容[J]. 电力系统保护与控制, 2017, 45(13): 34-41. CHU Zhuang, LI Zhao, BAI Wangwang. Optimal siting and sizing of distributed generations considering uncertainties and environmental factors[J]. Power System Protection and Control, 2017, 45(13): 34-41.
- [19] YUAN X, SHI J, XU J. Short-term power forecasting for photovoltaic generation considering weather type index[J]. Proceedings of the CSEE, 2013, 33(34): 57-64.
- [20] 刘卫亮, 刘长良, 林永君, 等. 计及雾霾影响因素的光伏发电超短期功率预测[J]. 中国电机工程学报, 2018, 38(14): 4086-4095, 4315. LIU Weiliang, LIU Changliang, LIN Yongjun, et al. Super short-term photovoltaic power forecasting considering influence factor of smog[J]. Proceedings of the CSEE, 2018, 38(14): 4086-4095, 4315.
- [21] 晁颖, 金焯, 朱晶亮, 等. 考虑光伏发电出力不确定性的年度最大负荷概率预测[J]. 广东电力, 2018, 31(9): 83-89. CHAO Ying, JIN Ye, ZHU Jingliang, et al. Annual maximum load probability prediction considering uncertainty of photovoltaic power generation output[J]. Guangdong Electric Power, 2018, 31(9): 83-89.
- [22] 李伟, 王冰, 陈献慧, 等. 基于气象因子权重相似日的短期光伏功率预测[J]. 广东电力, 2018, 31(4): 59-64. LI Wei, WANG Bing, CHEN Xianhui, et al. Short term photovoltaic power prediction based on weather factor weight similar days[J]. Guangdong Electric Power, 2018, 31(4): 59-64.
- [23] 姚仲敏, 潘飞, 沈玉会, 等. 基于 GA-BP 和 POS-BP 神经网络的光伏电站出力短期预测[J]. 电力系统保护与控制, 2015, 43(20): 83-89. YAO Zhongmin, PAN Fei, SHEN Yuhui, et al. Short-term output prediction of photovoltaic power stations based on GA-BP and POS-BP neural network[J]. Power System Protection and Control, 2015, 43(20): 83-89.
- [24] 王甜甜, 刘强. 基于 BAS-BP 模型的风暴潮灾害损失预测[J]. 海洋环境科学, 2018, 37(3): 457-463. WANG Tiantian, LIU Qiang. Storm surge disaster loss prediction based on BAS-BP model[J]. Marine Environmental Science, 2018, 37(3): 457-463.
- [25] WEI C, YING Y C, SHI C, et al. Simplex search-based brain storm optimization[J]. IEEE Access, 2018, 209(6): 75997-76006.

收稿日期: 2019-09-02; 修回日期: 2019-10-18

作者简介:

左远龙(1995—), 男, 硕士研究生, 主要研究方向为光伏发电短期预测算法等; E-mail: 1659694432@qq.com

黄玉水(1969—), 男, 博士, 教授, 主要研究方向为电力电子技术运用及新能源发电技术。E-mail: huangyushui@ncu.edu.cn

(编辑 魏小丽)