

基于DCC-GARCH的海上风电场出力空间相关性分析及预测

马欣¹, 吴涵², 苗安康¹, 袁越¹, 李振杰³, 郝思鹏⁴

(1. 河海大学 能源与电气学院, 江苏 南京 211100; 2. 南京工程学院 智能电网产业技术研究院, 江苏 南京 211167; 3. 电力规划设计总院, 北京 100120; 4. 南京工程学院 电力工程学院, 江苏 南京 211167)

摘要:多座海上风电场出力之间存在一定的空间相关性,构建合适的风电出力相关性模型有助于提高风电出力的预测精度。针对空间相关性具有时变特性以及难以描述和衡量,提出基于动态条件相关广义自回归条件异方差(DCC-GARCH)模型的海上风电场出力相关性模型。利用多维正态分布和DCC-GARCH模型拟合多风电场的皮尔森相关系数,求解随时间变化的风电场出力空间相关系数,在准确表征空间相关性大小的同时体现空间相关性的时序变化特征。基于DCC-GARCH模型建立多座风电场出力动态空间相关性短期预测模型。基于江苏省盐城市海上风电场数据进行算例分析,结果验证了所提方法的合理性和有效性。

关键词:空间相关性;时序特征;DCC-GARCH;空间相关性影响因素;空间相关性预测

中图分类号:TM614

文献标志码:A

DOI:10.16081/j.epae.202211029

0 引言

“双碳”目标的提出加速了电力系统能源转型进程,以风能为代表的可再生能源将逐渐成为我国乃至世界的主要一次能源形式^[1]。截至2022年3月底,我国风电累计装机容量已经达到了 3.37×10^8 kW,其中海上风电装机容量达到了 2.665×10^7 kW。然而,风电具有间歇性、随机性、波动性等特点,大规模风电并网会给电力系统的安全稳定和经济运行带来较大的影响,也会增加电网规划和调度的难度^[2],因此,有必要研究风电出力,尤其是大规模风电场出力的客观规律,从而更好地利用风能。

海上风电是集中利用风能的主要形式,风电资源集中分布,而地理位置相近的风电场的风速、风向、温度等物理量也相似^[3],这导致多座风电场出力之间具有空间相关性。深入探究多座风电场出力的空间相关性并对其进行精确合理的度量,有利于为风电出力的概率建模及预测奠定良好的基础,对于促进高比例风电并网和高风电渗透率下的电力系统规划与调度具有重要意义。

根据是否直接对风电功率进行建模可将现有风电场出力空间相关性研究方法分为间接法和直接法2类。间接法先对风速建立相关性模型,再根据风机的物理模型将风速值转换为功率值,从而构建考

虑相关性的风电出力模型^[4]。文献[5]考虑空间地理位置和地形对风速的影响,建立风速的空间相关性模型,并将得到的风速数据转换为风电功率数据。文献[6]引入特征风速的概念,通过2步相关性分析方法确定多元特征风速,降低了风电场超短期出力建模的维度。通常,间接法所需的气象信息难以采集,所需构建的风速物理模型也较复杂,在实际应用中,大多利用直接法来构建风电出力的空间相关性模型。

直接法主要是采用统计学方法,基于多座风电场的出力数据直接建立多维风电出力相关性模型。该方法首先通过皮尔森相关系数、秩相关系数等相关系数矩阵描述相关性大小^[7-8],再利用主成分分析法^[9]、协方差矩阵^[10]、Copula函数^[11-12]、贝叶斯网络^[13]等建立相关性模型。各类相关系数矩阵可以刻画多维风电出力相关性的非线性特征,但难以准确度量极端情况下的相关性。主成分分析法中的降维过程会丢失一部分数据信息,使得成分含义模糊,无法全面表征多座风电场出力的空间相关性。常见的协方差矩阵为静态模型,无法考虑数据之间的非线性联合分布。Copula函数能够有效构建多变量的相关性模型,但只适用于面板数据,难以反映相关性随时间的变化,且Copula函数构建的是概率分布模型,忽略了风电出力序列的时间自相关性。贝叶斯网络能够很好地描述多变量间的复杂相关性,但存在计算量大、计算时间长、有效性差等问题。现阶段风电出力空间相关性建模方法大多构建的是静态模型,未能考虑空间相关性的时变特性,同时目前也缺乏对多维风电出力空间相关性的预测模型及影响因素分析。综上所述,亟待提出一种考虑序列自身特性、结

收稿日期:2022-05-31;修回日期:2022-09-02

在线出版日期:2022-11-30

基金项目:江苏省高等学校基础科学(自然科学)研究项目(22KJD470003)

Project supported by the Basic Science(Natural Science) Research Project of Higher Education Institutions of Jiangsu Province(22KJD470003)

构简单且能够充分表征和衡量风电出力空间相关性的模型。

综上,本文提出一种基于时间序列的风电出力动态空间相关性模型。首先,采用广义自回归条件异方差(generalized auto regressive conditional heteroskedasticity, GARCH)模型拟合风电出力历史数据;其次,引入动态条件相关广义自回归条件异方差(dynamic conditional correlation generalized auto regressive conditional heteroskedasticity, DCC-GARCH)模型来构建多座风电场出力的多维动态条件相关(dynamic conditional correlation, DCC)系数模型,表达空间相关性的时序变化,并基于DCC-GARCH提出一种相关性预测方法,实现动态条件相关系数的多步前向预测;最后,以江苏省盐城市5座海上风电场为例,详细分析风电出力空间相关性的动态变化特征和影响因素,算例结果验证了本文所提方法的合理性和有效性。


1 海上风电场空间相关性的动态变化

风速在空间中的变化呈现连续性和相关性的特点,这使得不同位置的风电场功率间也存在一定的连续性和相关性。以江苏省盐城市大丰区5座风电场为例,具体的地理位置分布如附录A图A1所示。风电场出力数据采样间隔为1 h,根据风电场装机容量对这些数据进行标么化处理。不同位置、不同时间段各风电场功率点分布及相应的置信区间如附录A图A2、A3和图1所示。

图A2给出了海上风电场A与B、B与D、C与E出力空间相关性的置信区间,各置信椭圆的半轴数值如附录A表A1所示。风电场B与风电场D间的椭圆长轴最短,短轴最长,二者间的相关程度低于风电场A与风电场B以及风电场C与风电场E间的相关程度,这一点从风电场地理分布中也可以得出。

图A3给出了风电场A、B在1月、3月和7月的空间相关性的置信区间,各置信椭圆的半轴数值如附录A表A2所示。不同月份风电场出力的空间相关性有所不同,3月的风电场出力空间相关性显著高于1月和7月。图1给出了风电场A、B、C在1月24—26日连续3 d的空间相关性置信区间(图中功率均为标么值),每天包含24个时刻,不同置信度下的置信椭圆相关参数如附录A表A3所示。相较于1月25日和26日,1月24日的置信区间形状更偏向长椭圆,风电场出力的空间相关性更高。图1和图A3反映了风电场出力空间相关性在不同时间尺度下的动态变化,与图A3相比,图1中3座风电场出力间的空间相关性在时间尺度为天时的变化更明显,为更好地描述这种变化情况,本文建立基于DCC-GARCH的海上风电场动态空间相关性模型,并引入

动态条件相关系数来表征空间相关性在时间上的动态变化。



● 功率点, ■ 90% 置信椭圆, ■ 80% 置信椭圆, ■ 70% 置信椭圆

图1 连续3 d风电场A、B、C的功率点分布及置信区间

Fig.1 Power point distribution and confidence intervals of Wind Farm A, B and C for continuous three days

2 基于DCC-GARCH的海上风电场出力动态空间相关性模型

2.1 GARCH模型

经典的风电功率短期预测一般采用自回归滑动平均(auto regressive moving average, ARMA)模型等线性回归模型。通常要求残差序列满足白噪声假设,然而实际中某些风电出力序列的残差项常常会出现波动的集群性,这使得残差具有异方差性,并不

满足白噪声假设,且残差序列具有较高的自相关性。针对该问题,本文引入GARCH模型^[14]来描述单座风电场出力的相关性,并对其进行进一步建模,建立单座风电场出力模型GARCH(p, q)(p 为GARCH项的滞后阶数, q 为自回归条件异方差(auto regressive conditional heteroskedasticity, ARCH)项的滞后阶数),如式(1)~(3)所示。

$$P_{i,t}^w = \bar{P}_{i,t}^w + e_{i,t}^w \quad (1)$$

$$e_{i,t}^w = \sqrt{h_{i,t}^w} z_{i,t} \quad (2)$$

$$h_{i,t}^w = \omega_i + \sum_{a=1}^q \lambda_{i,a} (e_{i,t-a}^w)^2 + \sum_{b=1}^p \delta_{i,b} h_{i,t-b}^w \quad (3)$$

式中: $P_{i,t}^w$ 为 t 时刻第 i 座海上风电场出力; $\bar{P}_{i,t}^w$ 为 t 时刻第 i 座海上风电场的出力均值; $e_{i,t}^w$ 为 t 时刻第 i 座海上风电场出力的残差,满足式(2); $h_{i,t}^w$ 为 t 时刻第 i 座风电场出力时间序列的方差; $z_{i,t}$ 为独立同分布且服从(0,1)标准正态分布的随机变量; $\omega_i, \lambda_{i,a}, \delta_{i,b}$ 为参数,为保证方差为正,需满足 $\omega_i > 0, \lambda_{i,a} > 0, \delta_{i,b} > 0, \sum_{a=1}^q \lambda_{i,a} + \sum_{b=1}^p \delta_{i,b} < 1$; $e_{i,t-a}^w$ 为 t 时刻第 i 座海上风电场滞后 a 阶的模型残差,即ARCH项; $h_{i,t-b}^w$ 为 t 时刻第 i 座海上风电场滞后 b 阶的模型方差,即GARCH项。

2.2 基于DCC-GARCH的海上风电场出力空间相关性模型

为了更好地描述多座海上风电场出力间的相关性,需引入多元GARCH模型来建立多维风电场出力模型。多元GARCH模型不仅能够表现单座海上风电场出力的波动特性,还可以刻画多座风电场出力波动间的关系。常见的多元GARCH模型主要有向量误差条件异方差(vector error conditional heteroscedasticity, VEC)、常条件相关广义自回归条件异方差(constant conditional correlation generalized auto regressive conditional heteroskedasticity, CCC-GARCH)、DCC-GARCH模型等^[15]。

考虑到海上风电场出力空间相关性动态变化的实际情况,且为了尽量减少参数数量以及简化估计过程,本文采用DCC-GARCH模型来构建风电出力空间相关性模型。具体模型为:

$$P_t^w = [P_{1,t}^w \cdots P_{i,t}^w \cdots P_{k,t}^w]^T = \bar{P}_t^w + e_t^w \quad (4)$$

$$H_t^w = D_t^w R_t^w D_t^w \quad (5)$$

$$D_t^w = \text{diag}(\sqrt{h_{1,t}^w}, \dots, \sqrt{h_{i,t}^w}, \dots, \sqrt{h_{k,t}^w}) \quad (6)$$

$$R_t^w = \begin{bmatrix} \rho_{11,t} & \rho_{12,t} & \cdots & \rho_{1k,t} \\ \rho_{21,t} & \rho_{22,t} & \cdots & \rho_{2k,t} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{k1,t} & \rho_{k2,t} & \cdots & \rho_{kk,t} \end{bmatrix} = (Q_t^*)^{-1} Q_t (Q_t^*)^{-1} \quad (7)$$

$$Q_t = \left(1 - \sum_{m=1}^M \alpha_m - \sum_{n=1}^N \beta_n \right) \bar{Q} + \sum_{m=1}^M \alpha_m \xi_t \xi_t^T + \sum_{n=1}^N \beta_n Q_{t-n} \quad (8)$$

$$Q_t^* = \begin{bmatrix} \sqrt{q_{11,t}} & 0 & \cdots & 0 \\ 0 & \sqrt{q_{22,t}} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sqrt{q_{kk,t}} \end{bmatrix} \quad (9)$$

$$\bar{Q} = T^{-1} \sum_{t=1}^T \xi_t \xi_t^T \quad (10)$$

式中: k 为海上风电场数量; P_t^w 为 t 时刻海上风电场出力时间序列构成的矩阵; $\bar{P}_t^w$ 为 t 时刻海上风电场出力均值时间序列构成的矩阵; e_t^w 为 t 时刻的残差项,各残差项独立同分布,服从期望为0、协方差矩阵为 H_t^w 的条件正态分布,即 $e_t^w | \Omega_t \sim N(0, H_t^w)$, Ω_t 为 t 时刻风电出力 P_t^w 的集合; D_t^w, R_t^w 分别为 t 时刻风电场出力的标准差矩阵和动态条件相关系数矩阵; $\rho_{ij,t}(i, j=1, 2, \dots, k)$ 为 t 时刻第 i 个和第 j 个变量之间的动态条件相关系数; $Q_t = (q_{ij,t})$ 为条件协方差矩阵, Q_t^* 为对角矩阵,其元素为 Q_t 对角线元素的平方根,如式(9)所示,则 R_t^w 元素可表示为 $\rho_{ij,t} = q_{ij,t} / \sqrt{q_{ii,t} q_{jj,t}}$; α_m, β_n 为动态条件相关模型的参数, m, n 为滞后阶数; M, N 为最大滞后阶数; ξ_t 为一个 $k \times 1$ 阶的标准化后的残差向量,满足 $\xi_t = (D_t^w)^{-1} e_t^w$; $\bar{Q}$ 为 e_t^w 的无条件方差矩阵; T 为时间序列的总时刻数。式(8)为条件方差-协方差方程,用来约束 R_t^w 始终是正定的。

时间序列通常用DCC(1,1)-GARCH(1,1)模型来表示。该模型中,式(3)简化为式(11),式(8)简化为式(12),从而动态条件相关系数可以表示为式(13)。

$$h_{i,t}^w = \omega_i + \lambda_i (e_{i,t-1}^w)^2 + \delta_i h_{i,t-1}^w \quad (11)$$

$$Q_t = (1 - \alpha - \beta) \bar{Q} + \alpha \xi_{t-1} \xi_{t-1}^T + \beta Q_{t-1} \quad (12)$$

$$\rho_{ij,t} = \frac{q_{ij,t}}{\sqrt{q_{ii,t} q_{jj,t}}} = \frac{[(1 - \alpha - \beta) \bar{q}_{ij} + \alpha \xi_{i,t-1} \xi_{j,t-1} + \beta q_{ij,t-1}]}{\left\{ [(1 - \alpha - \beta) \bar{q}_{ii} + \alpha \xi_{i,t-1}^2 + \beta q_{ii,t-1}] [(1 - \alpha - \beta) \bar{q}_{jj} + \alpha \xi_{j,t-1}^2 + \beta q_{jj,t-1}] \right\}^{1/2}} \quad (13)$$

式中: λ_i, δ_i 为GARCH(1,1)模型的待估参数,满足 $\lambda_i, \delta_i > 0$; α, β 为DCC(1,1)模型中非负的待估参数, $\alpha > 0$,为前期标准化残差平方系数, $\beta > 0$,为前期条件异方差系数,满足 $\alpha + \beta < 1$; $\bar{q}_{ij}$ 为无条件协方差矩阵 $\bar{Q}$ 的第 i 行第 j 列元素; $\xi_{i,t-1}$ 为残差向量 ξ_{t-1} 的第 i 个元素。

有学者提出分别用ARMA和GARCH来描述均值与方差,构建更准确的风电出力时间序列ARMA-GARCH模型^[16]。ARMA(p, q)的典型形式为:

$$P_{i,t}^w = c_i + \sum_{a=1}^p \varphi_a P_{i,t-a}^w + \sum_{b=1}^q \theta_b e_{i,t-b}^w \quad (14)$$

式中: c_i 、 φ_a 、 θ_b 为常数系数。

本文采用ARMA(p, q)表示DCC-GARCH模型中的均值方程,在完整描述风电出力模型的同时,分析计算多座风电场出力的动态空间相关系数。选用较为常见的DCC(1,1)-GARCH(1,1)模型,得到具体的风电出力动态条件相关性模型如下:均值模型,式(2)、(14);方差模型,式(11);动态条件相关系数模型,式(5)~(7)、(9)、(10)、(12)、(13)。

3 基于DCC-GARCH的海上风电场出力空间相关性预测模型

3.1 基于DCC-GARCH的空间相关性预测模型

GARCH(1,1)模型可以直接进行风电出力协方差矩阵的 r 步前向预测,即:

$$h_{i,t+r}^w = \sum_{a=1}^{r-2} \omega_i (\lambda_i + \delta_i)^a + (\lambda_i + \delta_i)^{r-1} h_{i,t+1}^w \quad (15)$$

基于DCC-GARCH构建的海上风电场出力空间相关性模型是非线性模型,无法直接进行多步预测。目前有2种近似方法能够实现DCC-GARCH模型的预测,参考文献[17],本文选择效果更好的近似方法对海上风电场的出力空间相关性模型进行预测,具体如下。

考虑前向 r 步预测的协方差矩阵 Q_{t+r} 为:

$$\begin{cases} Q_{t+r} = (1 - \alpha - \beta) \bar{Q} + \alpha \xi_{t+r-1} \xi_{t+r-1}^T + \beta Q_{t+r-1} \\ E_t(\xi_{t+r-1} \xi_{t+r-1}^T) = E_t(R_{t+r-1}^w) \\ R_{t+r}^w = (Q_{t+r}^*)^{-1} Q_{t+r} (Q_{t+r}^*)^{-1} \end{cases} \quad (16)$$

式中: $E_t(\cdot)$ 表示期望。

假设 $\bar{Q}$ 与 $\bar{R}$ 近似相等,其中 $\bar{R} = \bar{Q}^* \bar{Q} \bar{Q}^*$, $\bar{Q}^*$ 为矩阵 $\bar{Q}$ 对角线元素的平方根构成的对角矩阵,则有 $E_t(R_{t+1}^w) = E_t(Q_{t+1})$,因此 R_{t+r}^w 的期望可以表示为:

$$E_t(R_{t+r}^w) = E_t(Q_{t+r}) = \sum_{i=0}^{r-2} (1 - \alpha - \beta) \bar{R} (\alpha + \beta)^i + (\alpha + \beta)^{r-1} R_{t+1}^w \quad (17)$$

3.2 基于DCC-GARCH的海上风电场出力空间相关性建模及预测步骤

对多座风电场出力建立DCC-GARCH模型,并进行动态空间相关性预测分析,具体步骤如下。

1) 数据处理及检验。剔除风电场出力中不合理的数据,对处理后的数据分别进行平稳性、自相关性、ARCH效应等检验。

2) 建立均值模型。采用ARMA模型建立各风电场出力的均值模型。

3) 建立方差模型。采用GARCH模型对每座风电场出力的时间序列进行方差建模,得到对应的条件方差,从而构建条件标准差矩阵 D_t^w 。

4) 标准化处理。根据已建立的ARMA模型得到各序列对应的残差序列,对其进行归一化和标准化处理。

5) 计算动态条件相关系数。将标准化残差序列代入DCC-GARCH模型,采用最大似然估计法估计参数 α 与 β ,得到动态条件相关系数矩阵 R_t^w 。

6) 基于DCC-GARCH的多步预测。对已建立的DCC-GARCH模型进行 r 步前向预测,得到动态条件相关系数的前向 r 个点预测值并进行预测误差分析。

4 算例分析

4.1 算例介绍

本文选择江苏省盐城市大丰区的国华海、华能风电、龙源丰海、三峡丰海与上电亮海这5座海上风电场作为研究对象,为便于表示,将其分别设为风电场A—E,其地理位置分布如附录A图A1所示,各风电场相关信息如附录A表A4所示。

以1h为采样间隔采集2020年全年5座风电场的出力数据,剔除不合理的数据后得到7768组数据。各风电场全年出力时序图如附录A图A4所示。盐城市位于长江三角洲地区,东临黄海,是典型的亚热带季风气候城市,该市一年四季的风力大且持久,因此各风电场全年出力基本处于较高水平。季风性气候的特点也导致该地区冬季风力强劲,夏季风力较弱,图A4中7—9月的出力高峰较少,整体出力较其余月份稍小。

4.2 数据检验

通过分别对5座风电场出力序列进行正态性检验和单位根检验发现,各序列均不服从正态分布,且在5%的显著性水平下均为平稳的时间序列,因此可以采用ARMA模型和DCC-GARCH模型进行建模分析。此外,通过统计学角度的格兰杰因果检验发现,5座风电场出力时间序列互为彼此的格兰杰因,即每座风电场出力的历史值均有助于解释另一个出力序列未来值的变化,也反映了各风电场出力的时间序列间存在较高的相关性。

4.3 DCC-GARCH模型的建立

通过对5座风电场出力时间序列进行ARMA模型拟合得到均值模型,结果如附录A表A5所示。由于DCC-GARCH模型要求残差序列具有异方差性,即ARCH效应,因此提取各时间序列ARMA模型的残差序列,并对其平方项进行自相关性检验。Ljung-Box检验和拉格朗日乘数检验表明,各残差序列均存在ARCH效应,因此可以建立DCC-GARCH模型。

针对多变量输入,建立一个5维的DCC-GARCH模型来表征5座风电场出力间的空间相关性,得到相关参数,如表1所示。在模型建好后通过再次对

标准化的残差序列进行 Ljung-Box 检验发现,各序列均不存在相关性,这说明模型已经很好地消除了数据本身存在的自相关性和异方差性。

表 1 5 维 DCC-GARCH 模型参数
Table 1 Parameters of five-dimensional DCC-GARCH model

风电场	ω_i	λ_i	δ_i	α	β
A	227.187 14	0.720 95	0.278 03		
B	366.736 12	0.765 52	0.233 48		
C	778.798 77	0.859 16	0.139 81	0.189 84	0.723 23
D	328.412 17	0.801 89	0.197 11		
E	335.057 43	0.894 09	0.104 91		

拟合结果中参数 α 和 β 均大于 0,且二者之和小于 1,这说明模型是稳定的,5 座风电场出力存在有效的动态条件相关关系。 α 表示当前残差信息对时间序列下一时刻波动性的影响程度,其值越大,时间序列对当前残差的敏感度越高。 $\alpha+\beta$ 表征风电场出力空间相关性的持续时间,其值越大,相关性的持续时间越长。从结果来看, β 拟合结果比 α 大,这说明各序列的当前动态异方差主要来源于上一期残差信息,当期信息对其影响较小。 $\alpha+\beta=0.913 07$,较接近 1,这说明该空间相关性具有较强的持续性,也反映了当前的动态条件相关性受前期的影响较大,而受当期的影响较小。

4.4 动态空间相关系数分析

1) 动态空间相关系数。

首先采用皮尔森相关系数计算每 2 座风电场全年出力数据的相关程度,得到相关系数矩阵,如附录 A 表 A6 所示。由表可知,皮尔森相关系数均大于 0.5,这表明风电场两两出力之间存在较高的空间相关性,按空间相关性由大到小排序的风电场为 C-D>D-E>C-E>A-B>A-C>B-C>B-D>A-D>A-E>B-E(C-D 表示风电场 C 与风电场 D,其他类似,后同),但表中的皮尔森相关系数是静态的,无法表征风电场出力空间相关性的时序特征。

采用 DCC-GARCH 模型计算得到风电场全年出力的动态条件相关系数,共 7 767 组,时间分辨率与风电场出力数据相同,均为 1 h。为便于表示,绘制每 2 座风电场间的动态条件相关系数图,如附录 A 图 A5 所示。图中不同时刻的动态条件相关系数变化显著,全年大部分时刻的动态条件相关系数接近 1,这说明 5 座风电场出力间存在较高的空间相关性。2 座风电场在不同时刻的空间相关系数不同,这说明动态条件相关系数能反映空间相关性的时变特点。对图中全年动态条件相关系数取平均值,结果如表 2 所示,按空间相关性由大到小排序的风电场为 C-D>D-E>A-B>C-E>B-C>A-C>B-D>A-D>B-E>A-E,与皮尔森相关系数结果大致相同,这说明动态

条件相关系数比皮尔森相关系数表征多座风电场出力的空间相关性更加准确全面。

表 2 海上风电场全年出力动态条件相关系数平均值
Table 2 Average values of dynamic conditional correlation coefficient of offshore wind farm outputs in all year

风电场	动态条件相关系数平均值	风电场	动态条件相关系数平均值
A-B	0.854 2	B-D	0.759 1
A-C	0.764 7	B-E	0.690 1
A-D	0.722 8	C-D	0.894 4
A-E	0.670 2	C-E	0.814 0
B-C	0.798 1	D-E	0.878 1

2) 动态空间相关性影响因素。

每个时刻的动态空间相关系数值由当前时刻及历史时刻的 2 座风电场出力唯一确定,而风电场出力不仅由风速、风向、距离等环境因素决定,而且受风机自身特性、人为控制等非自然环境的影响,因此,动态空间相关系数的变化也与这些影响因素有关。考虑到海上风电场气象条件变化较快、人为因素不易衡量等问题,选取部分风电场数据,重点分析风速、风向、距离对动态空间相关性的影响。

首先,考虑风速和风向变化对动态条件相关系数的影响。2020 年 1 月和 7 月风电场 A、B 的动态条件相关系数变化曲线分别如图 2 和附录 A 图 A6 所示,动态条件相关系数的峰值分别为 0.982、0.993,平均值分别为 0.850、0.878。由于风电场 A 与风电场 B 间的距离较近,采集到的风速与风向差别较小,因此统一以风电场 A 的风速和风向数据为基准,与




图 2 1 月风电场 A、B 间的动态条件相关系数与风电场 A 的风速、风向

Fig.2 Dynamic conditional correlation coefficient between Wind Farm A and B and wind speed and direction of Wind Farm A in January

态条件相关系数进行联合对比分析。由图2可知:在1月22日风速、风向发生剧烈变化,动态条件相关系数也随之变化,从09:00的0.85降至-0.13,同样的情况在1月15日、31日也出现;在冬季风盛行的1月24日至30日期间,风速处于较高水平,风向变化较为平稳,动态条件相关系数在0.91~0.96间变化,也基本处于平稳状态,若在该时间段内进行相关性预测,则有利于提高预测的精确度^[18]。对比图A6可知,由于2020年7月盐城市处于梅雨季节收尾期,沿海地区出现多次7级以上大风,这导致7月盐城市的风速和风向变化比1月更明显,整体而言,7月的动态条件相关系数大于1月,动态条件相关系数的变化也更剧烈。综上可知:当风速和风向均趋于稳定时,动态条件相关系数基本处于平稳变化状态;风速与风向中的任一因素发生剧烈变化,均会对风电功率产生显著影响,从而导致动态条件相关系数发生变化。

其次,考虑风电场间的距离对动态条件相关系数的影响。选取天气晴好、风速和风向较为稳定的2020年1月25日与26日作为研究时段,风电场A-B、A-C、B-D、B-E、C-E、D-E出力间的动态条件相关系数以及风电场A—C的风速、风向对比如图3所示。由图可知,风电场A与风电场B的风速和风向变化基本相同,而风电场C的风速和风向与风电场A、B的差别较大,在1月26日03:00—09:00时段内,




图3 多座风电场间的动态条件相关系数及风速、风向对比
Fig.3 Comparison of dynamic conditional correlation coefficient and wind speed and direction among multiple wind farms

风电场C的风速相较于风电场B出现明显时延,风电场C的风速在1 h后才基本达到风电场B的风速,结合图1可知,这主要是由于风电场A与风电场C间的距离大于风电场A与风电场B间的距离,这使得风电场C的风速与风向整体小于风电场B,从而导致风电场A与风电场C出力间的动态条件相关系数始终小于风电场A与风电场B出力间的动态条件相关系数。在风速和风向较为稳定的时段内,按动态条件相关系数由大到小排序的风电场为C-D>D-E>B-D>B-E,结合图1可知,动态条件相关系数大小与风电场间的距离基本呈正比。因此,距离也是动态条件相关系数的影响因素之一,风电场间的距离越近,动态条件相关系数越大。

4.5 基于DCC-GARCH的动态空间相关系数预测

由于海上风电场气象条件变化较快,考虑到数据的完整性及预测的准确性,参考2020年盐城市的天气变化情况,选取冬季风盛行的2020年1月数据进行动态空间相关性建模预测。测试集为2020年1月1日至26日,时间间隔为1 h,对1月27日00:00—23:00进行短期预测。

由于选取的数据影响模型参数的拟合,需要重新对测试集建立模型。经数据检验可知,测试集平稳并且具有异方差性。对测试集构建DCC(1,1)-GARCH(1,1)模型,相关参数如附录A表A7所示,5座风电场出力间存在有效的动态条件相关关系。

设定预测步长为24 h,对DCC-GARCH模型进行滚动预测,得到1月27日01:00—24:00时段5座风电场两两出力间的动态空间相关系数,时间间隔为1 h,最终得到动态条件相关系数的预测值与实际值对比,如图4和附录A图A7所示。采用均方误差(mean square error, MSE)作为预测结果的评价指标,预测误差如附录A表A8所示。由表可知,预测误差均远小于动态条件相关系数,预测结果较为准确。但由图4和图A7可知,每组风电场出力的动态空间相关系数预测值均略小于实际值,这主要是因




图4 动态条件相关系数的预测值与实际值对比
Fig.4 Comparison between predicted value and actual value for dynamic conditional correlation coefficient

为风电场出力受风速和风向影响较大,而海上风电场的风速和风向比陆地上的变化更为明显,因此不考虑风速和风向直接进行动态条件相关系数预测,这使结果较为保守。

5 结论

多座海上风电场出力间存在的空间相关性不可忽略,对风电场运维与电网调度有很大影响。本文基于DCC-GARCH模型建立空间相关性的时序模型,引入动态条件相关系数衡量空间相关性的大小,并建立动态条件相关系数短期预测模型。基于实际海上风电场数据说明空间相关性存在的时序特性,并分析动态条件相关系数的影响因素,结果表明:采用DCC-GARCH模型计算得到的动态条件相关系数能够表征空间相关性的大小,并准确体现空间相关性随时间变化的动态特征;风速、风向、风电场间距离对动态空间相关系数有显著影响。本文通过DCC-GARCH模型实现了对空间相关系数的短期预测,预测结果较为准确。在后续研究中,笔者将进一步考虑如何提高特殊天气情况下的预测精度等问题,以提高模型的适用性。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 谭显东,刘俊,徐志成,等. “双碳”目标下“十四五”电力供需形势[J]. 中国电力,2021,54(5):1-6.
TAN Xiandong, LIU Jun, XU Zhicheng, et al. Power supply and demand balance during the 14th five-year plan period under the goal of carbon emission peak and carbon neutrality[J]. Electric Power, 2021, 54(5): 1-6.
- [2] 齐晓光,姚福星,朱天瞳,等. 考虑大规模风电接入的电力系统混合储能容量优化配置[J]. 电力自动化设备,2021,41(10):11-19.
QI Xiaoguang, YAO Fuxing, ZHU Tiantong, et al. Capacity optimization configuration of hybrid energy storage in power system considering large-scale wind power integration[J]. Electric Power Automation Equipment, 2021, 41(10): 11-19.
- [3] 陈宁,薛禹胜,丁杰,等. 利用空间相关性的超短期风速预测[J]. 电力系统自动化,2017,41(12):124-130.
CHEN Ning, XUE Yusheng, DING Jie, et al. Ultra-short term wind speed prediction using spatial correlation[J]. Automation of Electric Power Systems, 2017, 41(12): 124-130.
- [4] 杨茂,代博社. 基于比恩法的风电场风速-功率曲线建模误差分析[J]. 电力自动化设备,2020,40(12):81-89.
YANG Mao, DAI Bozhi. Modeling error analysis of wind speed-wind power curve for wind farm based on Bins method[J]. Electric Power Automation Equipment, 2020, 40(12): 81-89.
- [5] 胡帅,向月,沈晓东,等. 计及气象因素和风速空间相关性的风电功率预测模型[J]. 电力系统自动化,2021,45(7):28-36.
HU Shuai, XIANG Yue, SHEN Xiaodong, et al. Wind power prediction model considering meteorological factor and spatial correlation of wind speed[J]. Automation of Electric Power Systems, 2021, 45(7): 28-36.
- [6] 胡阳,李倩,房方,等. 基于有限差分运行域的风电场全风况超短期出力动态区间建模[J]. 电网技术,2022,46(4):1346-1357.
HU Yang, LI Qian, FANG Fang, et al. Dynamic interval modeling of ultra-short-term output of wind farm based on finite difference operating domains[J]. Power System Technology, 2022, 46(4): 1346-1357.
- [7] 徐潇源,严正,冯冬涵,等. 基于输入变量秩相关系数的概率潮流计算方法[J]. 电力系统自动化,2014,38(12):54-61.
XU Xiaoyuan, YAN Zheng, FENG Donghan, et al. Probabilistic load flow calculation based on rank correlation coefficient of input random variables[J]. Automation of Electric Power Systems, 2014, 38(12): 54-61.
- [8] 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.
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.
- [9] LE D D, GROSS G, BERIZZI A. Probabilistic modeling of multisite wind farm production for scenario-based applications[J]. IEEE Transactions on Sustainable Energy, 2015, 6(3): 748-758.
- [10] 李运龙,李志刚,郑杰辉. 考虑风电不确定性和相关性的多区域电网分布鲁棒经济调度[J]. 电力自动化设备,2021,41(8):97-104.
LI Yunlong, LI Zhigang, ZHENG Jiehui. Distributionally robust economic dispatch of multi-regional power grid considering uncertainty and correlation of wind power[J]. Electric Power Automation Equipment, 2021, 41(8): 97-104.
- [11] 马燕峰,李鑫,刘金山,等. 考虑风电场时空相关性的多场景优化调度[J]. 电力自动化设备,2020,40(2):55-65.
MA Yanfeng, LI Xin, LIU Jinshan, et al. Multi-scenario optimal dispatch considering temporal-spatial correlation of wind farms[J]. Electric Power Automation Equipment, 2020, 40(2): 55-65.
- [12] 廖芷燕,李银红. 基于R藤Copula-DBN时空相关性建模的风光功率概率预测[J]. 电力自动化设备,2022,42(3):113-120.
LIAO Zhiyan, LI Yinrong. Probabilistic forecasting of wind-photovoltaic-load power based on temporal-spatial correlation modelling of Regular Vine Copula-DBN[J]. Electric Power Automation Equipment, 2022, 42(3): 113-120.
- [13] 王洪涛,李晓刚,邹斌. 基于贝叶斯网络刻画风-光-荷相关性的配电网概率潮流计算[J]. 中国电机工程学报,2019,39(16):4753-4763,4977.
WANG Hongtao, LI Xiaogang, ZOU Bin. Probabilistic load flow calculation of distribution system based on Bayesian network to depict wind-photovoltaic-load correlation[J]. Proceedings of the CSEE, 2019, 39(16): 4753-4763, 4977.
- [14] BOLLERSLEV T. Generalized autoregressive conditional heteroskedasticity[J]. Journal of Econometrics, 1986, 31(3): 307-327.
- [15] ENGLE R F, KRONER K F. Multivariate simultaneous generalized ARCH[J]. Econometric Theory, 1995, 11(1): 122-150.
- [16] 刘帅,朱永利,张科,等. 基于误差修正ARMA-GARCH模型的短期风电功率预测[J]. 太阳能学报,2020,41(10):268-275.
LIU Shuai, ZHU Yongli, ZHANG Ke, et al. Short-term wind power forecasting based on error correction ARMA-GARCH model[J]. Acta Energiae Solaris Sinica, 2020, 41(10): 268-275.
- [17] ENGLE R, SHEPPARD K. Theoretical and empirical properties of dynamic conditional correlation multivariate GARCH[R]. Cambridge, MA, USA: National Bureau of Economic Research, 2001.
- [18] 杨正甄,冯勇,熊定方,等. 基于季风特性改进风电功率预测的

研究展望[J]. 智能电网,2015,3(1):1-7.

YANG Zhengling, FENG Yong, XIONG Dingfang, et al. Research prospects of improvement in wind power forecasting based on characteristics of monsoons[J]. Smart Grid, 2015, 3(1):1-7.

作者简介:

马欣(1998—),女,硕士研究生,主要研究方向为可再生能源、主动配电网规划(E-mail:1150013949@qq.com);



马欣

吴涵(1990—),男,讲师,博士,通信作者,研究方向为主动配电网规划运行、可再生能源出力预测(E-mail:wuhanichina@vip.qq.com);

袁越(1966—),男,教授,博士研究生导师,博士,主要研究方向为主动配电网、综合能源(E-mail:yyuan@hhu.edu.cn)。

(编辑 王锦秀)

Spatial correlation analysis and prediction of offshore wind farm output based on DCC-GARCH

MA Xin¹, WU Han², MIAO Ankang¹, YUAN Yue¹, LI Zhenjie³, HAO Sipeng⁴

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China;

2. Smart Grid Industry Technology Research Institute, Nanjing Institute of Technology, Nanjing 211167, China;

3. China Electric Power Planning & Engineering Institute, Beijing 100120, China;

4. School of Electric Power Engineering, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: There exists certain spatial correlation between the outputs of multiple offshore wind farms, it is helpful for improving the prediction accuracy of wind power output to construct suitable wind power output correlation model. Aiming at that the spatial correlation has time-varying characteristic and is difficult to describe and measure, an output correlation model of offshore wind farm is proposed based on dynamic conditional correlation generalized autoregressive conditional heteroskedasticity (DCC-GARCH) model. The multi-dimensional normal distribution and DCC-GARCH model are used to fit Pearson correlation coefficient of multiple wind farms, the spatial correlation coefficient of wind farm output which varies with the time is solved, which accurately represents the size of spatial correlation while reflects the time-varying characteristic of spatial correlation. A short-term prediction model of output dynamic spatial correlation for multiple wind farms is built based on DCC-GARCH model. Case analysis is carried out based on the data of offshore wind farms in Yancheng City, Jiangsu Province, and results verify the rationality and effectiveness of the proposed method.

Key words: spatial correlation; temporal characteristics; DCC-GARCH; influencing factors of spatial correlation; spatial correlation prediction

附录 A:




图 A1 海上风电场地理位置
Fig.A1 Location of offshore wind farms




图 A2 部分风电场风电功率点分布及其置信区间
Fig.A2 Power point distribution and confidence interval of some wind farms




图 A3 1 月、3 月和 7 月风电场 A、B 的功率点分布及置信区间
Fig.A3 Power point distribution and confidence interval of Wind Farm A and B in January, March, and July

表 A1 风电场 A-B、B-D、C-E 全年出力置信椭圆参数

Table A1 Parameters of confidence ellipses of annual outputs of Wind Farm A-B, B-D, C-E

半轴	置信区间/%	半轴长度		
		A-B 全年	B-D 全年	C-E 全年
长半轴	90	0.868	0.852	0.946
	80	0.726	0.712	0.791
	70	0.628	0.616	0.684
短半轴	90	0.164	0.205	0.175
	80	0.137	0.171	0.146
	70	0.119	0.148	0.126

注：半轴以椭圆的二维正交坐标系为基准；半轴长度为标么值，后同。

表 A2 1 月、3 月、7 月风电场 A、B 出力置信椭圆参数

Table A2 Parameters of confidence ellipses of Wind Farm A and B outputs during January, March and July

半轴	置信区间/%	半轴长度		
		1 月	3 月	7 月
长半轴	90	0.766	0.938	0.892
	80	0.640	0.784	0.746
	70	0.553	0.678	0.645
短半轴	90	0.162	0.137	0.153
	80	0.135	0.115	0.128
	70	0.117	0.099	0.11

表 A3 连续 3 d 风电场 A、B、C 出力置信椭球参数

Table A3 Parameters of confidence ellipsoids of Wind Farm A, B and C outputs during January 24 to 26

半轴	置信区间/%	半轴长度		
		A-B-C 1 月 24 日	A-B-C 1 月 25 日	A-B-C 1 月 26 日
半轴 1	90	0.850	0.503	0.659
	80	0.718	0.425	0.557
	70	0.631	0.373	0.489
半轴 2	90	0.079	0.179	0.120
	80	0.067	0.151	0.101
	70	0.059	0.133	0.089
半轴 3	90	0.050	0.086	0.095
	80	0.043	0.072	0.080
	70	0.037	0.063	0.070

表 A4 海上风电场相关信息
Table A4 Parameters of offshore wind farms

风电场	装机容量/MW	离岸距离/km	经度/ (°)	纬度/ (°)
A	300	42	121.385	32.981
B	400	55	121.436	33.101
C	400	45	121.291	33.483
D	300	72	121.593	33.324
E	300	40	121.101	33.511




图 A4 海上风电场全年出力时序图

Fig.A4 Time sequence diagrams of offshore wind farms output in all year

表 A5 均值模型拟合结果
Table A5 Fitting results of mean models

风电场	拟合模型	φ_1	θ_1	θ_2
A	ARMA (1,2)	0.933 4	0.077 5	-0.026 2
B	AR (1)	0.936 5	—	—
C	ARMA (1,1)	0.928 5	0.083 2	—
D	AR (1)	0.930 2	—	—
E	ARMA (1,2)	0.933 8	0.066 5	-0.036 4

表 A6 每 2 座风电场全年出力数据间的皮尔森相关系数

Table A6 Pearson correlation coefficient between output data of every two wind farms during the year

风电场	皮尔森相关系数				
	风电场 A	风电场 B	风电场 C	风电场 D	风电场 E
A	1	—	—	—	—
B	0.928 9	1	—	—	—
C	0.915 6	0.909 8	1	—	—
D	0.881 5	0.888 3	0.955 6	1	—
E	0.872 8	0.858 8	0.934 1	0.946 3	1




图 A5 海上风电场全年出力动态条件相关系数图

Fig.A5 Dynamic conditional correlation coefficient diagrams of offshore wind farm outputs in all year





图 A6 7 月风电场 A、B 间动态条件相关系数与风电场 A 的风速、风向

Fig.A6 Dynamic conditional correlation coefficient between Wind farm A and B and wind speed and direction of Wind farm A in July


表 A7 测试集 5 维 DCC-GARCH 模型参数

Table A7 Parameters of five-dimensional DCC-GARCH model for test set


风电场	ω	λ	δ	α	β
A	343.94	0.980 95	0.010 24	0.264 67	0.614 48
B	938.02	0.914 04	0.025 09		
C	2467.7	0.835 23	0.064 25		
D	1225.4	0.905 77	0.051 21		
E	872.56	0.779 70	0.122 00		



(a) B-C、B-D



(b) B-E、C-D



(c) C-E、D-E

图 A7 动态条件相关系数预测值与实际值对比

Fig.A7 Comparison between predicted value and actual value for dynamic conditional correlation coefficient

表 A8 动态条件相关系数预测误差

Table A8 Prediction errors of dynamic correlation coefficient

风电场	MSE	风电场	MSE
A-B	1.497×10^{-5}	A-C	4.069×10^{-5}
A-D	5.918×10^{-5}	A-E	1.052×10^{-4}
B-C	5.109×10^{-6}	B-D	7.924×10^{-6}
B-E	1.868×10^{-5}	C-D	1.520×10^{-6}
C-E	9.164×10^{-5}	D-E	1.328×10^{-4}