

考虑气象因素的短期光伏出力预测的奇异谱分析方法

黎静华, 赖昌伟

(广西大学 广西电力系统最优化与节能技术重点实验室, 广西 南宁 530004)

摘要:在传统奇异谱分析(SSA)方法的基础上,提出一种嵌入气象因素的改进 SSA 方法,该方法融合了 SSA、相关性分析和灵敏度分析等技术,可有效提高传统 SSA 方法的预测精度。采用 SSA 技术将光伏出力时间序列分解为低频序列、高频序列和噪声序列,通过 Pearson 相关系数法确定温度和辐照为影响光伏出力的主要气象因素,再对光伏出力与气象因素之间的灵敏度进行分析。根据灵敏度分析的结果和基准值分别对待预测日的低频序列和高频序列进行修正,将修正结果进行叠加得到光伏出力预测结果。将所提方法运用于某地区的光伏短期预测中,与自回归模型、BP 神经网络及传统的奇异谱分析-回归方法的对比结果表明,所提方法具有更高的预测精度。

关键词:奇异谱分析;气象因素;相关性分析;灵敏度分析;短期光伏出力预测

中图分类号:TM 615

文献标识码:A

DOI:10.16081/j.issn.1006-6047.2018.05.007

0 引言

随着大规模光伏电站的入网,光伏出力固有的随机性和波动特性给电网的安全稳定和经济运行带来了挑战^[1-2]。准确的光伏出力预测可为调度决策提供依据,对降低系统备用和运行成本、保证系统的安全稳定与经济运行具有重要意义^[3-4]。

近年来,不少学者对短期光伏出力预测进行了研究,并取得了一些成果。短期光伏出力预测的方法主要分为物理方法、统计类方法以及上述方法的组合方法 3 类^[5-7]。

a. 物理方法是根据光伏组件所在的详细地理位置和光电转换效率等因素建立物理模型,依据光伏系统的发电原理直接将气象数据作为输入进行预测。其有效性取决于对研究对象内在结构及其遵循规律的把握程度和模型参数的精度,该方法涉及环节多,过程复杂,参数求解困难^[7-8]。

b. 统计类方法是利用某种统计方法对历史光伏出力数据进行分析,寻找数据中的内在规律并用于预测。统计类方法包括时间序列法、回归分析法、灰色预测法以及元启发式系列方法等。如文献[9]基于马尔科夫链提出一种直接预测光伏电站出力的方法,该方法避免了对光伏系统逆变模型的具体建模及光照数据的采集和转换,但其对复杂天气条件的辨识性较差。文献[10]提出了一种考虑气象因素的自回归移动平均时间序列 ARMAX (Auto-Regressive Moving Average eXogenous) 广义模型,与传

统自回归综合移动平均 ARIMA (Auto-Regressive Integrated Moving Average) 相比,ARMAX 对气象因素的依赖性不高,但其预测精度不高。文献[11]采用灰色系统对神经网络预测模型进行修正,该方法较 BP 神经网络 (Back Propagation neural network) 有更好的逼近拟合能力,但是整体预测精度不高。

元启发式方法的本质是对生物的作息规律进行模拟,采用某种算法对样本数据进行训练而得到预测条件与待预测量之间的关系。元启发式方法主要包括神经网络、支持向量机、遗传算法等。如文献[12]采用地基云图径向基函数人工神经网络对超短期光伏出力进行预测,该模型能够较好地实现对出力“突变”的预测,但需要大量详细的气象数据,其实现较为复杂。文献[13]提出针对气象专业天气类型进行归纳合并,并给出分类预测框架,然后建立基于支持向量机的天气状态模式识别,但未考虑不同样本数据分布情况的适应性和分类预测模型总数的限制。文献[14]采用支持向量机的方法,但其输入端只有温度,未考虑其他气象因素的影响,因此不具有普适性。

c. 组合方法利用不同模型提供的信息并发挥各自优势,选择合适的方式进行组合,以期提高预测效果。如文献[15]提出了基于近邻传播聚类 and 回声状态网络的组合算法,该方法能够满足非突变型天气的要求,但是在突变型天气的预测精度有待提高。文献[16]采用包含基于集合经验模态分解法的组合预测法,该方法能够以自适应的方式提取信号的分量及变化趋势,能够有效提高预测精度,但是实际操作较为困难。

上述文献为研究光伏出力预测提供了很好的参考,但均未从光伏出力序列分解预测的角度进行研究,而奇异谱分析 SSA (Singular Spectrum Analysis) 方法通过分解和重构能够获取光伏出力不同序列的

收稿日期:2017-12-14; **修回日期:**2018-03-20

基金项目:国家重点研发计划支持项目(2016YFB0900100);
国家自然科学基金资助项目(51377027)

Project supported by the National Key R&D Plan of China (2016YFB0900100) and the National Natural Science Foundation of China(51377027)

特性,有利于对不同序列的辨识和处理。文献[17]采用SSA方法和支持向量机对短期负荷进行了预测,但该文仅通过奇异值分解SVD(Singular Value Decomposition)提取了序列的部分特征,且未考虑气象因素的影响,使得预测精度不高。文献[18]采用SSA方法将金融时间序列分解成低频序列和高频序列两部分,采用回归方法进行了预测,由于该文是对金融序列进行预测,未剔除对预测有干扰作用的噪声序列,不完全适用于光伏序列的预测,并且采用的回归模型难以准确考虑气象因素。

为更好地挖掘光伏出力序列的特性和分析气象因素对光伏出力的影响,提高光伏出力的预测精度。本文提出一种考虑气象因素的短期光伏出力预测的奇异谱分析方法SSA-MF(Singular Spectrum Analysis method considering Meteorological Factors)。该方法采用SSA技术,能够挖掘光伏出力不同序列的特性,获得原始序列隐含的部分信息,并剔除了序列中对预测有干扰作用的噪声序列;建模时考虑了对光伏出力影响较大的气象因素,可以更好地把握光伏出力的变化趋势,提高短期光伏出力的预测精度。通过与自回归模型AR(AutoRegressive model)、BP神经网络和不考虑气象因素的SSA方法SSA-AR(Singular Spectrum Analysis method based on AutoRegressive)的预测结果进行对比分析,验证了本文所提方法的有效性。

1 SSA方法

SSA是一种用于时间序列分析和预测的技术,对信号进行SVD可以得到原始信号的趋势特性、周期特性以及噪声特性等,有利于对原始信号的分析^[18]。目前,SSA技术已被广泛应用于气象、环境及金融等研究领域,其分析效果显著。图1为SSA技术流程图,其主要包括分解和重构2个阶段。SSA分解是先将原始时间序列转化为一个矩阵形式,再利用SVD得到与该矩阵等价的 d 个子矩阵。SSA重构是先将SVD后的 d 个子矩阵划分为低频/高

频/噪声矩阵,再对其对角平均化得到低频/高频/噪声序列。

1.1 SSA分解

SSA分解方法的基本思想是将原始时间序列变换成一个矩阵形式,再将该矩阵分解为与之等价的多个子矩阵之和。SSA分解主要分为嵌入操作和SVD 2个步骤。

a. 嵌入操作。

嵌入操作是将长度为 $N(N>2)$ 的原始一维时序光伏出力 $P=(P_1, P_2, \dots, P_N)$ 转化为多维时序光伏出力矩阵 $Z=[Z_1, Z_2, \dots, Z_K]$ 的一种映射操作,即:

$$P=(P_1, P_2, \dots, P_N) \rightarrow Z=[Z_1, Z_2, \dots, Z_K] \quad (1)$$

其中, $Z_i(i=1, 2, \dots, K)$ 为矩阵 Z 的某一列, $Z_i=(P_i, P_{i+1}, \dots, P_{i+L-1})^T \in \mathbf{R}^L$, L 为嵌入维数($2 \leq L \leq N$), $K=N-L+1$ 。通常, L 的选取不宜超过整个序列长度的1/3。称矩阵 Z 为轨迹矩阵,即:

$$Z=[Z_1, Z_2, \dots, Z_K]=\begin{pmatrix} P_1 & P_2 & P_3 & \dots & P_K \\ P_2 & P_3 & P_4 & \dots & P_{K+1} \\ \vdots & \vdots & \vdots & & \vdots \\ P_L & P_{L+1} & P_{L+2} & \dots & P_N \end{pmatrix} \quad (2)$$

至此,完成一维光伏出力序列向多维光伏出力矩阵的转换。

b. SVD。

SVD将式(2)的轨迹矩阵 Z 分解为 d 个子矩阵 $\bar{Z}_1, \bar{Z}_2, \dots, \bar{Z}_d$, d 为矩阵 Z 的秩,并使得 d 个子矩阵之和等于矩阵 Z ,即:

$$Z=\bar{Z}_1+\bar{Z}_2+\dots+\bar{Z}_d \quad (3)$$

根据文献[18], $\bar{Z}_j(j=1, 2, \dots, d)$ 按式(4)计算:

$$\bar{Z}_j=\sqrt{\lambda_j}U_jV_j^T \quad j=1, 2, \dots, d \quad (4)$$

其中, $\lambda_1, \lambda_2, \dots, \lambda_L(\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L \geq 0)$ 为 $S=ZZ^T$ 的特征值; $U_1, U_2, \dots, U_L$ 为矩阵 S 的正交特征向量。

V_j 可由式(5)计算得到:

$$V_j=Z^T U_j / \sqrt{\lambda_j} \quad j=1, 2, \dots, d \quad (5)$$

其中, U_j 和 V_j 分别为轨迹矩阵 Z 的左、右特征向量, $\sqrt{\lambda_j}(j=1, 2, \dots, d)$ 为轨迹矩阵 Z 的奇异值,集合 $\{\sqrt{\lambda_j}\}$ 为矩阵 Z 的奇异谱, $U_j, V_j, \sqrt{\lambda_j}$ 共同形成一个特征环 $(U_j, V_j, \sqrt{\lambda_j})$ 。

至此,完成SVD,得到矩阵 Z 的奇异谱所对应的 d 个子矩阵。

1.2 SSA重构

SSA重构是先将SVD得到的 d 个子矩阵 $\bar{Z}_j(j=1, 2, \dots, d)$ 进行分组,得到低频/高频/噪声矩阵,分别记为 $Z_{\text{low}}, Z_{\text{high}}$ 和 Z_{noise} ;再将低频/高频/噪声矩阵




图1 SSA技术流程图

Fig.1 Flowchart of singular spectrum analysis technology

分别对角平均化转化为序列,即低频率序列 P_l 、高频率序列 P_h 和噪声序列 P_s 。SSA 重构主要包括分组和对角平均化 2 个步骤。

a. 分组。

根据矩阵 Z 的 $r(0 \leq r \leq d)$ 个奇异值之和对矩阵 Z 的贡献率 η ,以及奇异值发生较大跳跃的情况进行分组,贡献率由式(6)计算得到。例如,矩阵 $H(H=ZZ^T)$ 的 d 个奇异值满足如下条件: $\lambda_1 > \lambda_2 > \dots > \lambda_\omega > \lambda_{\omega+1} > \dots > \lambda_k > \lambda_{k+1} > \dots > \lambda_{d-1} > \lambda_d$, η_{low0} 和 η_{high0} 为设定的低频/高频矩阵的奇异值对矩阵 Z 的贡献率的阈值。当出现 $\lambda_{\omega+1}$ 远小于 λ_ω 且 $\eta \geq \eta_{low0}$ 时, λ_j ($j=1, 2, \dots, \omega$) 所对应的矩阵 Z_j 视为低频子矩阵;当出现 λ_{k+1} 远小于 λ_k 且 $\eta \geq \eta_{high0}$ 的情况时, λ_j ($j=\omega+1, \omega+2, \dots, k$) 所对应的矩阵 Z_j 视为高频子矩阵; λ_j ($j=k+1, k+2, \dots, d$) 所对应的矩阵 Z_j 视为噪声子矩阵,通常噪声子矩阵的奇异值所对应的贡献率较小可忽略不计,具体分组视实际情况而定。将式(3)得到的 d 个子矩阵分成低频/高频/噪声矩阵,形如式(7)所示。

$$\eta = \sum_{j=1}^r \lambda_j / \sum_{j=1}^d \lambda_j \quad (6)$$

$$Z = \underbrace{\bar{Z}_1 + \bar{Z}_2 + \dots + \bar{Z}_\omega}_{\text{低频矩阵}} + \underbrace{\bar{Z}_{\omega+1} + \bar{Z}_{\omega+2} + \dots + \bar{Z}_k}_{\text{高频矩阵}} + \underbrace{\bar{Z}_{k+1} + \bar{Z}_{k+2} + \dots + \bar{Z}_d}_{\text{噪声矩阵}} \quad (7)$$

b. 对角平均化。

进一步将步骤 a 分组确定的低频/高频/噪声矩阵变换成长度为 N 的低频/高频/噪声序列,下面以高频矩阵 Z_{high} 为例对此过程进行说明。

假定 Z_{high} 为 $a \times b$ 维的矩阵, Z_{ij} 为 Z_{high} 的任一元素,记 $a^* = \min(a, b)$, $b^* = \max(a, b)$, $N = a + b - 1$,且当 $a < b$ 时,令 $Z_{ij}^* = Z_{ij}$,否则,令 $Z_{ij}^* = Z_{ji}^{[18]}$ 。上述分组矩阵所对应的重构序列 $R_c = (r_{c1}, r_{c2}, \dots, r_{cN})$ 可由下式计算得到:

$$r_{cn} = \begin{cases} \frac{1}{n} \sum_{m=1}^n Z_{m, n-m+1}^* & 1 \leq n \leq a^* \\ \frac{1}{a^*} \sum_{m=1}^{a^*} Z_{m, n-m+1}^* & a^* \leq n \leq b^* \\ \frac{1}{N-n+1} \sum_{m=n-b^*+1}^{a^*} Z_{m, n-m+1}^* & b^* \leq n \leq N \end{cases} \quad (8)$$

由式(8)即可得到高频率序列 P_h ,同理可求得低频率序列 P_l 及噪声序列 P_s 。

2 SSA-MF

2.1 SSA-MF 的基本思想

通过第 1 节的分解可以得到低频率序列、高频率

列及噪声序列。由于噪声序列是由特征值占比很小的子矩阵重构而成,对原始数据的影响不大,考虑将噪声序列剔除。因此,本文重点对低频率序列和高频率序列进行预测。

SSA-MF 基本思想如图 2 所示。改进 SSA 方法在传统 SSA 方法的基础上考虑了气象因素,分别建立了低频/高频率序列预测模型,得到低频/高频率序列的预测值之后,按照式(9)进行叠加,即可得到光伏出力的预测值。

$$P = P_{low} + P_{high} \quad (9)$$

其中, P_{low} 、 P_{high} 分别为低频率序列、高频率序列预测值。




图 2 SSA-MF 思路图

Fig.2 Flowchart of SSA-MF

与传统的 SSA 方法相比,所提方法在预测模型中增加考虑了气象因素,下面介绍低频、高频率序列的具体预测过程。

2.2 考虑气象因素的预测过程

首先,通过对光伏出力原始序列与不同气象因素之间的相关性分析,确定影响光伏出力变化的主要气象因素;然后,对光伏出力原始序列与选定的主要气象因素之间进行灵敏度分析;接着,以参照日光伏出力低频/高频率序列作为待预测日低频/高频率序列的基准值;最后,根据灵敏度分析的结果和基准值,分别对低频率序列和高频率序列进行建模预测。具体预测过程如下。

(1) 对光伏出力时间序列和不同气象因素进行相关性分析。本文采用 Pearson 相关系数法^[19],对温度、辐照、风速、降雨量等不同气象因素进行研究,根据相关系数的大小确定影响光伏出力的主要气象因素,假设确定的主要气象因素为温度和辐照。

(2) 文献[20]分析主要气象因素对光伏出力变化的灵敏度,并将单位长度的气象因素值区间所对应的灵敏度确定为气象灵敏度。其中,光伏出力对气象因素的灵敏度指的是单位气象因素变化量下光伏出力的变化量。

(3) 考虑到对低频/高频率序列建模预测的步骤相同,以下以高频率序列的建模预测过程为例进行说明。

a. 选取高频率序列的参照日和基准值,以距离待预测日最近且天气类型相似的历史日作为高频率序列

参照日,并以参照日的光伏出力高频率序列作为待预测日高频率序列的基准值。

b. 以温度和辐照与光伏出力之间的 Pearson 相关系数 α_1 和 α_2 分别作为主要气象因素影响光伏出力变化的权重系数。

c. 根据气象因素对光伏出力变化的灵敏度、待预测日与参照日的温差和辐照差,按照式(10)对光伏出力高频率序列 P_{high} 进行修正。

$$P_{\text{high}} = P'_{\text{high}} + \alpha_1 \Delta P_1 + \alpha_2 \Delta P_2 \quad (10)$$

其中, P_{high} 、 P'_{high} 、 ΔP_1 和 ΔP_2 分别为待预测日的光伏出力高频率序列、参照日的光伏出力高频率序列、因温度变化引起的光伏出力高频率序列变化量以及因辐照变化引起的光伏出力高频率序列变化量; α_1 和 α_2 分别为温度和辐照影响光伏出力高频率序列变化的权重系数。

从式(10)可以看出,修正的量包括 ΔP_1 和 ΔP_2 ,本文采用下列公式计算两者的取值。

ΔP_1 的取值如下。

a. 当待预测日温度与参照日温度处于同一温度区间(设定的温度区间范围内)时:

$$\Delta P_1 = S_i(t - t') \quad (11)$$

b. 当待预测日温度与参照日温度处于2个不同的温度区间时,如以2个相邻区间为例,则:

$$\Delta P_1 = S'_i(\bar{t} - t') + S_i(t - \bar{t}) \quad (12)$$

其中, t 和 t' 分别为待预测日温度与参照日温度值; S_i 和 S'_i 分别为待预测日温度与参照日温度各自所在区间对应的灵敏度; $\bar{t}$ 为2个区间公共端点的温度值。

ΔP_2 的取值如下。

a. 当待预测日辐照与参照日辐照处于同一辐照区间(设定的辐照区间范围内)时:

$$\Delta P_2 = S_i(l - l') \quad (13)$$

b. 当待预测日辐照与参照日辐照处于2个不同的辐照区间时,如以2个相邻区间为例,则:

$$\Delta P_2 = S'_i(\bar{l} - l') + S_i(l - \bar{l}) \quad (14)$$

其中, l 和 l' 分别为待预测日辐照与参照日辐照值; S_i 和 S'_i 分别为待预测日辐照与参照日辐照各自所在区间对应的灵敏度; $\bar{l}$ 为2个区间公共端点的辐照值。

至此,完成了式(10)所示光伏出力高频率序列的修正。

3 算例分析

本文以全球能源预测竞赛中1号电站2013年5月1日至2014年4月30日的光伏出力、温度、辐照、风速、降雨量及2014年5月1日至6月30日的

温度、辐照等数据,采用 SSA-MF 提前一天对2014年5月1日至6月30日期间晴天、阴天、雨天和多云天气各10d的光伏出力进行预测。为验证本文方法的有效性,本节采用 AR、BP 神经网络和 SSA-AR 方法对光伏出力进行了预测,与考虑气象因素后的奇异谱分析预测进行了对比,其中 BP 神经网络考虑了气象因素,SSA-AR 的具体步骤见文献[18]。考虑到夜间无光照,所以在算例中展示了06:00—18:00的出力预测结果。

采用平均绝对误差百分比(MAPE)、均方根(RMSE)和均方根误差(ERMSE)对预测效果进行评价,其计算式分别如下:

$$V_{\text{MAPE}} = \frac{1}{M} \sum_{i=1}^M \frac{|X_i - \bar{X}_i|}{\bar{X}_i} \quad (15)$$

$$V_{\text{RMSE}} = \sqrt{\frac{1}{M} \sum_{i=1}^M (X_i - \bar{X}_i)^2} \quad (16)$$

$$V_{\text{ERMSE}} = \sqrt{\frac{1}{M} \sum_{i=1}^M \left(\frac{X_i - \bar{X}_i}{\bar{X}_i} \right)^2} \quad (17)$$

其中, M 为预测点个数; $\bar{X}_i$ 为实际值; X_i 为预测值。

3.1 SSA 方法的分解结果

利用 SSA 技术将2013年5月1日至2014年4月30日期间8760个样本值所构成的光伏出力序列分解,得到低频率序列、高频率序列和噪声序列。算例中,设定嵌入维数 L 为2500,根据式(2)将光伏出力序列排列成轨迹矩阵,采用 SVD 得到2500个递减排列的奇异值。通过式(6)计算得到低频率序列、高频率序列和噪声序列的奇异值的贡献率分别为0.883、0.108和0.009,对应的奇异值分别为第1~15个、第16~1000个和第1001~2500个。通过式(7)计算得到低频矩阵 Z_{low} ,利用式(8)计算其对应的重构序列,得到低频序列。同样的方法得到高频率序列和噪声序列。

图3为2014年4月份原始光伏出力序列经 SSA 技术分解后的序列。由图可知,光伏出力原始序列(图3(a))具有很强的间歇性和波动性,经 SSA 技术分解得到的低频序列(图3(b))有一定的周期性,高频率序列(图3(c))也有较强的波动性,但相较于原始序列而言其波动幅度有所降低,噪声序列(图3(d))无明显规律且其矩阵对应特征值的贡献率较小(0.009),对预测结果的影响不大,在预测中不予考虑。

3.2 传统 SSA-AR 预测结果分析

不考虑气象因素时,采用传统 SSA-AR 对光伏出力进行预测,图4为5月12日光伏出力预测结果。图4(a)中低频序列的预测曲线和实际曲线几乎重合,表明预测效果很好,这是因为低频序列均由




图 3 2014 年 4 月份光伏出力分解序列

Fig.3 Decomposition sequence of photovoltaic output in April 2014

特征值较大的子序列构成,该部分序列累加后有一定的周期性(图 3(b)),在预测时根据这一周期性可较精确地把握未来的变化趋势,有助于保证低频序列的预测精度。而图 4(b)中光伏出力高频率序列的预测效果则较低频序列差,这是因为高频率序列的预测样本本身不具有周期性(图 3(c)),且构成高频率序列的子序列对应的特征值变化较大,难以把握其变化趋势。

将低频和高频序列预测结果相叠加得到该日光伏出力预测曲线图 4(c)。由图知,出力预测值与实际值较接近,但对 07:00—09:00 和 16:00—17:00 的光伏出力预测效果较差。原因是早上和下午温度和辐照等气象因素易发生较大变化,而 SSA-AR 预测方法仅采用历史数据,未考虑气象条件,难以预测气象变化较大时刻光伏出力。可见,若想提高短期光伏出力预测精度,仅采用历史光伏出力进行预测难以达到理想预测效果,还需结合气象等因素进行预测。

3.3 SSA-MF 预测结果分析

3.3.1 相关性及灵敏度分析结果

a. 从第 2 节中,首先计算温度、辐照、风速、降雨量等不同气象与光伏出力的 Pearson 相关系数,其计算结果分别为 0.664 1、0.437 0、0.223 2 和 -0.120 0,




图 4 5 月 12 日光伏出力实际数据与预测数据曲线(SSA-AR)

Fig.4 Actual data and forecasting data curves of photovoltaic output on May 12(SSA-AR)

说明温度和辐照强度对光伏出力的影响程度最大。因此,本文在预测中主要考虑温度和辐照气象因素。

b. 对光伏出力与温度和辐照强度 2 种气象因素进行灵敏度分析,求得不同气温/辐照区间内光伏出力对气温/辐照变化的灵敏度,计算结果见附录中表 A1、A2。

3.3.2 预测结果分析

根据第 2 节中 SSA-MF 的步骤,得到考虑主要气象因素(温度和辐照强度)下的短期光伏出力预测结果。图 5 为考虑气象因素时 5 月 12 日光伏出力预测结果。可见,当考虑气象因素后,光伏出力低频和高频序列都能较好地接近实际值,说明考虑气象因素后能很好地把握序列未来的变化趋势。

图 4(a)和图 5(a)均为低频序列的预测结果,相比较而言,图 4(a)的预测效果比图 5(a)理想。而图 5(b)对高频率序列的预测效果明显优于图 4(b)。从图 5 来看,对于低频序列,考虑气象因素之后,该子序列的预测精度不一定会提高,这是因为低频序列主要反映原序列中规律性较强的部分,曲线的趋势性较强。低频序列受气象因素的影响不大,考虑气象因素有可能扰乱了低频序列的规律性,不利于低频序列的预测。而高频率序列主要反映原序列中的




图5 5月12日光伏出力实际数据与预测数据曲线(SSA-MF)

Fig.5 Actual data and forecasting data curves of photovoltaic output on May 12(SSA-MF)

变化部分,曲线的趋势性较弱,考虑气象因素可以更好地跟踪曲线的变化趋势,有利于提高高频率序列的预测效果。

3.4 不同方法下光伏出力的预测效果定量对比分析

为了更进一步说明本文所提 SSA-MF 的有效性,本节与 AR 法、BP 神经网络和 SSA-AR 对光伏出力的预测精度进行对比,并按照晴天、阴天、雨天、多云 4 种不同天气类型,以 MAPE、RMSE 和 ERMSE 这 3 种指标(式(15)~(17))对 AR、BP 神经网络、SSA-AR 和 SSA-MF 的预测效果进行评价。

图 6 分别为 SSA-MF、SSA-AR、AR 和 BP 神经网络 4 种方法对晴天、阴天、雨天和多云 4 种不同天气类型下光伏出力的预测曲线。下面分别以 6 月 26 日、5 月 21 日、5 月 1 日和 6 月 22 日为例进行说明。

由图可知,预测精度的比较为晴天>阴天>雨天>多云。可以看出,各种方法对晴天的预测效果均较为理想,其中 SSA-MF 的预测精度最高(MAPE、RMSE 和 ERMSE 分别为 4.6%、0.063 MW、7.9%),BP 神经网络次之,SSA-AR 更次,AR 的预测精度最低(MAPE、RMSE 和 ERMSE 分别为 7.4%、0.10 MW、12.5%)。对于阴天而言,SSA-MF 与 BP 神经网络的预测效果较好且相差不大,SSA-AR 的预测效果稍




图6 不同天气类型下各种方法的光伏出力预测曲线

Fig.6 Forecasting curves of photovoltaic output for different methods under different weather types

差,AR 的预测效果最差(MAPE、RMSE 和 ERMSE 分别为 15.8%、0.136 MW、17.0%)。雨天中,各方法的预测精度较晴天和阴天均有所降低,预测效果如下:SSA-MF 最佳、BP 神经网络次之、SSA-AR 和 AR 预测水平较差且相差不大。对于多云天气,各方法的预测水平较其他 3 类天气均明显下降,预测效果最好的为 SSA-MF(MAPE、RMSE 和 ERMSE 分别为 15.1%、0.165 MW、20.6%),其次是 BP 神经网络,SSA-AR 更次,AR 效果最差(MAPE、RMSE 和 ERMSE 分别为 19.3%、0.239 MW、29.8%)。根据上述分析可知,SSA-MF 较其他 3 种预测方法具有一定的优势。

表 1 为 AR、BP 神经网络、SSA-MF 和 SSA-AR 4

表 1 不同天气类型下各种方法的预测误差比较

Table 1 Comparison of forecasting errors among different methods under different weather types

天气类型	日期	AR			BP 神经网络			SSA-AR			SSA-MF		
		MAPE/ %	RMSE/ MW	ERMSE/ %	MAPE/ %	RMSE/ MW	ERMSE/ %	MAPE/ %	RMSE/ MW	ERMSE/ %	MAPE/ %	RMSE/ MW	ERMSE/ %
晴天	5月2日	0.076	0.087	0.109	0.073	0.087	0.109	0.081	0.089	0.111	0.052	0.068	0.086
	5月12日	0.099	0.133	0.166	0.078	0.089	0.111	0.082	0.103	0.129	0.066	0.077	0.097
	5月28日	0.091	0.117	0.146	0.081	0.087	0.109	0.054	0.067	0.084	0.051	0.063	0.079
	平均值	0.089	0.112	0.140	0.078	0.088	0.110	0.072	0.087	0.108	0.057	0.070	0.087
阴天	5月11日	0.166	0.127	0.159	0.146	0.151	0.188	0.149	0.125	0.156	0.128	0.102	0.128
	5月16日	0.153	0.122	0.153	0.161	0.154	0.193	0.150	0.127	0.159	0.117	0.125	0.157
	6月5日	0.167	0.138	0.173	0.132	0.137	0.172	0.141	0.131	0.164	0.131	0.123	0.154
	平均值	0.162	0.129	0.161	0.146	0.147	0.184	0.146	0.128	0.160	0.125	0.117	0.146
雨天	5月5日	0.139	0.122	0.152	0.147	0.181	0.227	0.126	0.107	0.134	0.130	0.133	0.166
	5月9日	0.196	0.198	0.247	0.148	0.139	0.174	0.204	0.203	0.254	0.134	0.124	0.155
	6月14日	0.183	0.128	0.159	0.194	0.153	0.191	0.151	0.153	0.191	0.140	0.133	0.166
	平均值	0.173	0.149	0.186	0.163	0.158	0.197	0.160	0.155	0.193	0.135	0.130	0.162
多云	5月3日	0.228	0.182	0.227	0.208	0.206	0.257	0.204	0.147	0.184	0.161	0.156	0.195
	5月20日	0.170	0.184	0.230	0.211	0.121	0.151	0.189	0.213	0.266	0.147	0.144	0.180
	5月26日	0.179	0.103	0.129	0.149	0.126	0.158	0.221	0.220	0.275	0.145	0.163	0.203
	平均值	0.192	0.156	0.195	0.189	0.151	0.189	0.204	0.193	0.242	0.151	0.154	0.193

种方法的预测偏差,鉴于篇幅,此处分晴天、阴天、雨天和多云 4 种天气类型各给出了 3 d 的误差统计结果,完整的光伏出力预测误差统计结果见附录中表 A3。表 1 中 4 种天气情况下 SSA-MF 的预测误差均小于其他 3 种方法的预测误差,SSA-MF 对晴天预测的 MAPE、RMSE 和 ERMSE 分别为 5.7%、0.070 MW 和 8.7%,对多云天气预测的 MAPE、RMSE 和 ERMSE 分别为 15.1%、0.154 MW 和 19.3%。

表 2 为不同天气类型下各种方法分别预测 10 d 的误差平均值。整体上,各种方法对晴天的预测水平最高,其次是阴天、雨天和多云。根据表 2 数据可知:晴天中,SSA-MF 的预测水平最佳,其次是 BP 神

络预测水平相当,其次为 AR 法。雨天中,4 种方法的预测精度由 SSA-MF、SSA-AR、BP 神经网络、AR 依次降低。多云天,4 种方法的预测水平较晴天、阴天和雨天均明显降低,但与 AR、BP 神经网络和 SSA-AR 相比,SSA-MF 预测精度具有显著优势(SSA-MF 的 MAPE 较 AR、BP 神经网络和 SSA-AR 分别提高 23.53%、17.82%和 18.29%)。可见,在 4 种天气情况下,SSA-MF 的预测效果均显著优于 AR、BP 神经网络、SSA-MF 3 种方法。

表 3 为所有预测日 MAPE、RMSE 和 ERMSE 的平均值,可见,与 AR、BP 神经网络和 SSA-AR 相比,本文所提 SSA-MF 的预测具有明显优势。

表 2 不同天气类型下各种方法的预测误差平均值

Table 2 Average forecasting error of different methods under different weather types

天气类型	方法	MAPE/%	RMSE/MW	ERMSE/%
晴天	AR	0.090	0.110	0.137
	BP 神经网络	0.085	0.095	0.118
	SSA-AR	0.086	0.104	0.130
	SSA-MF	0.068	0.082	0.102
阴天	AR	0.145	0.137	0.171
	BP 神经网络	0.137	0.142	0.177
	SSA-AR	0.139	0.137	0.172
	SSA-MF	0.124	0.119	0.149
雨天	AR	0.164	0.158	0.198
	BP 神经网络	0.155	0.151	0.188
	SSA-AR	0.147	0.147	0.183
	SSA-MF	0.130	0.127	0.159
多云	AR	0.187	0.193	0.242
	BP 神经网络	0.174	0.171	0.213
	SSA-AR	0.175	0.180	0.225
	SSA-MF	0.143	0.147	0.184

经网络和 SSA-AR,AR 法预测水平最低。阴天中,SSA-MF 法的预测效果最好,SSA-AR 和 BP 神经网络

表 3 平均预测误差统计结果

Table 3 Statistical results of average forecasting error

方法	MAPE/%	RMSE/MW	ERMSE/%
AR	14.6	0.150	18.7
BP 神经网络	13.8	0.140	17.4
SSA-AR	13.7	0.142	17.8
SSA-MF	11.6	0.119	14.8

4 结论

本文采用 SSA 技术对光伏出力进行时序分解,得到了低频/高频/噪声序列。通过对光伏出力与气象因素间的相关性和灵敏性分析,确定了影响光伏出力的主要气象因素,从而提出采用考虑气象因素的短期光伏出力预测的 SSA 方法。该方法仅考虑了对光伏出力影响较大的气象因素,简化了建模过程,分解预测的思想也显著提高了预测精度。通过对比及仿真分析得到以下结论:

a. SSA 技术通过提取原始数据的主要信息,可将原本无任何规律的序列分解成不同成份的序列,

使得部分序列具有一定的规律性,该处理方法有助于对光伏特性的分析和光伏出力的预测;

b. 对不同天气类型,SSA-MF对短期光伏出力的预测精度高于AR法、BP神经网络和SSA-AR,这表明在不同的天气类型下,考虑气象因素的奇异谱分析方法对短期光伏出力预测均具有较好的预测能力和适应性。

本文采用分解预测的思想为光伏出力的预测提供了新的研究思路,有一定的实用性。但预测效果仍有一定的提升空间,预测模型和预测方法有待进一步的优化。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 李秋燕,王利利,丁岩,等.考虑光伏不确定性的安全约束机组组合[J].电力自动化设备,2016,36(11):101-106.
LI Qiuyan, WANG Lili, DING Yan, et al. Security-constrained unit commitment considering PV output uncertainty[J]. Electric Power Automation Equipment, 2016, 36(11): 101-106.
- [2] 黎静华,文劲宇,潘毅,等.面向新能源并网的电力系统鲁棒调度模式[J].电力系统保护与控制,2015,43(22):47-54.
LI Jinghua, WEN Jinyu, PAN Yi, et al. Robust dispatching mode of electrical power system to cope with renewable energy power[J]. Power System Protection and Control, 2015, 43(22): 47-54.
- [3] 袁晓玲,施俊华,徐杰彦.计及天气类型指数的光伏发电短期出力预测[J].中国电机工程学报,2013,33(34):57-64.
YUAN Xiaoling, SHI Junhua, XU Jieyan. Short-term power forecasting for photovoltaic generation considering weather type index[J]. Proceedings of the CSEE, 2013, 33(34): 57-64.
- [4] 陈通,孙国强,卫志农,等.基于相似日和CAPSO-SNN的光伏发电功率预测[J].电力自动化设备,2017,37(3):66-71.
CHEN Tong, SUN Guoqiang, WEI Zhinong, et al. Photovoltaic power generation forecasting based on similar day and CAPSO-SNN[J]. Electric Power Automation Equipment, 2017, 37(3): 66-71.
- [5] 黎静华,桑川川,甘一夫,等.风电功率预测技术研究综述[J].现代电力,2017,34(3):1-11.
LI Jinghua, SANG Chuanchuan, GAN Yifu, et al. A review of researches on wind power forecasting technology[J]. Modern Electric Power, 2017, 34(3): 1-11.
- [6] 杨锡运,刘欢,张彬,等.组合权重相似日选取方法及光伏输出功率预测[J].电力自动化设备,2014,34(9):118-122.
YANG Xiyun, LIU Huan, ZHANG Bin, et al. Similar day selection based on combined weight and photovoltaic power output forecasting[J]. Electric Power Automation Equipment, 2014, 34(9): 118-122.
- [7] 张程熠,唐雅洁,李永杰,等.适用于小样本的神经网络光伏预测方法[J].电力自动化设备,2017,37(1):101-106.
ZHANG Chengyi, TANG Yajie, LI Yongjie, et al. Photovoltaic power forecast based on neural network with a small number of samples[J]. Electric Power Automation Equipment, 2017, 37(1): 101-106.
- [8] 王晓兰,葛鹏江.基于相似日和径向基函数神经网络的光伏阵列输出功率预测[J].电力自动化设备,2013,33(1):100-109.
WANG Xiaolan, GE Pengjiang. PV array output power forecasting based on similar day and RBFNN[J]. Electric Power Automation Equipment, 2013, 33(1): 100-109.
- [9] 丁明,徐宁舟.基于马尔可夫链的光伏发电系统输出功率短期预测方法[J].电网技术,2011,35(1):152-157.
DING Ming, XU Ningzhou. A method to forecast short-term output power of photovoltaic generation system based on Markov chain[J]. Power System Technology, 2011, 35(1): 152-157.
- [10] LI Y T, SU Y, SHU L J. An ARMAX model for forecasting the power output of a grid connected photovoltaic system[J]. Renewable Energy, 2014(66):78-89.
- [11] 丁明,刘志,毕锐,等.基于灰色系统校正-小波神经网络的光伏功率预测[J].电网技术,2015,39(9):2438-2443.
DING Ming, LIU Zhi, BI Rui, et al. Photovoltaic output prediction based on grey system correction-wavelet neural network[J]. Power System Technology, 2015, 39(9): 2438-2443.
- [12] 陈志宝,丁杰,周海,等.地基云图结合径向基函数神经网络的光伏功率超短期预测模型[J].中国电机工程学报,2015,35(3):561-567.
CHEN Zhibao, DING Jie, ZHOU Hai, et al. A model of very short-term photovoltaic power forecasting based on ground-based cloud images and RBF neural network[J]. Proceedings of the CSEE, 2015, 35(3): 561-567.
- [13] 茆美琴,龚文剑,张榴晨,等.基于EEMD-SVM方法的光伏电站短期出力预测[J].中国电机工程学报,2013,33(34):17-24.
MAO Meiqin, GONG Wenjian, ZHANG Liuchen, et al. Short-term photovoltaic generation forecasting based on EEMD-SVM combined method[J]. Proceedings of the CSEE, 2013, 33(34): 17-24.
- [14] 傅美平,马红伟,毛建容.基于相似日和最小二乘支持向量机的光伏发电短期预测[J].电力系统保护与控制,2012,40(16):65-69.
FU Meiping, MA Hongwei, MAO Jianrong. Short-term photovoltaic power forecasting based on similar days and least square support vector machine[J]. Power System Protection and Control, 2012, 40(16): 65-69.
- [15] 李乐,刘天琪.基于近邻传播聚类和回声状态网络的光伏预测[J].电力自动化设备,2016,36(7):41-46.
LI Le, LIU Tianqi. PV power forecasting based on AP-ESN[J]. Electric Power Automation Equipment, 2016, 36(7): 41-46.
- [16] LIU Yongqian, SHI Jie, YANG Yongping, et al. Short-term wind-power prediction based on wavelet transform-support vector machine and statistic-characteristics analysis[J]. IEEE Transactions on Industry Applications, 2012, 48(4): 1136-1141.
- [17] 高彩亮.基于奇异值分解和支持向量机的负荷预测新方法[J].科技广场,2012(1):105-108.
GAO Cailiang. One new approach of load forecasting based on singular value decomposition and support vector machine[J]. Science Plaza, 2012(1): 105-108.
- [18] 周天清.基于奇异谱分析的金融时间序列自适应分解预测研究[D].南昌:华东交通大学,2012.
ZHOU Tianqing. The research of financial time series adaptive decomposition prediction based on singular spectrum analysis[D]. Nanchang: East China Jiaotong University, 2012.
- [19] WANG J, ZHENG N. A novel fractal image compression scheme with block classification and sorting based on Pearson's correlation coefficient[J]. IEEE Transactions on Image Processing, 2013, 22(9): 3690-3702.
- [20] 李嘉龙,李小燕,刘思捷,等.考虑气温累积效应的短期负荷预测[J].华北电力大学学报(自然科学版),2013,40(1):49-54.
LI Jialong, LI Xiaoyan, LIU Sijie, et al. Short-term load forecasting considering the accumulative effects of temperatures[J]. Journal of North China Electric Power University (Natural Science Edition), 2013, 40(1): 49-54.

作者简介:



黎静华

黎静华(1982—),女,广西博白人,教授,博士,通信作者,主要研究方向为电力系统优化运行与控制、大规模可再生能源并网技术等(E-mail: happyjinghua@163.com);

赖昌伟(1991—),男,陕西安康人,硕士研究生,主要研究方向为大规模可再生能源并网技术(E-mail: laiwei_gxu@qq.com)。

(下转第76页 continued on page 76)

Relevance characteristic analysis of line loss big data in AC and DC transmission channels based on random matrix theory

WANG Qi¹, ZHUANG Yuancan², YAN Shuai¹, ZHU Jianquan², CAI Yanlei¹, LIU Mingbo²

(1. Maintenance and Test Center, EHV, China Southern Power Grid, Guangzhou 510663, China;

2. School of Electric Power, South China University of Technology, Guangzhou 510640, China)

Abstract: In order to analyze the relevance characteristics of line loss rate in AC and DC transmission channels of West-East Power Transmission Project, a method is proposed based on random matrix theory. Firstly, the experimental matrix data source and the comparison matrix data source are constructed by using line loss big data, and the sliding window is used to sample these two types of data sources respectively. Secondly, the MSR (Mean Spectral Radius) of the random matrix theorem is defined as the quantitative index of the relevance characteristics, and the relevance characteristics of line loss rate are quantized by calculating the MSRs of the experimental matrix and the comparison matrix. Finally, the line loss big data of the eight AC and eight DC transmission channels of China Southern Power Grid are analyzed, and the results show that the proposed method can quantitatively describe the relevance characteristics between the line loss rate and the power state as well as the relevance characteristics among the line loss rates of different channels.

Key words: power transmission channels; line loss rate; relevance characteristics; random matrix theory; mean spectral radius

(上接第57页 continued from page 57)

Singular spectrum analysis method for short-term photovoltaic output prediction considering meteorological factors

LI Jinghua, LAI Changwei

(Guangxi Key Laboratory of Power System Optimization and Energy-Saving Technology, Guangxi University, Nanning 530004, China)

Abstract: An improved SSA (Singular Spectrum Analysis) method embedded with the meteorological factors is proposed based on the traditional SSA method, which combines technologies such as SSA, correlation analysis and sensitivity analysis, effectively improving the prediction accuracy of the traditional SSA method. The PV (PhotoVoltaic) output time series is decomposed into low frequency series, high frequency series and noise sequence series by the SSA technology. The temperature and irradiation are determined as the main meteorological factors influencing the PV output by the Pearson correlation coefficient method. The sensitivity between the PV output and meteorological factors is analyzed, according to the results of which and the reference value, the low frequency series and high frequency series of the prediction day are modified respectively and then superimposed to obtain the PV output prediction results. The proposed method is applied in the short-term PV prediction of an area, and the results compared with the AR (AutoRegressive) model, the BP neural network, and the traditional SSA-AR method show that, the proposed method has higher prediction accuracy.

Key words: singular spectrum analysis; meteorological factor; correlation analysis; sensitivity analysis; short-term photovoltaic output prediction

附录：

表 A1 光伏出力对气温变化的灵敏度

Table A1 Sensitivity of PV output to temperature variations

气温区 间/°C	灵敏度/kW	气温区 间/°C	灵敏度/kW
-	-	[26,27)	13.996
[16,17)	15.186	[27,28)	13.877
[17,18)	15.067	[28,29)	13.758
[18,19)	14.948	[29,30)	13.640
[19,20)	14.829	[30,31)	13.521
[20,21)	14.710	[31,32)	13.402
[21,22)	14.591	[32,33)	13.283
[22,23)	14.472	[33,34)	13.164
[23,24)	14.353	[34,35)	13.045
[24,25)	14.234	[35,36)	12.926
[25,26)	14.115	-	-

表 A2 光伏出力对辐照强度变化的灵敏度

Table A2 Sensitivity of PV output to radiation intensity variation

辐照强度区间 (W/m²)	灵敏度/W	辐照强度区间(W/m²)	灵敏度/W
-	-	[1120,1160)	67.513
[640,680)	41.599	[1160,1200)	69.869
[720,760)	43.955	[1200,1240)	72.224
[800,840)	46.311	[1240,1280)	74.580
[840,880)	48.666	[1280,1320)	76.936
[880,920)	51.022	[1320,1360)	79.292
[920,960)	53.378	[1360,1400)	81.648
[960,1000)	55.734	[1440,1480)	84.003
[1000,1040)	58.090	[1480,1520)	86.359
[1040,1080)	60.445	[1520,1560)	86.359
[1080,1120)	62.801	-	-

表 A3 不同天气类型下各种方法对光伏出力的预测误差比较

Table A3 Comparison of forecasting error of PV output under different weather types

方法		AR			BP 神经网络			SSA-AR			SSA-MF		
天气类型	日期	MAPE/ %	RMSE/ MW	ERMSE/ %	MAPE/ %	RMSE/ MW	ERMSE/ %	MAPE/ %	RMSE/ MW	ERMSE/ %	MAPE/ %	RMSE/ MW	ERMSE/ %
晴天	5月2日	0.076	0.087	0.109	0.073	0.087	0.109	0.081	0.089	0.111	0.052	0.068	0.086
	5月4日	0.094	0.124	0.155	0.102	0.108	0.135	0.125	0.144	0.181	0.092	0.095	0.119
	5月7日	0.115	0.121	0.152	0.104	0.123	0.153	0.101	0.116	0.145	0.083	0.088	0.109
	5月12日	0.099	0.133	0.166	0.078	0.089	0.111	0.082	0.103	0.129	0.066	0.077	0.097
	5月15日	0.097	0.116	0.145	0.086	0.092	0.115	0.113	0.139	0.173	0.078	0.088	0.110
	5月17日	0.075	0.074	0.092	0.086	0.097	0.122	0.059	0.070	0.088	0.061	0.075	0.094
	5月25日	0.102	0.126	0.157	0.085	0.091	0.114	0.081	0.102	0.128	0.080	0.098	0.123
	5月28日	0.091	0.117	0.146	0.081	0.087	0.109	0.054	0.067	0.084	0.051	0.063	0.079
	6月9日	0.076	0.099	0.124	0.099	0.103	0.129	0.089	0.119	0.149	0.068	0.103	0.128
	6月26日	0.074	0.100	0.125	0.059	0.070	0.088	0.074	0.093	0.116	0.046	0.063	0.079
	平均值	0.090	0.110	0.137	0.085	0.095	0.118	0.086	0.104	0.130	0.068	0.082	0.102
阴天	5月11日	0.166	0.127	0.159	0.146	0.151	0.188	0.149	0.125	0.156	0.128	0.102	0.128
	5月16日	0.153	0.122	0.153	0.161	0.154	0.193	0.150	0.127	0.159	0.117	0.125	0.157
	5月19日	0.161	0.130	0.162	0.130	0.122	0.153	0.129	0.132	0.165	0.128	0.128	0.160
	5月21日	0.158	0.136	0.170	0.118	0.156	0.195	0.124	0.146	0.183	0.116	0.140	0.174
	5月30日	0.110	0.133	0.166	0.132	0.134	0.167	0.126	0.146	0.182	0.117	0.104	0.129
	6月4日	0.145	0.194	0.243	0.138	0.129	0.161	0.129	0.112	0.140	0.121	0.117	0.146
	6月5日	0.167	0.138	0.173	0.132	0.137	0.172	0.141	0.131	0.164	0.131	0.123	0.154
	6月7日	0.132	0.140	0.175	0.135	0.159	0.198	0.144	0.180	0.226	0.117	0.127	0.159
	6月8日	0.116	0.139	0.174	0.149	0.138	0.172	0.146	0.132	0.165	0.138	0.123	0.153
	6月10日	0.141	0.111	0.139	0.130	0.140	0.175	0.149	0.144	0.180	0.124	0.099	0.124
	平均值	0.145	0.137	0.171	0.137	0.142	0.177	0.139	0.137	0.172	0.124	0.119	0.149
雨天	5月1日	0.154	0.146	0.182	0.141	0.112	0.140	0.151	0.160	0.200	0.126	0.106	0.133
	5月5日	0.139	0.122	0.152	0.147	0.181	0.227	0.126	0.107	0.134	0.130	0.133	0.166
	5月9日	0.196	0.198	0.247	0.148	0.139	0.174	0.204	0.203	0.254	0.134	0.124	0.155
	5月10日	0.194	0.217	0.271	0.131	0.146	0.183	0.135	0.129	0.162	0.126	0.133	0.166
	5月18日	0.192	0.185	0.231	0.150	0.145	0.181	0.152	0.112	0.140	0.126	0.149	0.186
	5月27日	0.169	0.182	0.228	0.134	0.132	0.165	0.128	0.104	0.130	0.128	0.108	0.135
	6月1日	0.113	0.142	0.178	0.164	0.164	0.204	0.146	0.182	0.228	0.130	0.138	0.172
	6月2日	0.138	0.106	0.132	0.215	0.170	0.213	0.161	0.182	0.228	0.138	0.119	0.149
	6月14日	0.183	0.128	0.159	0.194	0.153	0.191	0.151	0.153	0.191	0.140	0.133	0.166
	6月19日	0.157	0.157	0.196	0.126	0.164	0.205	0.120	0.133	0.166	0.119	0.126	0.158
	平均值	0.164	0.158	0.198	0.155	0.151	0.188	0.147	0.147	0.183	0.130	0.127	0.159
多云	5月3日	0.228	0.182	0.227	0.208	0.206	0.257	0.204	0.147	0.184	0.161	0.156	0.195
	5月6日	0.152	0.191	0.238	0.184	0.231	0.289	0.150	0.157	0.196	0.129	0.163	0.204
	5月20日	0.170	0.184	0.230	0.211	0.121	0.151	0.189	0.213	0.266	0.147	0.144	0.180
	5月26日	0.179	0.103	0.129	0.149	0.126	0.158	0.221	0.220	0.275	0.145	0.163	0.203
	6月11日	0.164	0.179	0.224	0.151	0.179	0.224	0.127	0.161	0.201	0.153	0.117	0.147

	6 月 13 日	0.221	0.246	0.308	0.155	0.185	0.231	0.146	0.123	0.154	0.139	0.134	0.167
	6 月 15 日	0.149	0.212	0.264	0.199	0.168	0.210	0.137	0.174	0.217	0.136	0.147	0.184
	6 月 22 日	0.193	0.239	0.298	0.185	0.170	0.213	0.214	0.204	0.255	0.151	0.105	0.131
	6 月 27 日	0.192	0.186	0.232	0.145	0.126	0.158	0.156	0.200	0.250	0.140	0.164	0.205
	6 月 29 日	0.225	0.214	0.267	0.157	0.195	0.244	0.203	0.203	0.253	0.130	0.182	0.227
	平均值	0.187	0.193	0.242	0.174	0.171	0.213	0.175	0.180	0.225	0.143	0.147	0.184