

DOI:10.12158/j.2096-3203.2021.05.013

基于典型气象周的 GRNN 光伏发电量预测模型

卞海红, 孙健硕

(江苏省主动配电网重点建设实验室(南京工程学院), 江苏 南京 211167)

摘要: 由于光伏发电量具有波动性,且现有的光伏发电量预测技术存在气象因素考虑不全面、特征提取不充分等问题,为提高光伏发电量预测精度,文中提出一种改进的典型气象年方法(TMY Method)生成典型气象年数据,并结合广义回归神经网络(GRNN)进行光伏发电量预测。首先,选择6种历史气象指标,利用Finkelstein-Schafer统计方法选择典型气象周,并生成典型气象年数据;然后,使用因子分析法对会影响光伏发电量的气象指标进行筛选,对筛选出的气象指标和日光伏发电量进行标准化处理后,将其作为GRNN模型的初始输入量,得到预测日的光伏发电量;最后,利用江苏省南京市的历史气象数据及日发电量数据对所设计的模型进行训练和预测。结果表明,与标准TMY Method-GRNN预测方法相比,文中所提预测方法有较好的预测性能。

关键词: 典型气象年;广义回归神经网络(GRNN);改进的典型气象年方法(TMY Method);因子分析法;光伏发电量预测;气象指标

中图分类号:TM615

文献标志码:A

文章编号:2096-3203(2021)05-0094-06

0 引言

我国光伏资源十分丰富。随着光伏产业规模的不断扩大,为了改善环境,实现可持续发展,提高光伏能源利用率,研究精确度更高的光伏发电量预测技术已成为未来趋势^[1-3]。如今,基于历史运行数据和历史气象数据相结合的光伏发电量预测模型应用广泛,其中天气因素对光伏系统及光伏发电预测影响最大,所以在进行光伏发电量预测时,构建特定地区典型气象年数据非常重要^[4-7]。

文献[8]选取中国南海地区7个数据较完整的气象观测点,通过3种方法构建典型气象年数据,综合分析比较3种生成结果,发现The Festa-Ratto Method是生成中国南海地区典型气象年的适用算法。文献[9]通过构建中国不同气候区域的35个代表性城市的典型气象年数据,分析对比3种典型气象年的生成方法,提出了一种混合典型气象年构建方法,提高了在不同气候区域形成典型年数据的精确度。文献[10]通过皮尔逊相关系数和灰色关联分析选取最佳相似日,将最佳相似日中相关气象参数和光伏输出功率作为广义回归神经网络(general regression neural network, GRNN)模型的输入参数,预测出各个时刻的输出功率,解决了天气类型改变时预测精度下降的问题。

针对上述文献未考虑典型气象周数据与历史长期平均数据之间误差关系的缺点,文中利用改进的平均绝对百分比误差(mean absolute percentage

error, MAPE)方法,构建改进典型气象年方法(typical meteorological year method, TMY Method)下的典型气象年数据,使用因子分析法(factor analysis, FA)筛选气象指标进行标准化处理,结合GRNN预测模型进行日光伏发电量预测。文中选取江苏省南京市2000年—2015年历史气象数据和日光伏发电量数据进行算例分析,验证模型的预测精度。

1 典型气象年算法研究

典型气象年通常是由历年气象数据中选择出的12个典型气象月组合成一个“虚拟年”^[11]。构建典型气象年的常用方法有:The Danish Method^[12], The Festa-Ratto Method^[13]和TMY Method等。

TMY Method最早由美国的Sandia National Laboratories提出,主要通过Finkelstein-Schafer^[14]统计方法来选取和确定典型气象年数据。

为提高基于改进TMY Method-GRNN的光伏发电预测模型的预测精度,文中针对标准TMY Method进行以下改进:

(1)文中介绍的光伏发电量预测模型是为了提高短期光伏发电量预测精度。相较于按月度划分,对历年气象数据按照一周7d进行划分可以提高模型的预测精度,因此文中选择从历年气象数据中选取52个典型气象周组合构成一个“虚拟年”。

(2)为了使构建出的典型气象年数据与长期气候数据有较高的拟合度,采用计算候选周数据与历史长期平均数据间MAPE值的方法选取典型气象周,构建改进TMY Method下的典型气象年。

在历史气象指标中,由于日太阳总辐射、日最高

收稿日期:2021-04-17;修回日期:2021-06-21

基金项目:江苏省重点研发计划资助项目(BE2020688)

大气干球温度、日平均大气干球温度、日最低大气干球温度、日平均风速和日平均大气相对湿度对光伏系统和光伏发电量预测的影响最大,所以选取上述 6 种气象指标作为形成典型气象年的历史气象数据。

1.1 标准 TMY Method

首先针对历年每周短期与长期的累积分布函数进行分析比较^[15]。累积分布函数计算如下:

$$T_n(s) = \begin{cases} 0 & s < s_1 \\ (i - 0.5)/n & s_i \leq s < s_{i+1} \\ 1 & s \geq s_n \end{cases} \quad (1)$$

式中: $T_n(s)$ 为气象指标 s 的累积分布函数值; n 为气象指标 s 的总个数; $i = 1, 2, 3, \dots, n-1$ 。

各个参数指标的 Finkelstein-Schafer 统计值计算如下^[16]:

$$F_s(y, w) = \frac{1}{N} \sum_{i=1}^N |L_w(s_i) - L_{y,w}(s_i)| \quad (2)$$

式中: $F_s(y, w)$ 为气象指标 s 的第 y 年第 w 周统计值; $L_w(s_i)$ 为气象指标 s 的各周历年长期累积分布函数值; $L_{y,w}(s_i)$ 为气象指标 s 的各周第 y 年短期累积分布函数值; N 为一周的总天数,取 7。

根据 6 种历史气象指标的 $F(y, w)$ 值进行综合统计,计算得出加权统计值,加权统计值最小的周被选取为标准 TMY Method 下的典型气象周。加权统计值的计算如下:

$$C(y, w) = \frac{1}{M} \sum_{s=1}^M [W_s F_s(y, w)] \quad (3)$$

$$\sum_{s=1}^M W_s = 1 \quad (4)$$

式中: $C(y, w)$ 为第 y 年第 w 周的加权统计值; W_s 为气象指标 s 的权重系数;气象指标个数 M 为 6。

考虑到空间尺度对于光伏发电功率有一定影响,文中使用位于亚热带(区域年积温为 4 500 ~ 8 000 °C)的江苏省南京市的历史气候数据,且构建的典型气象年数据主要用于光伏发电量的预测。因此,给日太阳总辐射这一气象指标设定较高的权重系数,大小为 50/100,即 0.5^[15]。文中选用的 6 种气象指标的权重系数经过仿真检验表明在中国亚热带城市效果较好。具体权重系数见表 1^[20]。

1.2 改进 TMY Method

在标准 TMY Method 下生成典型气象周的过程中,未考虑典型气象周数据与历史长期平均数据之间的误差。为了使构建出的典型气象年数据与长期气候数据的分布规律类似且有较高的拟合度,文中提出相应的改进方法。

将计算得出的各周加权统计值按照升序排列,

表 1 气象指标的权重系数

Table 1 Weight coefficients of meteorological parameters

气象指标	权重系数大小	
空气温度	日最高大气干球温度	5/100
	日平均大气干球温度	30/100
	日最低大气干球温度	5/100
湿度	日平均相对湿度	5/100
风速	日平均风速	5/100
太阳辐射	日太阳总辐射	50/100

选取加权统计值最小的 3 个周作为候选周。

日太阳总辐射是光伏发电量预测中最为关键的因素,因此计算候选周日太阳总辐射与历史长期平均数据间的 MAPE 值,选取 MAPE 值最小的候选周作为改进 TMY Method 下的典型气象周。MAPE 值的计算如下:

$$M_w = \frac{1}{N} \sum_{d=1}^N \left(\left| \frac{K_{y,w,d} - K_w}{K_w} \right| \times 100 \right) \quad (5)$$

式中: M_w 为第 w 周太阳总辐射的 MAPE 值; $K_{y,w,d}$ 为第 y 年第 w 周第 d 日的日太阳总辐射; K_w 为第 w 周的日太阳总辐射量历年的均值。

将获得的 52 个典型气象周组合起来构建成在改进 TMY Method 下的典型气象年。

2 GRNN 模型

GRNN 是一种非线性回归的前馈式神经网络^[16]。通常是由输入层、模式层、求和层和输出层构成。GRNN 算法在运算速度与学习能力上比径向基函数神经网络(radial basis function, RBF)、反向传播神经网络(back propagation, BP)更强,广泛应用于系统辨识、预测、控制等领域中^[17-18]。

GRNN 网络模型如图 1 所示,含有四部分:




图 1 GRNN 模型

Fig.1 Model of GRNN

(1) 输入层。输入层作用是将样本数据传送到模式层且不运行计算,输入向量的维数为 m 。文中通过 FA 法确定在南京地区使用该模型时输入向量的维数 $m = 7$, 7 种数据分别为平均大气干球温度、最高大气干球温度、最低大气干球温度、平均相对湿度、平均风速、日太阳总辐射和日光伏发电量。

输入向量为:

$$\mathbf{X} = [x_1, x_2, \dots, x_m] \quad (6)$$

(2) 模式层。模式层中含有的神经元数目和学习样本的数目相同,均为 n , 神经元 i 的传递函数为:

$$T_i = e^{-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2}} \quad i = 1, 2, \dots, n \quad (7)$$

式中: X_i 为神经元 i 所对应的学习样本; σ 为平滑参数, 将平滑参数 σ 代入神经网络训练过程, 以 $\Delta\sigma$ 的间距在 $[\sigma_{\min}, \sigma_{\max}]$ 寻取最优平滑参数。

(3) 求和层。求和层含有 2 种类型的神经元, 分别表示如下:

$$S_D = \sum_{i=1}^n T_i \quad (8)$$

$$S_N = \sum_{i=1}^n (Y_i T_i) \quad (9)$$

式中: Y_i 为第 i 个样本观测值。

(4) 输出层。在输出层进行如下计算:

$$Y = S_N / S_D \quad (10)$$

式中: Y 为具有最大概率的输出变量。

3 算例结果与分析

3.1 历史气象数据和历史发电量数据来源

文中使用的气象数据为 2000 年—2015 年江苏省南京市某气象观测站点的实测气象数据, 选取平均大气干球温度、最高大气干球温度、最低大气干球温度、平均相对湿度、平均风速和日太阳总辐射 6 种气象指标作为构建典型气象年的历史气象数据。文中使用的历史发电数据为 2000 年—2015 年江苏省南京市某分布式光伏电站的日光伏发电量。

3.2 评价指标

文中选用相对误差 (relative error, RE) 和均方根误差 (root mean squared error, RMSE) 评价基于改进 TMY Method-GRNN 的光伏发电预测模型的预测效果。RE 和 RMSE 的计算如下^[19-21]:

$$E_{RE} = \frac{X - Y}{X} \times 100\% \quad (11)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2} \quad (12)$$

式中: X 为实际测量的日光伏发电总量; Y 为预测的日光伏发电总量; X_i, Y_i 分别为元素个数为 i 时实测和预测的日光伏发电总量; n 为测试样本中的元素个数。

3.3 典型气象年数据对比

根据上文介绍的 TMY Method 算法, 文中建立标准和改进 TMY Method 下的典型气象年模型, 对生成的典型气象年数据进行对比分析。

由于篇幅原因, 文中只展示典型气象周第 25~30 周的选取结果, 结果如表 2、表 3 所示。

表 2 南京地区第 25~30 周典型周 (标准 TMY Method)

Table 2 Typical meteorological week 25~30 in Nanjing area (using the original TMY Method)

周数	选择年份	周数	选择年份
第 25 周	2013	第 28 周	2006
第 26 周	2007	第 29 周	2013
第 27 周	2004	第 30 周	2005

表 3 南京地区第 25~30 周典型周 (改进 TMY Method)

Table 3 Typical meteorological week 25~30 in Nanjing area (using the optimized TMY Method)

周数	年份	$\delta_{MAPE}/\%$	周数	年份	$\delta_{MAPE}/\%$
第 25 周	2004	35.63	第 28 周	2000	32.54
	2014	28.69		2014	26.88
	2007	23.49		2008	16.74
第 26 周	2006	33.97	第 29 周	2014	27.31
	2013	24.32		2007	25.75
	2012	26.89		2008	13.90
第 27 周	2009	19.41	第 30 周	2001	12.62
	2015	26.19		2004	14.65
	2015	26.19		2002	8.65

对比典型气象周的周平均数据与 2000 年—2015 年长期周平均数据, 选择日太阳总辐射和平均大气干球温度 2 种关键气象指标进行展示, 具体对比如图 2、图 3 所示。




图 2 典型周日平均太阳总辐射值对比

Fig.2 Comparison of the average solar radiation values on a typical week

分析图 2 和图 3 可知: 改进 TMY Method 较标准 TMY Method 在典型气象年数据中的日太阳总辐射和平均大气干球温度 2 种关键气象指标上和长期平均数据之间误差较小。

3.4 基于改进 TMY Method-GRNN 的光伏发电预测模型

3.4.1 选择输入的气象指标

使用统计学中常用的 FA 法对光伏发电量和典

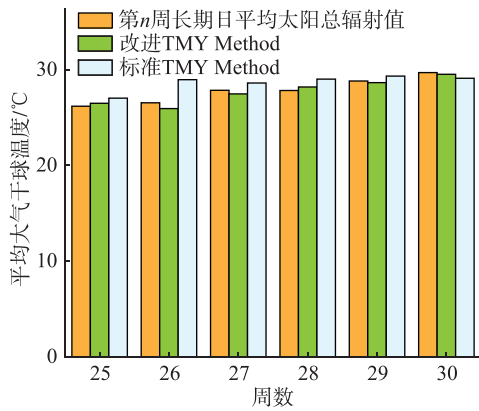


图3 典型周日平均大气干球温度对比

Fig.3 Comparison of average atmospheric dry bulb temperature on a typical week

型年数据中的6种气象指标进行相关性分析。选取因子载荷矩阵中绝对值超过0.8的气象指标作为预测模型的数据输入。因子载荷矩阵如表4所示。

表4 因子载荷矩阵

Table 4 Correlation coefficient of factor analysis

参数	温度因子	辐射因子	大气密度因子
平均大气干球温度	0.971	0.349	-0.103
最高大气干球温度	0.964	0.457	-0.141
最低大气干球温度	0.942	0.246	-0.171
平均相对湿度	0.432	0.253	0.862
平均风速	0.324	0.111	0.808
日太阳总辐射	0.444	0.982	-0.052

分析表4可知典型年数据中6种气象指标都和光伏发电量有较高相关性,所以文中选取典型气象年数据中全部6种气象指标作为预测模型的输入。

3.4.2 数据预处理

根据上文FA法结果,文中使用标准和改进TMY Method典型气象年中的6种气象指标,结合日光伏发电量作为GRNN光伏发电量预测模型的输入数据。由于输入数据间单位不一致,因此需对数据进行标准化处理,具体如下:

$$b'_i = \frac{b_i - b_{i,\min}}{b_{i,\max} - b_{i,\min}} \quad i = 1, 2, 3, \dots, 7 \quad (13)$$

式中: b_i 为指标*i*的实际数据; $b_{i,\max}$, $b_{i,\min}$ 分别为指标*i*的最大、最小值。

3.4.3 样本选择

(1) 训练样本的选择。文中选取预测日前7日典型气象年数据中6种气象指标数据和日光伏发电量作为训练样本输入,预测日光伏发电预测量作为训练样本输出。采用改进TMY Method典型气象年中第1~299天的相关数据对预测模型进行训练。

(2) 测试样本的选择。测试样本的输入、输出

与训练样本类似。采用改进TMY Method典型气象年中第300~364天的数据对预测模型进行测试。

3.5 算例结果分析

为了验证基于改进TMY Method-GRNN的光伏发电量预测模型性能,将改进和标准TMY Method下光伏发电预测量与日光伏发电量分别进行对比,计算RE值和RMSE值。标准和改进TMY Method下光伏发电预测量与日实测光伏发电量对比如图4所示。标准和改进TMY Method下光伏发电预测量相对误差对比如图5所示。

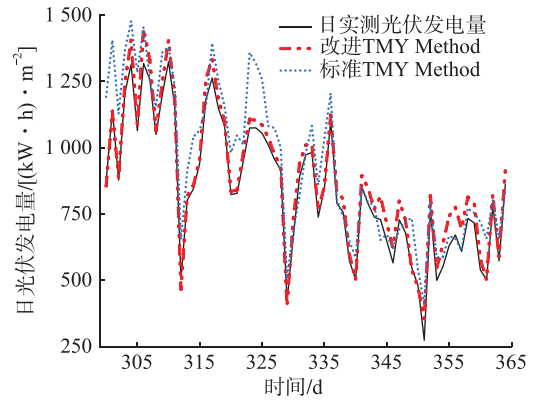


图4 改进和标准TMY Method下光伏发电预测量与日光伏发电量对比

Fig.4 Comparison of forecasted photovoltaic power generation and daily photovoltaic power generation under optimized and original TMY Method

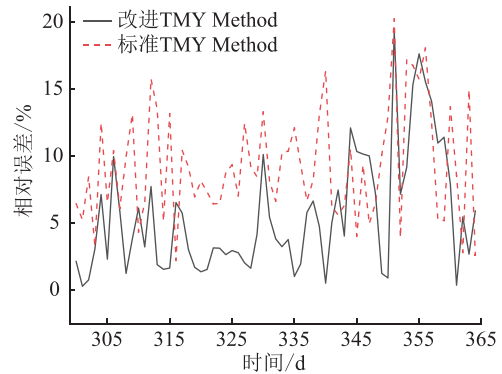


图5 标准和改进TMY Method下光伏发电预测量相对误差对比

Fig.5 Comparison of relative errors of forecasted photovoltaic power generation under the original and optimized TMY Method

分析图4和图5可知:标准与改进TMY Method-GRNN光伏发电预测模型输出的光伏发电预测值和日光伏发电实际值之间曲线趋势相同且数值接近,使用改进TMY Method比使用标准TMY Method预测效果更佳。在与日光伏发电实际值进行对比时,使用改进TMY Method下光伏发电预测量比使用标准TMY Method下光伏发电预测量的相

对误差更小。

通过计算比较可得:使用标准 TMY Method-GRNN 模型输出的光伏发电预测量与日光伏发电量之间 RMSE 为 $12.73 (\text{kW} \cdot \text{h})/\text{m}^2$;使用改进 TMY Method-GRNN 模型输出的光伏发电预测量与日光伏发电量之间 RMSE 为 $5.28 (\text{kW} \cdot \text{h})/\text{m}^2$ 。改进 TMY Method-GRNN 预测模型的预测均方根误差小,预测准确度高。

4 结论

文中介绍了使用 TMY Method 生成典型气象年的具体方法,并针对光伏发电量预测方向进行改进,提出了基于改进 TMY Method-GRNN 的光伏发电预测模型。

选取对光伏发电预测影响最大的 6 种历史气象指标,生成在标准和改进 TMY Method 下的典型气象年数据,并与长期平均数据进行对比分析。将标准和改进 TMY Method 下生成的典型气象年数据中 6 种气象指标和日光伏发电量作为 GRNN 的输入数据,得到预测日光伏发电量,进行对比分析后得到以下结论:

(1) 标准和改进 TMY Method 的典型气象年数据中日太阳总辐射和平均大气干球温度都与长期平均数据十分接近,其中改进 TMY Method 下典型气象年数据与长期平均数据更接近。

(2) 基于改进 TMY Method-GRNN 的光伏发电预测模型输出的预测值与日光伏发电量实际值的曲线趋势相同且数值接近。改进 TMY Method-GRNN 预测模型与标准 TMY Method-GRNN 预测模型相比,其预测准确度更高,预测效果更佳。

本文得到 2020 年江苏省研究生科研创新项目(SJ CX20_0718),2019 年度南京工程学院校级科研基金(CKJB201904)资助,谨此致谢!

参考文献:

[1] 杨茂,朱亮. 基于非参数估计的光伏功率短期预测误差分析[J]. 电网与清洁能源,2020,36(5):107-114.
YANG Mao, ZHU Liang. Error analysis of photovoltaic power short-term prediction based on non-parametric estimation[J]. Power System and Clean Energy, 2020, 36(5):107-114.

[2] 李科,李秋燕,张艺涵,等. 基于模糊信息粒化的电力系统中光伏出力预测模型分析[J]. 电网与清洁能源,2020,36(5):115-120.
LI Ke, LI Qiuyan, ZHANG Yihan, et al. Prediction model analysis of photovoltaic output in power system based on fuzzy information granulation[J]. Power System and Clean Energy, 2020, 36(5):115-120.

[3] 王军辉,李民,畅蓬博,等. 基于相似日误差校正的光伏功率

预测[J]. 电网与清洁能源,2020,36(11):134-138.
WANG Junhui, LI Min, CHANG Pengbo, et al. Photovoltaic power prediction based on similar day error correction[J]. Power System and Clean Energy, 2020, 36(11):134-138.

[4] 吴建中. 欧洲综合能源系统发展的驱动与现状[J]. 电力系统自动化,2016,40(5):1-7.
WU Jianzhong. Drivers and state-of-the-art of integrated energy systems in Europe[J]. Automation of Electric Power Systems, 2016, 40(5):1-7.

[5] 王昕,黄柯,郑益慧,等. 基于萤火虫算法-广义回归神经网络的光伏发电功率组合预测[J]. 电网技术,2017,41(2):455-461.
WANG Xin, HUANG Ke, ZHENG Yihui, et al. Combined PV power forecast based on firefly algorithm-generalized regression neural network[J]. Power System Technology, 2017, 41(2):455-461.

[6] 荆博,谭伦农,钱政,等. 光伏发电短期预测研究进展综述[J]. 电测与仪表,2017,54(12):1-6.
JING Bo, TAN Lunnong, QIAN Zheng, et al. An overview of research progress of short-term photovoltaic forecasts[J]. Electrical Measurement & Instrumentation, 2017, 54(12):1-6.

[7] ZANG H X, XU Q S, BIAN H H. Generation of typical solar radiation data for different climates of China[J]. Energy, 2012, 38(1):236-248.

[8] 王华. 南海地区典型气象年生成方法对比研究[D]. 西安:西安建筑科技大学,2018.
WANG Hua. Study on typical meteorological year generation method in South China sea[D]. Xi'an: Xi'an University of Architecture and Technology, 2018.

[9] ZANG H X, WANG M M, HUANG J, et al. A hybrid method for generation of typical meteorological years for different climates of China[J]. Energies, 2016, 9(12):1094.

[10] 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.
PENG Zhouning, LIN Peijie, LAI Yunfeng, et al. Short-term power prediction for photovoltaic power plants based on hybrid grey relational analysis-generalized regression neural network[J]. Electrical Engineering, 2019, 20(10):11-18.

[11] TAO Q H, LI Z R, JIANG F J, et al. An improved method for generating typical meteorological years used in building energy simulation in China[J]. Journal of Harbin Institute of Technology, 2014, 21(1):17-24.


[12] HASSAN K M Z. Comparative evaluation among various robust estimation methods in deformation analysis[J]. Spatial Information Research, 2016, 24(4):485-492.

[13] GARCÍA I, TORRES J L. Temporal downscaling of test reference years: effects on the long-term evaluation of photovoltaic systems[J]. Renewable Energy, 2018, 122:392-405.

[14] YILMAZ S, EKMEKCI I. The generation of typical meteorological year and climatic database of Turkey for the energy analysis of buildings[J]. Journal of Environmental Science and Engi-

- neering A, 2017, 6(7):370-376.
- [15] 臧海祥. 实用目标下光伏发电规划关键基础研究[D]. 南京:东南大学, 2014.
ZANG Haixiang. Key basic researches of photovoltaic planning with practical principle [D]. Nanjing: Southeast University, 2014.
- [16] 李明骏. 基于遗传算法优化的广义回归神经网络在 GPS 高程转换中的应用[D]. 重庆:重庆交通大学, 2014.
LI Mingjun. Application of generalized regression neural network optimized based on genetic algorithm in GPS height conversion [D]. Chongqing: Chongqing Jiaotong University, 2014.
- [17] 商永婕. 基于改进的广义回归神经网络短期光伏发电功率预测[D]. 南京:南京邮电大学, 2018.
SHANG Yongjie. Study on photovoltaic power short-term forecast based on improved GRNN [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2018.
- [18] 李金拓. 计及雾霾影响的光伏发电功率短期预测方法研究 [D]. 北京:华北电力大学, 2018.
LI Jintuo. Study on short-term forecasting method of PV power generation with influence of fog and haze [D]. Beijing: North China Electric Power University, 2018.
- [19] 宋人杰, 刘福盛, 马冬梅, 等. 基于相似日和 WNN 的光伏发电功率超短期预测模型[J]. 电测与仪表, 2017, 54(7): 75-80.
SONG Renjie, LIU Fusheng, MA Dongmei, et al. A very short-term prediction model for photovoltaic power based on similar days and wavelet neural network [J]. Electrical Measurement & Instrumentation, 2017, 54(7): 75-80.
- [20] 周海, 李登宣, 尹万思, 等. 基于极限学习机的光伏发电短期预测校正方法[J]. 电网与清洁能源, 2020, 36(6): 64-69, 77.
ZHOU Hai, LI Dengxuan, YIN Wansi, et al. Short-term forecasting correction method of photovoltaic power based on extreme learning machine [J]. Power System and Clean Energy, 2020, 36(6): 64-69, 77.
- [21] 刘家庆, 张弘鹏, 郭希海, 等. 基于 SVR 残差修正的光伏发电功率预测模型[J]. 电力工程技术, 2020, 39(5): 146-151.
LIU Jiaqing, ZHANG Hongpeng, GUO Xihai, et al. Prediction model of photovoltaic power generation based on SVR residual correction [J]. Electric Power Engineering Technology, 2020, 39(5): 146-151.

作者简介:



卞海红

卞海红(1979),女,博士,副教授,研究方向为新能源发电技术及用户侧资源调度(E-mail: bhh_njit@126.com);

孙健硕(1996),男,硕士在读,研究方向为新能源发电技术。

Photovoltaic power generation prediction model based on optimized TMY Method-GRNN

BIAN Haihong, SUN Jianshuo

(Jiangsu Key Laboratory of Active Distribution Network (Nanjing Institute of Technology), Nanjing 211167, China)

Abstract: Due to the volatility of photovoltaic power generation, the existing photovoltaic power generation prediction technology has problems such as incomplete consideration of meteorological factors and insufficient feature extraction. In order to improve the accuracy of photovoltaic power generation prediction, an improved typical meteorological year method (TMY Method) is proposed to generate typical meteorological year data, and this method is combined with the generalized regression neural network (GRNN) to predict photovoltaic power generation. First of all, six kinds of historical meteorological indicators are selected, and Finkelstein-Schafer statistical method is used to select typical meteorological week and generate typical meteorological year data. Then, the factor analysis method is used to filter out the meteorological indicators that affect the photovoltaic power generation, and the selected meteorological indicators and daily photovoltaic power generation are standardized as the initial input of the GRNN model to obtain the predicted daily photovoltaic power generation. Finally, the designed model is trained and predicted by historical weather data and daily power generation data from Nanjing, Jiangsu Province. The results show that the prediction method proposed in this paper has better prediction accuracy than the original TMY-GRNN prediction method dose.

Keywords: typical meteorological year; generalized regression neural network (GRNN); improved typical meteorological year method (TMY Method); factor analysis; photovoltaic power generation prediction; meteorological indicators

(编辑 方晶)