

考虑时空相关性的多风电场出力场景生成与评价方法

丁明¹, 宋晓皖¹, 孙磊¹, 黄冯¹, 张舒捷², 杜德贵³

(1. 合肥工业大学 安徽省新能源利用与节能重点实验室, 安徽 合肥 230009;

2. 国网青海省电力公司电力科学研究院 青海省光伏发电并网技术重点实验室, 青海 西宁 810008;

3. 国网青海省电力公司, 青海 西宁 810008)

摘要:含多个风电场的场景生成技术可为电力系统中长期规划和运行提供所需基础数据。为在场景生成过程中计入多风电场风电出力的时空相关性,提出两阶段场景生成方法:在第一阶段,采用Copula函数对多个风电场出力的空间相关性建模,获得多风电场出力的初始场景;在第二阶段,运用随机微分方程对风电场出力波动随机性建模,通过重构初始风电出力场景,使得最终获得的场景中风电序列较好地保留原始序列的时间相关性。为评估生成场景的有效性,构建场景有效性评价指标体系;引入多重分形去趋势波动分析方法,提供刻画风电序列的自相关特性和动态波动特性的多维度指标。以某区域风电场为例,生成风电季度出力场景,结果表明所提方法能够复现原始风电序列的时空相关性。

关键词:风电;时空相关性;Copula函数;随机微分方程;多重分形;评价指标

中图分类号:TM 614

文献标志码:A

DOI:10.16081/j.epae.201909024

0 引言

近年来,随着我国区域性风电集群的增多,由多风电场出力的时空相关性所带来的问题日益突显。开展多风电场出力时空相关性建模,建立符合实际的中长期风电集群多风电场出力场景并进行场景有效性评价,能够为系统发展规划、检修计划提供基础信息,有助于应对风电的不确定性^[1]。

风电集群场景生成是以多个风电场为讨论对象,建模时需同时考虑风电场本身的时间相关性(即自相关性)和各风电场间的空间相关性(即互相关性),所生成的出力场景是各风电场出力序列的集合,包含各风电场的空间-时间相关性信息。文献[2]基于Copula理论构建多风电场联合分布函数模型,通过蒙特卡洛抽样生成具有空间相关性的风电场出力场景。文献[3]采用主成分分析法将多个相关的风电出力序列转化为不相关的主成分PC(Principal Component)序列,再利用自回归滑动平均ARMA(Auto-Regressive and Moving Average)模型拟合各PC序列。文献[4]采用纵横双向优化方法生成日风电功率序列场景,纵轴方向采用最优消减技术基于历史数据产生每个时段代表场景,横轴方向采用禁忌搜索方法决定时段连接规则。文献[5]建立基于不同气象变量的风电功率预测模型,再采用特定机制对气象变量预测结果进行组合。文献[6]首先利用Copula函数构造能描述多风电场空间相关

性和概率分布的风速场景,在此基础上利用随机微分方程对生成的风速场景次序重构,使其满足时域上的变化特性。以上研究在同时考虑集群风电场出力的时空相关性以及对长期风电场景中风电波动特征的刻画方面尚不完善。

对于生成的风电场景,需要评价其结果的有效性。针对长期风电出力场景,主要的评价指标是考察其是否保留了实际的序列特征。文献[7]采用平均绝对误差MAE(Mean Absolute Error)、平均绝对百分比误差MAPE(Mean Absolute Percentage Error)和均方根误差RMSE(Root Mean Square Error)评价确定性估计结果。文献[8]采用可信度、区间平均宽度和技巧得分评价概率预测结果。文献[9]基于可靠度以及锐度评价概率性预测结果,利用连续等级概率评分CRPS(Continuous Ranked Probability Score)指标对概率密度分布进行总体性评价。文献[10]通过线性相关系数评价序列间的互相关性程度。文献[11]采用自相关函数ACF(AutoCorrelation Function)曲线评价生成序列的自相关性。然而,上述评价方法尚不适用于更细致的相关性分析,如序列中不同波动成分的时间相关性以及不同时间尺度下序列的自相关性等,因此,有进一步改进的必要。

针对上述问题,本文开展2个方面的工作。在中长期风电场景生成技术方面,对文献[6]的两阶段法进行进一步完善:在第一阶段,基于拟合优度指标和相关性指标,从Copula函数库中优选最佳Copula函数对多个风电场出力的多元联合概率分布进行拟合,旨在更准确地捕获与表达风电场间出力的空间相关性;在第二阶段,选取中心风电场,以中心风电场出力波动序列为输入,基于改进的Ornstein-

收稿日期:2019-02-22;修回日期:2019-08-03

基金项目:国家电网公司科技项目(5228001600DX)

Project supported by the Science and Technology Project of SGCC(5228001600DX)

Uhlenbeck 随机微分方程,生成基准波动序列,基于基准波动序列,重构初始风电场景,将各风电场出力的自相关性信息纳入风电场景中。改进的随机微分方程模拟了序列的波动特性,考虑了日内波动规律。在生成场景的评估方面,本文建立包含可靠性、空间相关性、自相关性和多重分形性的评估指标体系,引入多重分形去趋势波动分析 MF-DFA (MultiFractal Detrended Fluctuation Analysis) 方法,更深入地刻画风电序列在不同尺度下的长期相关性及多重分形特性。

1 考虑时空相关性的多风电场出力场景生成技术

1.1 阶段1:多风电场的空间相关性建模

基于实际风电出力场景数据,通过 Copula 函数建立多元联合概率分布对风电场间空间相关性模型。

1.1.1 风电功率边缘分布拟合

本文采用核密度估计法求解。设单一风电场出力为随机变量 X , 样本点为 $(x_1, x_2, \dots, x_N)$, N 为样本长度,其概率密度函数为 $f(x)$, 则核密度估计公式为:

$$f(x) = \frac{1}{Nh} \sum_{i=1}^N K\left(\frac{x-x_i}{h}\right) \quad (1)$$

其中, h 为滑动窗口长度且 $h > 0$; $K(\cdot)$ 为 Epanechnikov 核函数,相比其他核函数,该核函数具有最小的均方根 RMS (Root Mean Square), 其具体表达式见文献[12]。对 $f(x)$ 求积分可得到变量的累积概率函数。

1.1.2 Copula 函数参数求取及最佳 Copula 函数优选

基于多风电场的出力数据,可得到经验多元联合概率分布,采用极大似然法求取 Copula 函数参数。常用的 Copula 函数有 Gaussian-Copula、t-Copula、Gumbel-Copula、Clayton-Copula、Frank-Copula。通过评估各 Copula 函数的拟合效果,选取拟合效果最佳的 Copula 函数。用于评估拟合效果的指标如下。

(1) 拟合优度指标:即欧氏距离 d , d 值越小表明该 Copula 函数越贴近经验概率分布函数。

(2) 相关性指标:包括 Spearman 和 Kendall 相关性系数,计算各 Copula 函数抽样生成的样本场景的 Spearman 和 Kendall 相关性系数,相关性系数越接近实际样本,表明该 Copula 模型越接近实际的空间相关性程度。

上述指标的定义如下。

设随机向量 X, Y 的累积分布函数分别为 $F(x)$ 和 $G(y)$, 表示为 $u = F(x)$ 和 $v = G(y)$ 。设 $(x_i, y_i) (i=1, 2, \dots, N)$ 为取自随机向量 (X, Y) 的样本。 (X, Y) 的 Copula 函数为 $C(u, v)$, 且 $u, v \in [0, 1]$ 。

欧氏距离 d 为:

$$d = \sqrt{\sum_{i=1}^N \left| \hat{C}(u_i, v_i) - C(u_i, v_i) \right|^2} \quad (2)$$

其中, $\hat{C}(u, v)$ 为经验分布函数,可由式(3)计算得到。

$$\hat{C}(u, v) = \frac{1}{N} \sum_{i=1}^N I[F(x_i) \leq u] I[G(y_i) \leq v] \quad (3)$$

其中, $I(\cdot)$ 为显式函数,若 $F(x_i) \leq u$, 则 $I[F(x_i) \leq u] = 1$, 反之 $I[F(x_i) \leq u] = 0$ 。

Spearman 相关性系数为:

$$\rho(X, Y) = 3 \left\{ P[(X - X')(Y - \tilde{Y}) > 0] - P[(X - X')(Y - \tilde{Y}) < 0] \right\} \quad (4)$$

其中, $P(\cdot)$ 为概率密度函数;随机向量 (X', Y') 、 $(\tilde{X}, \tilde{Y})$ 和 (X, Y) 服从相同的分布。

Kendall 相关性系数为:

$$\tau(X, Y) = P[(X - X')(Y - Y') > 0] - P[(X - X')(Y - Y') < 0] \quad (5)$$

1.1.3 生成初始风电场景 S^1

对 1.1.2 节中得到的最佳 Copula 函数进行随机抽样,可得到初始风电场景 S^1 , 其矩阵形式为:

$$S^1 = (x_{w_k, t}) = \begin{bmatrix} x_{w_1, 1} & x_{w_1, 2} & \cdots & x_{w_1, N} \\ x_{w_2, 1} & x_{w_2, 2} & \cdots & x_{w_2, N} \\ \vdots & \vdots & \ddots & \vdots \\ x_{w_m, 1} & x_{w_m, 2} & \cdots & x_{w_m, N} \end{bmatrix} \quad (6)$$

其中, $x_{w_k, t}$ 为风电出力值, w_k 表示风电场 $k (k=1, 2, \dots, m, m$ 为风电场总数), $t=1, 2, \dots, N$ 。式中,行向量表示每个风电场的出力序列;列向量表示每次抽样产生的结果,每个列向量包含了风电场间的空间相关性信息。

1.2 阶段2:多风电场的时间相关性建模

在阶段1产生的初始风电场景 S^1 中,列向量之间是随机分布的,不包含风电内在的时序信息。本阶段基于基准波动序列,重构 S^1 中列向量的次序,使得场景中的各风电序列保留原始序列的时间相关性。

1.2.1 随机性建模与基准风电波动序列生成

文献[13]提出一种随机微分方程 SDE (Stochastic Differential Equation) 模型进行短期风速预测。在此基础上,本文提出一种改进的 SDE 模型用于长期风电波动序列生成,基于标准 Ornstein-Uhlenbeck 过程,在其漂移项和扩散项中增加了使状态稳定和考虑日内波动的项。该模型定义为:

$$d_{x_t} = \left\{ \frac{1}{2} \cos \left[\left(\frac{2\pi}{24} + p \right) t \right] U_t (1 - e^{-x_t}) + \theta_x (l_x - x_t) \right\} dt + \sigma_x x_t^\beta dW_{x,t} \quad (7)$$

$$dU_t = \theta_u (l_u - U_t) dt + \sigma_u dW_{u,t} \quad (8)$$

其中, x_t 和 dx_t ($dx_t = x_t - x_{t-1}$) 分别为风电出力和波动值; $W_{x,t}$ 和 $W_{u,t}$ 表示标准 Wiener 过程; p 为相位值; U_t 为随机趋势变量, 采用 Ornstein-Uhlenbeck 过程; θ_x 、 l_x 、 β 及 θ_u 、 l_u 均为大于 0 的常数; σ_x 及 σ_u 为扩散项的系统噪声参数。式(7)系数中新增的指数项 $1 - e^{-x_t}$ 和 x_t^β 可以保证 x_t 为非负值, 若 x_t 趋近于 0, 随机过程由 $\theta_x(l_x - x_t)dt$ 决定, 由于 l_x 、 θ_x 均为大于 0 的常数, 因此 x_t 的值不可能为负值; 式中新增加的余弦项可以模拟风电的日内波动规律, 随着 θ_u 的增加, U_t 向 l_u 逼近的速度越快。式(7)和式(8)能够模拟风电波动中的日内波动规律和长期波动变化趋势。

选取中心风电场(处于风电场集群中心位置或装机容量较大的风电场), 将其实际风电波动序列作为输入, 采用极大似然法求取 SDE 式(7)和式(8)中的未知参数, 并生成基准风电波动序列 $\{P_t, t=1, 2, \dots, N-1\}$ 。

1.2.2 对初始风电场景 S^1 进行重构

对 S^1 中各风电场风电出力序列(即行向量)进行一阶差分计算求得各风电场风电波动序列。基于生成的基准风电波动序列, 重构 S^1 中列向量的次序。重构算法为: 设上一时刻 t 的场景出力值为 $[x_{w_1,t}, x_{w_2,t}]^T$, 在中心风电场出力 $x_{w_1,t}$ 和基准波动 P_t 的基础上, 找到最接近 $x_{w_1,t} + P_t$ 的下一时刻值 $x_{w_1,t+1}$, 将列向量 $[x_{w_1,t+1}, x_{w_2,t+1}]^T$ 作为下一时刻场景出力值。遍历初始场景 S^1 , 得到重构后的风电出力场景 S^2 。重构的准则是使得重构后的中心风电场波动序列与基准波动序列的平均绝对误差最小。其定义为:

$$MAE = \frac{1}{N-1} \sum_{i=1}^{N-1} |P_i - z_i| \quad (9)$$

其中, P_i 和 z_i 分别为基准风电波动序列和中心风电场的风电波动序列。

值得注意的是, 生成基准波动序列并不是为了得到准确的波动值, 而是为了保证出力序列在一定长度的时间区间内连续变化。重构后得到风电场景 S^2 , 其准确反映了各风电场之间的空间相关性和风电场时间自相关性。

图 1 给出了场景生成方法的流程图。

2 生成场景评估体系

对于生成的风电场景, 本文采用可靠性、空间相关性、时间相关性及多重分形性指标作为评估其有效性的标准, 评估的核心是判断生成场景对实际场景序列所属特性的复现程度。

2.1 可靠性

可靠性是风电不确定性预测的基本要求^[14], 指




图 1 两阶段多风电场出力场景生成方法流程图

Fig.1 Flowchart of two-stage output scenario generation method for multiple wind farms

生成风电场景与原始风电场景在概率分布上的一致性。双分位数 Q-Q (Quantile-Quantile) 图常用来比较 2 个变量概率分布的相似性。Q-Q 图的纵、横坐标分别为模拟值和经验值的分位数, 若图上的点均落在过原点的对角线上, 则两变量服从同一分布; 图上的点越接近对角线, 两变量的概率分布越相似。

2.2 空间相关性

空间相关性是指由于风电集群内地理位置较近和具有相似气候条件的风电场, 其出力序列变化趋势存在相关性。本文采用 Spearman 和 Kendall 相关性系数来评估本文方法对样本区域上风电场间的空间相关性的复现程度。Spearman 和 Kendall 相关性系数的定义分别如式(4)和式(5)所示。生成场景与原始场景的 Spearman 和 Kendall 相关性系数越相近, 说明生成场景对原始场景空间相关性的复现程度越高。

2.3 时间相关性

时间相关性指风电场景中, 各风电场的出力序列各时间点间的自相关性。本文采用 MF-DFA 方法分析风电出力波动序列, 通过广义 Hurst 指数定量描述序列中不同大小波动的自相关性。

2.4 多重分形性

多重分形性是基于对序列中不同幅值波动的尺度特性分析, 对风电序列中不同幅值波动在其差异性程度上的一种衡量指标。

2.5 MF-DFA 方法

MF-DFA 是由 Peng C K 等首先提出, 被证明是检测时间序列长程相关的重要方法^[15], 能够在更高维度上分析序列的自相关性、互相关性和多重分形性, 并给出相关的量化指标^[16], 已广泛应用于生物、气象、金融等领域的序列分析中。

本文利用 MF-DFA 方法分析风电序列的自相关性和多重分形性, 具体步骤如下。

(1) 设风电出力序列 $(x_1, x_2, \dots, x_N)$, 其均值为 μ_x 。对序列预处理得到序列 $Y(i)$:

$$Y(i) = \sum_{t=1}^i (x_t - \mu_x) \quad i=1, 2, \dots, N \quad (10)$$

此步骤为后续序列的局部去趋势的预处理。

(2) 序列划分。选取时间尺度 s , 将序列 $Y(i)$ 划分为长度为 s , 共计 $N_s (N_s = N/s)$ 个不重叠的片段。由于可能出现序列长度 N 不是 s 的整数倍的情况, 为了不丢失序列信息, 对序列从 $Y(N)$ 向 $Y(1)$ 的顺序再次划分。因此, 共计得到 $2N_s$ 个片段。

(3) 对各片段局部去趋势。拟合各片段得到片段局部趋势, 本文采用多项式拟合, 计算各片段多项式拟合的 RMS 值作为片段局部去趋势结果, 也即为片段的波动值:

$$F^2(s, v) = \frac{1}{s} \sum_{i=1}^s \{Y[(v-1)s+i] - y_v(i)\}^2 \quad v=1, 2, \dots, N_s \quad (11)$$

其中, 为方便理解, 本文称 $F^2(s, v)$ 为局部 RMS 值; $y_v(i)$ 为片段 v 的多项式拟合值。对于反向划分得到的片段, 其局部去趋势结果为:

$$F^2(s, v) = \frac{1}{s} \sum_{i=1}^s \{Y[N-(v-N_s)s+i] - y_v(i)\}^2 \quad v=N_s+1, N_s+2, \dots, 2N_s \quad (12)$$

(4) 计算 q 阶波动函数。通过对所有片段进行 q 阶平均化得到序列的波动函数 $F_q(s)$:

$$F_q(s) = \left\{ \frac{1}{2N_s} \sum_{v=1}^{2N_s} [F^2(s, v)]^{q/2} \right\}^{1/q} \quad (13)$$

其中, $q \in \mathbf{R}^+$ 。当 $q=0$ 时, 波动函数 $F_{q=0}(s)$ 根据下式计算:

$$F_{q=0}(s) = \exp \left[\frac{1}{4N_s} \sum_{v=1}^{2N_s} \ln F^2(s, v) \right] \quad (14)$$

当 $q=2$ 时, 上述过程为标准去趋势波动分析。当 q 取负值时, 平均化过程放大了波动序列中的小幅值波动; 当 q 取正值时, 波动序列中的大幅值波动被放大。因此, 通过取不同的 q 值, 能够对序列中不同大小的波动进行尺度特性分析。

(5) 确定波动函数的尺度特性。若序列 $x(t)$ 是长期幂相关, 在 $F_q(s)$ 的双对数图上, $F_q(s)$ 与 s 满足线性关系, 即:

$$F_q(s) \sim s^{h(q)} \quad (15)$$

其中, $h(q)$ 数值上等于 $F_q(s)$ 在双对数图上的斜率, 当 $q=2$ 时, 在标准分形去趋势分析中, $h(q)$ 又称为 Hurst 指数, 在 MF-DFA 中, 对于 q 取不同值, $h(q)$ 可视为广义 Hurst 值。

当 q 取不同值时, 得到不同的 $h(q)$ 值, 则序列具有多重分形性。 $h(q)$ 值相差越大, 表明序列的多重分形程度越强。多重分形谱函数可以用来描述序列的多重分形性^[17-19], 通过 Legendre 变换, 多重分形谱

函数 $f(\alpha)$ 为:

$$f(\alpha) = q\alpha - \tau(q) \quad (16)$$

$$\tau(q) = qh(q) - 1, \quad \alpha = \tau'(q) \quad (17)$$

其中, α 为奇异强度 (或 Hölder 指数); $\tau(q)$ 为尺度函数, 当序列具有多重分形性, 尺度函数为非线性; $\tau'(q)$ 为尺度函数 $\tau(q)$ 的斜率; $f(\alpha)$ 能够表示序列中不同分形成分的比重。

本文采用 3 个指标来描述序列的多重分形谱函数特征。

a. 谱宽度 $\Delta\alpha$:

$$\Delta\alpha = \alpha_{\max} - \alpha_{\min} \quad (18)$$

其中, $\alpha_{\max}$ 和 $\alpha_{\min}$ 分别为奇异值最大值和最小值。 $\Delta\alpha$ 能够反映序列的多重分形性程度, $\Delta\alpha$ 越大, 表明序列的多重分形性越强。

b. 谱函数差 $\Delta f(\alpha)$:

$$\Delta f(\alpha) = f(\alpha_{\max}) - f(\alpha_{\min}) \quad (19)$$

c. 对称性 A :

$$A = \left| \alpha_0 - \alpha_{\min} \right| / \left| \alpha_0 - \alpha_{\max} \right| \quad (20)$$

其中, α_0 为 $f(\alpha)$ 最大值对应的 α 值。

谱函数差 $\Delta f(\alpha)$ 和对称性 A 能够反映序列中大波动和小波动的比例。当 $\Delta f(\alpha)=0$ 或 $A=1$ 时, 表明序列的多重分形性是对称的, 即序列中大波动和小波动的比例相同; 当 $\Delta f(\alpha)>0$ 或 $A<1$ 时, 表明序列中小波动占主导; 当 $\Delta f(\alpha)<0$ 或 $A>1$ 时, 表明序列中大波动占主导。

3 算例分析

选取我国西北某地区两风电场 2015 年 6—8 月的风功率数据作为算例数据, 时间粒度为 15 min, 该数据经风机特性曲线转换得到, 不考虑调度弃风及检修等因素。两风电场分别记为 W_1 和 W_2 , 其直线距离为 5.66 km, 经数据预处理分析, 两风电场出力序列的 Spearman 相关系数和 Kendall 相关系数分别为 0.869 5 和 0.702 7, 呈强相关。

3.1 风电场景生成

3.1.1 阶段 1: 空间相关性分析

两风电场样本出力场景如图 2 所示 (仅显示前 200 个点), 可见 W_1 和 W_2 的空间相关性具体表现在序列的幅值和波动的连续变化趋势上。

通过对样本数据的分析可见, W_1 和 W_2 的概率分布不符合高斯分布、t 分布等常见分布, 因此本文采用核密度估计法确定 W_1 和 W_2 的累积分布函数 $u=F(x)$ 和 $v=G(y)$, 结果如图 3 所示, 图中两曲线基本重合, 说明核密度估计具有较高的精度。

图 4 为 W_1 和 W_2 出力的经验联合概率分布直方图。由于风电出力的强间歇性, 经验联合概率分布






图2 样本风电场景

Fig.2 Wind power scenario of sample

(a) W_1 (b) W_2

---- 经验分布函数, — 累积分布函数

图3 W_1 和 W_2 边缘累积概率分布函数Fig.3 Marginal cumulative probability distribution function of W_1 and W_2

具有强尾部相关性。表1给出了Copula函数库中5种典型Copula函数拟合结果及评价指标值,表中 r 、 λ 分别为线性相关系数、自由度。从表中可以看出:t-Copula和Gaussian-Copula的欧氏距离最小,分别为2.114和2.112,说明Gaussian-Copula和t-Copula有更高的拟合优度。同时,对拟合的Copula函数进行抽样生成 W_1 和 W_2 出力序列,并计算序列的Spearman和Kendall相关性系数,旨在比较Copula函数对样本空间相关性的复现程度。Gaussian-Copula生成序列的Spearman和Kendall相关性系数分别为0.9102和0.7433,更接近原始样本序列对应的相关性系数。




图4 经验联合概率分布直方图

Fig.4 Empirical joint probability distribution histogram

表1 Copula拟合结果及评价指标值

Table 1 Fitting results and evaluation index values of Copula functions

Copula 函数	参数估计值				评价指标	
	r	λ	α	d	Spearman 相关性系数	Kendall 相关性系数
t	0.9229	79.4962	—	2.114	0.9158	0.7520
Gaussian	0.9213	—	—	2.112	0.9102	0.7433
Clayton	—	—	36.3789	3.214	0.9955	0.9472
Frank	—	—	48.0107	2.968	0.9916	0.9222
Gumbel	—	—	4.0420	2.221	0.9143	0.7587
样本数据	—	—	—	—	0.8695	0.7027

因此,可以认为Gaussian-Copula函数能更好地拟合 W_1 和 W_2 的空间相关性。

通过随机抽样产生满足Gaussian-Copula函数分布的初始风电场景 S^1 ,时间尺度为3个月,即取 $N=8\,736$ 。图5给出了初始场景部分曲线,可以看出在每个时间点上, W_1 和 W_2 出力变化趋势存在关联,具有空间相关性,但是 W_1 和 W_2 本身的出力幅值波动跳跃性很大,没有反映出样本风电场出力的自相关性特征。



(a) W_1 出力序列(b) W_2 出力序列

图5 初始生成风电场景

Fig.5 Initial generated wind power scenario

3.1.2 阶段2:风电序列重构

在阶段2,为了捕获 W_1 和 W_2 出力的自相关特性,选取 W_1 为中心风电场,将 W_1 的出力波动序列作为输入,采用极大似然法求解式(7)和式(8)中各参数估计值,如表2所示。在此基础上生成基准波动

表2 SDE模型的参数估计结果

Table 2 Parameter estimation results of SDE model

参数	估计值	参数	估计值
p	-0.191 1	β	0.039 5
θ_x	0.033 4	θ_u	0.005 5
l_x	28	l_u	$3.756\,8 \times 10^{-4}$
σ_x	0.462 5	σ_u	$1.610\,6 \times 10^{-7}$

序列 $\{P_t, t=1, 2, \dots, 8735\}$,如图6所示。然后对初始风电场景 S^1 以列向量为单位进行次序重构,得到重构后的风电场最终场景 S^2 ,如图7所示。




图6 生成基准波动序列

Fig.6 Generated benchmark fluctuation series




图7 重构后风电场景

Fig.7 Wind power scenario after reconstruction

3.2 生成场景的有效性评价

本文采用由可靠性、空间相关性、时间相关性和多重分形性构成的指标体系对生成场景的有效性进行评价。

3.2.1 可靠性

不同于短期风电出力预测点对点高精度的要求,中长期风电出力场景旨在捕获风电出力的统计特征和时空相关性。因此在评估生成场景时,主要分析生成场景对样本场景特征的复现水平。

图8通过Q-Q图比较了生成序列和样本风电序列的概率分布的一致性。图中实线与虚线近似重




图8 W_1 和 W_2 的生成和样本出力序列的Q-Q图

Fig.8 Q-Q plots of generated and sample wind power series for W_1 and W_2

合,表明生成的风电序列近似与样本风电序列服从相同的分布,满足可靠性要求。

3.2.2 空间相关性

表3比较了生成场景与样本场景的空间相关性的相似程度。从表中数值来看,生成场景 S^2 很大程度上复现了样本场景的空间相关性,且 S^2 和 S^1 的相关性系数值相同,说明重构过程不会改变初始场景的空间相关性程度。

表3 风电场空间相关系数

Table 3 Spatial correlation coefficients between wind farms

场景	Spearman 相关性系数	Kendall 相关性系数
样本场景	0.8695	0.7027
S^1	0.9102	0.7433
S^2	0.9102	0.7433

3.2.3 时间相关性

对风电场 W_1 和 W_2 的波动序列进行MF-DFA,得到在不同阶数 q 下的波动函数 $F_q(s)$ 。相比于标准分形去趋势分析($q=2$),MF-DFA对去趋势后的序列取不同阶数 q 的平均化过程,即式(13)。当 q 取正值时,能够放大去趋势序列中较大的局部RMS值;当 q 取负值时,去趋势序列中较小的局部RMS值反而被放大。其中,去趋势序列中较大(小)的局部RMS值,等价于波动序列中的大(小)波动。因此 q 取不同值,能够对波动序列中不同大小的波动进行分析。

图9为风电场 W_1 波动函数的双对数图。 $F_q(s)$ 的值能够反映序列的波动水平,由图中可看出,生成序列的波动水平和样本序列大致相同。当 s 值较小




图9 W_1 波动函数双对数图

Fig.9 Log-log plot of fluctuation function for W_1

时,序列被划分为较短的片段,这些小片段可能是一个完整波动周期的一部分;当 s 值较大时,长度较大的片段可能包含多个完整的波动周期。因此在图9中,波动函数 $F_q(s)$ 在 $s \in [10, 110]$ 间为单调递增的函数。当直线的斜率(即Hurst值)在 $[0, 1]$ 之间,序列近似于噪声序列,其中当斜率大于0.5时,表明序列具有长期相关性;当斜率大于1时,序列近似于随机游走序列^[20]。表4给出了每个波动函数的Hurst值,对于风电场 W_1 ,当 q 取值在 $[-2, 2]$ 之间时,Hurst值在 $[0.5, 1]$ 之间,说明此时波动序列具有长期相关性;当 $q=-3$ 时序列中小波动通过-3阶的平均化过程被放大,Hurst值为1.0532,此时的波动序列近似于随机游走。对比两风电场样本和生成出力序列的Hurst值,生成序列在不同大小波动上基本保留了样本序列的自相关特性。

表4 Hurst指数值

Table 4 Hurst exponent values

q	Hurst指数值			
	样本场景		生成场景	
	W_1	W_2	W_1	W_2
-3	1.0532	1.2473	0.8620	1.3269
-2	0.9833	1.1945	0.8541	1.2560
-1	0.9035	1.0558	0.7258	1.1279
0	0.7863	0.8445	0.6945	0.9078
1	0.6594	0.6695	0.6614	0.6599
2	0.5599	0.5480	0.5044	0.4950
3	0.4896	0.4595	0.4154	0.4019

3.2.4 多重分形性

当 q 取不同值,所得Hurst值不同时,说明该序列具有多重分形性,且Hurst值相差越大,序列的多重分形性越强。构建多重分形谱图可以比较不同序列的多重分形性。图10给出了风电场 W_1 的多重分形谱图,表5给出了两风电场多重分形谱函数参数。在图10中,初始风电场景 S^1 的谱宽度较小, $\Delta\alpha$ 为0.2993,这是由于初始风电场景中出力序列不包含时序信息,大小波动均匀分布。对初始场景的序列重构使得场景 S^2 波动存在持续性和一定的周期,因此重构后的序列具有更强的多重分形性, $\Delta\alpha$ 上升为0.8292,更接近样本序列的 $\Delta\alpha$ 值。谱函数差 $\Delta f(\alpha)$ 和对称


图10 风电场 W_1 多重分形谱图Fig.10 Multifractal spectrum of wind farm W_1

表5 多重分形谱系数

Table 5 Coefficients of multifractal spectrum

场景	风电场	$\Delta\alpha$	$\Delta f(\alpha)$	A
样本场景	W_1	0.948 1	0.107 5	0.987 5
	W_2	1.131 3	-0.330 6	1.168 7
S^1	W_1	0.299 3	0.306 6	0.325 0
	W_2	0.392 2	0.478 1	0.252 5
S^2	W_1	0.829 2	0.211 0	0.652 4
	W_2	1.296 0	-0.146 4	1.233 7

性 A 能够反映序列中大波动和小波动的比例。以风电场 W_1 为例,其 $\Delta f(\alpha)$ 和 A 分别为0.2110和0.6524,表明 W_1 风电序列波动主要为小波动。重构后风电场景与样本场景的 $\Delta f(\alpha)$ 和 A 值更接近。

3.3 与其他方法的对比

为验证本文方法及评估指标的有效性,与文献[3]的主成分法进行对比。按照文献[3]方法所生成的风电场景见图11。对生成场景计算有效性评价指标,图12为两风电场序列的Q-Q图,生成场景的空间相关性系数分别为0.8366(Spearman)和0.6406(Kendall)。表6和表7分别给出了采用主成分法生成场景的Hurst值与多重分形谱系数,其中加粗数据表示本文方法误差更小。可以看出,在序列的时间相关性和多重分形性上,本文方法效果更好。




图11 生成风电场景序列

Fig.11 Generated wind power scenario



(a) W_1 (b) W_2 图12 W_1 和 W_2 的生成和样本出力序列的Q-Q图Fig.12 Q-Q plots of generated and sample wind power series for W_1 and W_2

表6 生成场景的Hurst指数值

Table 6 Hurst exponent value of generated scenario

q	Hurst指数值(误差值)			
	本文方法		主成分法	
	W ₁	W ₂	W ₁	W ₂
-3	0.8620 (-0.1912)	1.3269 (0.0796)	1.2992 (0.2460)	1.6074 (0.3601)
-2	0.8541 (-0.1292)	1.2560 (0.0616)	1.1247 (0.1414)	1.4591 (0.2646)
-1	0.7258 (-0.1777)	1.1279 (0.0722)	0.8783 (-0.0251)	1.1201 (0.0644)
0	0.6945 (-0.0918)	0.9078 (0.0633)	0.6805 (-0.1058)	0.7451 (-0.0994)
1	0.6614 (0.0021)	0.6599 (-0.0096)	0.5709 (-0.0885)	0.5732 (-0.0964)
2	0.5044 (-0.0555)	0.4950 (-0.0530)	0.5076 (-0.0524)	0.4938 (-0.0542)
3	0.4154 (-0.0742)	0.4019 (-0.0576)	0.4139 (-0.0757)	0.4446 (-0.0149)

注:误差值=原始数据指标-生成数据指标。

表7 生成场景的多重分形谱系数

Table 7 Multifractal spectrum coefficients of generated scenario

方法	风电场	取值(误差值)		
		$\Delta\alpha$	$\Delta f(\alpha)$	A
本文方法	W ₁	0.8292 (0.1189)	0.2110 (-0.1035)	0.6524 (0.3351)
	W ₂	1.2960 (0.1647)	-0.1464 (0.1842)	1.2337 (0.0650)
主成分法	W ₁	1.3355 (0.3874)	0.8307 (0.7233)	0.3259 (-0.6616)
	W ₂	1.5909 (0.4596)	0.5417 (0.8723)	0.3619 (-0.8068)

4 结论

本文提出了考虑时空相关性的两阶段风电出力场景生成方法,重点构建了改进的基于标准 Ornstein-Uhlenbeck 过程的 SDE 模型,该模型能够捕获风电序列的波动特性;建立了场景有效性评价体系,引入 MF-DFA 方法分析比较了生成场景中不同波动的时间相关性,并提出风电序列的多重分形性指标。以 2 个风电场出力序列为算例,验证了采用本文方法生成的场景能够复现样本场景的时空相关性。算例结果表明生成场景中各风电场出力序列在不同大小波动水平上的长期相关性 with 样本序列相似,并具有与样本序列相似的序列波动差异性程度。

参考文献:

- [1] 薛禹胜,陈宁,王树民,等. 关于利用空间相关性预测风速的评述[J]. 电力系统自动化,2017,41(10):161-169.
- [2] XUE Yusheng, CHEN Ning, WANG Shumin, et al. Review on wind speed prediction based on spatial correlation[J]. Automation of Electric Power Systems, 2017, 41(10): 161-169.
- [3] 黎静华,孙海顺,文劲宇,等. 生成风电功率时间序列场景的双向优化技术[J]. 中国电机工程学报,2014,34(16):2544-2551.
- [4] LI Jinghua, SUN Haishun, WEN Jinyu, et al. A two-dimensional optimal technology for constructing wind power time series scenarios[J]. Proceedings of the CSEE, 2014, 34(16): 2544-2551.
- [5] 欧阳庭辉,查晓明,秦亮,等. 中长期风电功率的多气象变量模型组合预测方法[J]. 电网技术,2016,40(3):847-852.
- [6] OUYANG Tinghui, ZHA Xiaoming, QIN Liang, et al. Medium-or long-term wind power prediction with combined models of meteorological multi-variables[J]. Power System Technology, 2016, 40(3): 847-852.
- [7] 吴峰,孔卫亚,周宇,等. 考虑多风电场风速变化规律的模拟数据生成方法[J]. 电网技术,2016,40(7):2038-2044.
- [8] WU Feng, KONG Weiya, ZHOU Yu, et al. A wind speed modeling method for multiple wind farms considering variation regularities[J]. Power System Technology, 2016, 40(7): 2038-2044.
- [9] 林鹏,赵书强,谢宇琪,等. 基于实测数据的风电功率曲线建模及不确定估计[J]. 电力自动化设备,2015,35(4):90-95.
- [10] LIN Peng, ZHAO Shuqiang, XIE Yuqi, et al. Wind power curve modeling based on measured data and uncertainty estimation[J]. Electric Power Automation Equipment, 2015, 35(4): 90-95.
- [11] 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.
- [12] 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.
- [13] 钱政,裴岩,曹利霄,等. 风电功率预测方法综述[J]. 高电压技术,2016,42(4):1047-1060.
- [14] QIAN Zheng, PEI Yan, CAO Lixiao, et al. Review of wind power forecasting method[J]. High Voltage Engineering, 2016, 42(4): 1047-1060.
- [15] 黄越辉,张鹏,李驰,等. 基于波动划分及时移技术的多风电场出力相关性研究[J]. 电力自动化设备,2018,38(4):162-168.
- [16] HUANG Yuehui, ZHANG Peng, LI Chi, et al. Research on correlation of multiple wind farms power based on fluctuation classification and time shifting[J]. Electric Power Automation Equipment, 2018, 38(4): 162-168.
- [17] LI D, YAN W, LI W, et al. A two-tier wind power time series model considering day-to-day weather transition and intraday wind power fluctuations[J]. IEEE Transactions on Power Systems, 2016, 31(6): 4330-4339.
- [18] HE Yaoyao, LI Haiyan. Probability density forecasting of wind power using quantile regression neural network and kernel density estimation[J]. Energy Conversion and Management, 2018, 164: 374-384.
- [19] IVERSEN E B, MORALES J M, MØLLER J K, et al. Short-term probabilistic forecasting of wind speed using stochastic differential equations[J]. International Journal of Forecasting, 2016, 32(3): 981-990.

XIE Min, XIONG Jing, LIU Mingbo, et al. Modeling of multi wind farm output correlation based on Copula and its application in power system economic dispatch [J]. Power System Technology, 2016, 40(4): 1100-1106.

- [14] ZHANG Yao,WANG Jianxue,WANG Xifan. Review on probabilistic forecasting of wind power generation[J]. Renewable and Sustainable Energy Reviews, 2014, 32: 255-270.
- [15] PENG C K, HAVLIN S, STANLEY H E, et al. Quantification of scaling exponents and crossover phenomena in nonstationary heartbeat time series[J]. Chaos, 1995, 5(1): 82-87.
- [16] KANTELHARDT J, ZSCHIEGNER A, KOSCIELNY E, et al. Multifractal detrended fluctuation analysis of nonstationary time series[J]. Physica A: Statistical Mechanics and its Applications, 2002, 316(1): 87-114.
- [17] XIONG Hui, SHANG Pengjian. Detrended fluctuation analysis of multivariate time series[J]. Communications in Nonlinear Science and Numerical Simulation, 2017, 42: 12-21.
- [18] LAIB M, GOLAY J, TELESKA L, et al. Multifractal analysis of the time series of daily means of wind speed in complex regions[J]. Chaos, Solitons & Fractals, 2018, 109: 118-127.
- [19] RUAN Yongping, ZHOU Weixing. Long-term correlations and multifractal nature in the intertrade durations of a liquid

Chinese stock and its warrant[J]. Physica A: Statistical Mechanics and its Applications, 2011, 390(9): 1646-1654.

- [20] IHLEN E. Introduction to multifractal detrended fluctuation analysis in Matlab[J]. Frontiers in Physiology, 2012, 3(141): 141.

作者简介:



丁 明

丁 明(1956—),男,安徽合肥人,教授,博士研究生导师,主要研究方向为电力系统规划及可靠性、新能源及其利用、电力电子技术在电力系统中应用等(E-mail: mingding56@126.com);

宋晓皖(1994—),女,安徽六安人,硕士研究生,主要研究方向为新能源与分布式发电技术(E-mail: xiaowansongst@163.com);

孙 磊(1989—),男,安徽宿州人,讲师,博士,主要研究方法为电力系统恢复、电力系统规划及可靠性(E-mail: leisun@hfut.edu.cn)。

Scenario generation and evaluation method of multiple wind farms output considering spatial-temporal correlation

DING Ming¹, SONG Xiaowan¹, SUN Lei¹, HUANG Feng¹, ZHANG Shujie², DU Degui³

(1. Anhui New Energy Utilization and Energy Saving Laboratory, Hefei University of Technology, Hefei 230009, China;

2. Key Laboratory of Photovoltaic Power Generation and Grid Integration, State Grid Qinghai Electric Power Research

Institute, Xining 810008, China; 3. State Grid Qinghai Electric Power Company, Xining 810008, China)

Abstract: The scenario generation technology for multiple wind farms can provide basic data for medium- and long-term planning and operation of power system. In order to consider the output spatial-temporal correlation of multiple wind farms in the process of scenario generation, a two-stage scenario generation method is proposed. In the first stage, the output spatial correlation of multiple wind farms is modelled by Copula function to obtain the initial output scenario of multiple wind farms. In the second stage, the randomness of wind power fluctuation is modelled by the stochastic differential equations, and the initial wind power scenario is reconstructed to ensure the wind power series in the finally obtained scenario better preserve the temporal correlation of the original series. An index system is constructed to evaluate the effectiveness of the generated scenario. The multi-fractal detrended fluctuation analysis method is introduced to provide multi-dimensional indexes for describing the autocorrelation and dynamic fluctuation characteristics of wind power series. A regional wind farm is taken as an example to generate quarterly output scenario, and results show that the proposed method can preserve the spatial-temporal correlation of original wind power series.

Key words: wind power; spatial-temporal correlation; Copula function; stochastic differential equation; multifractal; evaluation index