

基于混合半云模型的风速-功率曲线建模方法

杨茂¹, 张罗宾¹, 崔杨¹, 杨琼琼², 黄宾阳³

(1. 东北电力大学 现代电力系统仿真控制与绿色电能新技术教育部重点实验室, 吉林 吉林 132012;

2. 国网陕西省电力有限公司宝鸡供电公司, 陕西 宝鸡 721004;

3. 国网重庆市电力有限公司检修分公司, 重庆 400039)

摘要: 风速-功率曲线的准确建模是风电机组出力态势评估和风电功率预测的关键基础之一。计及风电映射关系的不确定性及功率曲线的分布形态, 提出一种基于混合半云模型的建模策略来实现对风功率数据固有和随机分布特征的挖掘和建模。引入最优组内云熵算法快速有效地剔除异常数据; 采用逆向云发生器求期望、熵与超熵数字特征来定量刻画风速-功率对应关系的不确定性, 构建腰部数据的半云模型; 通过X条件云发生器和正向云发生器分别求取腰部部和上部数据的功率云滴, 实现定性数字特征向定量数据的转换。以中国东北某大型风电场的实测数据为例, 从数据质量、频率分布和功率预测等维度分析混合半云模型, 验证了所提方法的可行性。

关键词: 混合半云模型; 风速-功率曲线; X条件云发生器; 最优组内云熵算法; 不确定性预测

中图分类号: TM 614

文献标志码: A

DOI: 10.16081/j.epae.202005004

0 引言

截至2019年底, 中国风电并网容量累计达到 2.1×10^8 kW^[1], 已成为现代电力系统的主力新能源之一。然而, 原动力的弱可控性和风机转化效率的时变性^[2-3]是制约以风电为代表的新能源体系发展的瓶颈。受风速与功率映射关系不确定性^[4]的影响, 风速-功率数据对在统计域上呈现出“带状”的分布特征^[5], 其导致风机输出功率的波动性, 对电网的稳定运行施加了无序冲击。风机功率曲线建模是量化风速-功率转化机制^[6]、评估风机发电性能^[7]及支持以风速为先导的风电功率预测^[4]的核心环节, 为缓解新能源电力系统调度压力提供了决策^[8]。

风速-功率曲线本质为描述风速与功率转换关系的映射集合^[9-10]。按照建模思路的不同, 风功率曲线构建主要包含5类方法: ①以异常数据清洗为先行工作的功率曲线特性分析, 如置信等效边界法^[11]; ②以连续过程近似代替离散过程的离散方法, 如离散随机函数^[12]; ③以构造一个含参数的概率模型作为问题解的随机方法, 如蒙特卡洛模拟^[5]、马尔科夫链^[13]; ④以建立具体数学表达式为基础的参数法, 如四参数法^[14]、改进双曲正切法^[15]; ⑤以数据驱动为主要特征的非参数法^[10], 如Copula理论^[7]、核密度估计^[16]、高斯过程^[17]、神经网络^[18]等。此外, 混合法^[19]

以及多场景(如考虑时序差异、风向多变性)策略^[20-21]等也用于功率曲线的建模。现有研究已对风速-功率曲线建模进行了大量探索。然而, 传统建模方法对现阶段风机运行工况复杂、不确定性因素多等特点考虑不全, 目前参数法仍存在无法量化风机出力不确定性等不足, 亟需优化风速-功率耦合关系不确定性的量化机制, 现有方法的主要缺陷如下。

缺陷1: 风电场数据的内蕴误差会对建模效果产生较大影响, 若直接使用未清洗的数据, 则会引起功率曲线参数偏移。另外, 单一Copula函数难以完全捕获风功率数据的不确定性^[11]。

缺陷2: 参数法为理想状态下设定的时不变系数^[14], 仅能表征风机出力的均值特性, 无法全面反映样本的不确定性。

缺陷3: 数据驱动模型通过网络层间的反复迭代挖掘样本特征, 存在训练耗时、参数调整繁琐、预测趋势光滑等问题^[20], 背离了风功率散点的随机性。

实际上, 受多重复杂因素的影响^[2], 不同风速段下的功率散点呈现出显著的离散性和随机性^[22], 分别对应客观样本边界的混沌性和发生的概率, 故风功率散点分布的不确定性才是其本质属性。但目前大多统计分析和数据驱动方法仅实现了从定量数据挖掘定性概念的单向认知过程。1995年, 李德毅教授提出云模型理论^[23], 较好地揭示出客观样本与抽象概念间的双向变换过程, 充分挖掘了数据中所蕴含的模糊性和随机性。

鉴于上述情形, 本文引入一种基于混合半云模型的不确定性风机功率曲线建模方法。通过最优组内云熵算法对异常数据进行清洗; 在此基础上, 采用逆向云发生器BCG(Backward Cloud Generator)求

收稿日期: 2019-12-27; **修回日期:** 2020-03-05

基金项目: 国家重点研发计划项目(促进可再生能源消纳的风电/光伏发电功率预测技术及应用)(2018YFB0904200)

Project supported by the National Key R&D Program of China(Technology and Application of Wind Power/Photovoltaic Power Prediction for Promoting Renewable Energy Consumption)(2018YFB0904200)

取期望、熵、超熵等数字特征来量化风电转换关系的不确定性;结合X条件云发生器、正向云发生器分别求取指定风速下的腰部、上部功率云滴,建立还原功率曲线的混合半云模型。选取中国东北某风电场的历史数据作为测试样本,从拟合误差和功率频率分布等方面进行模型有效性检验,验证了混合半云模型可兼顾风机出力的整体性和不确定性。

1 云模型理论

引入云模型的定性-定量双向转换机制,可评价不同风速段对应功率的整体数字特征和离散度。

1.1 正态云

设 U 为一个用确定数值组成的定量论域, C 是 U 上的定性概念,若定量值 $x \in U$ 为 C 的一次随机实现,同时 x 对 C 的隶属度满足:

$$\mu(x) = e^{-\frac{(x-E_x)^2}{2E_n^2}} \quad (1)$$

即 $\mu: U \in [0, 1], \forall x \in U, x \rightarrow \mu(x)$,则 x 在论域 U 上的分布称为正态云,记作 $C(x)$,其中每个 x 称为一个云滴。云模型分别通过期望 E_x 、熵 E_n 和超熵 H_e 这三个数字特征刻画云滴分布的重心位置、度量定性概念的不确定性以及描述云滴的凝聚度。

1.2 逆向云发生器

逆向云发生器可求取样本分布特征(E_x, E_n, H_e),将一组已知的数据映射为相应的数字特征。

(1)已知隶属度。此时云模型参数可采用已知隶属度逆向云求取,具体步骤如下。

a.调用MATLAB拟合包,获得样本的近似表达式为 $y = a \exp\left\{-\left[\frac{(v_i - b)/c}{c'}\right]^2\right\}$,其中 a, b, c 为拟合式中的系数, v_i 为输入风速值。

b.逐渐调整步骤a公式中的 c 值大小,使包络线 $y_{1/2} = a \exp\left\{-\left[\frac{(v_i - b)/c'}{c'}\right]^2\right\}$ 包围区域达到实测数据的98%左右,此时 c' 即为所求。

c.输出3个数字特征:风速功率散点中腰部样本的期望、熵、超熵分别为 $E_{xw} = b, E_{nw} = c, H_{ew} = \Delta c/3$,其中 $\Delta c = |c' - c|$ 。

(2)未知隶属度。此时参数求解流程如下。

a.当风机输出功率在额定值附近随机波动,并假设具有正态统计特性时,其均值可表示为:

$$E_{xw} = \frac{1}{N} \sum_{i=1}^N p_i \quad (2)$$

其中, N 为功率样本数量; p_i 为第 i 个功率值。

功率数据二阶中心距为:

$$c_2 = \frac{1}{N-1} \sum_{i=1}^N (p_i - E_{xw})^2 \quad (3)$$

功率数据四阶中心距为:

$$c_4 = \frac{1}{N-1} \sum_{i=1}^N (p_i - E_{xw})^4 \quad (4)$$

b.云模型上部数据的熵和超熵分别为:

$$E_{nu} = \sqrt{\frac{9c_2^2 - c_4}{6}} \quad (5)$$

$$H_{eu} = \sqrt{c_2 - \sqrt{\frac{9c_2^2 - c_4}{6}}} \quad (6)$$

1.3 正向云发生器

正向云发生器能够完成从数字特征向定量数据的转化,即输入风速值 v_i 及其3个数字特征 E_{xw}, E_{nw} 和 H_{ew} ,输出风机功率 p_i ,即:

$$p_i = \text{randn}(1)(\text{randn}(1)H_{eu} + E_{nu}) + E_{xw} \quad (7)$$

其中, $\text{randn}(1)$ 表示服从方差为1、均值为0的高斯分布。

1.4 X条件云发生器

X条件云发生器是指在正向云的基础上,已知特定的X,求取腰部云滴,具体生成步骤如下。

步骤1:由熵和超熵产生一个正态随机熵 $E'_{nw} \sim N(E_{nw}, H_{ew}^2)$ 。

步骤2:求取指定风速情况下的功率云滴 $p_i = a \exp\left[-\left(\frac{v_i - E_{xw}}{E'_{nw}}\right)^2\right]$ ($i = 1, 2, \dots, N$)。

步骤3:重复步骤1和步骤2,直至生成所有指定风速下的功率。

2 异常数据处理

实测风电场样本中往往存在异常数据,众多功率曲线建模方法显式或隐含地假设其不会明显改变原始数据的统计规律,但异常数据会影响样本的真实数字特征^[6],易造成风功率的统计特性偏移和风电转变规律畸变等问题。

2.1 风电机组风速-功率曲线

施加于风机上的风速是影响功率输出的主要因素,本文不考虑机组的内部转化特性,而仅考虑输入风速 v_{in} 和风机输出功率 p_{out} 的关联性:

$$p_{out} = f(v_{in}) \quad (8)$$

以中国东北某风电场数据采集与监视控制(SCADA)系统的2015年出力数据为例,其中包含时间跨度为4个月、采样粒度为10 min的风速和功率值,绘制某风机的实测及标准功率曲线,见图1。

综上所述,风速-功率曲线有以下基本特征。

(1)“厂形”阶段性。基于该特性,可将功率曲线划分为腰部和上部2个区段。

(2)不确定性。风功率散点在标准功率曲线两侧随机分布,不完全按照既定轨迹运行。

(3)弱离散性。散点分布的偏移范围较窄,并伴随异常数据出现。在异常类型上,包括随机干扰等产生的离散型以及限功率运行等导致的聚集型;在分布位置上,正常数据的上下部均存在异常数据。

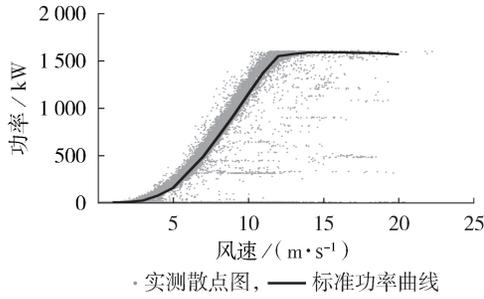


图1 单机实测风速-功率曲线与标准功率曲线对比图

Fig.1 Comparison between actual measured wind speed-power curve of single wind turbine and standard power curve

为减小异常数据对风速-功率建模过程的干扰,本文采用最优组内云熵算法^[6]作为异常数据剔除的决策规则。

2.2 最优组内云熵决策

最优组内云熵算法的实质是利用每个分组内云模型的最优熵值来辨识出偏离风功率标准值的样本点。若给定风速、功率样本集合 G ,令 $T = \{T_1, T_2, T_3\}$ 为研究对象,其中 T_1, T_2, T_3 分别为功率偏小、偏大及正常的集合,满足 $T_1 \cap T_2 \cap T_3 = \emptyset$ 且 $T_1 \cup T_2 \cup T_3 = G$,具体识别流程如下。

步骤1:风速分组表示。以 0.5 m/s 为窗宽将风速划分为 M 段,有 $G = \{G(1), G(2), \dots, G(M)\}$,对各风速段下所对应的功率进行云分组表示。假设 $G(i) = \{(v_1, p_1), (v_2, p_2), \dots, (v_n, p_n)\}$ 内有 n 个风速-功率数据对,对其降序排列,得到新的风速-功率数据对 $G'(i) = \{(v'_1, p'_1), (v'_2, p'_2), \dots, (v'_n, p'_n)\}$,且满足 $p'_i < p'_{i+1}$ 。

步骤2:求取云模型的熵。将 $G(i)$ 中前 k ($k \in (2, n)$)个功率点输入逆向云中,输出云模型的期望、熵和超熵。取熵所处的云分段序列,共 $n-1$ 个采样点,为保证样本的完整,设定第一个采样点对应的熵值为0。

步骤3:异常数据辨识。将熵值曲线斜率陡升、陡降点对应的熵分别作为上界阈值 T_h 及下界阈值 t_h ,找到大于 T_h 的熵值所对应的点 v_u 以及小于 t_h 的熵值所对应的点 v_l ,小于 v_u 的视为上部异常样本,大于 v_l 的视为下部异常样本,剩余为正常样本,即可分离云分组 $G(i)$ 内的不同类型数据。

步骤4:对其余区间重复步骤1—3,由此实现异常数据与正常数据的分离。

3 不确定性风速-功率曲线的混合半云建模框架

3.1 数据预处理及划分

(1)风电异常数据预处理。利用最优组内云熵算法对风机异常数据进行识别,通过熵值曲线设定

云区间内的阈值,各云区间的最大和最小阈值视其所在区间的具体情况而定,以保证算法识别效果最佳。

(2)数据划分。由图1可知,风功率曲线具有显著的不对称特征。但传统云模型属于对称分布模型,无法直接用于功率曲线建模,鉴于此,本文对预处理后的不对称风速-功率曲线进行如下区间划分:

a.取风机功率在区间 $[0.05 P_r, 0.98 P_r)$ (P_r 为风机额定功率, $0.98 P_r$ 为风机功率保证值)的样本作为腰部数据;

b.取风机功率大于等于 $0.98 P_r$ 的样本作为上部数据。

3.2 模型构建

考虑到功率曲线腰部与平台部分映射关系的不对称形态特征,同时体现腰部与上部风速对功率输出的作用差异,通过半云模型对腰部数据进行还原,由此构建混合半云模型。

以预处理后的风功率数据为样本,风机功率曲线混合半云模型的构建框架如图2所示。图中, v_n 为风机额定风速(理论上恰好达到风机额定输出功率时的风速); v_{out} 为切出风速。

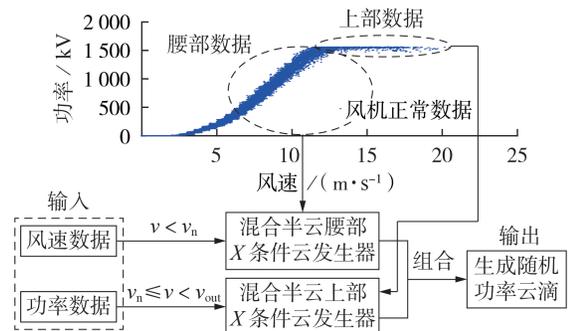


图2 混合半云模型构建框架

Fig.2 Framework of hybrid half-cloud model construction

3.3 模型参数求取

(1)构造映像样本。以原始腰部样本为基础,为便于求取其数字特征,对腰部数据构造映像样本。

首先,设腰部风速集合为:

$$W = \{v \mid V_{\min} \leq v \leq V_{\max}\} \quad (9)$$

其对称映像样本可表示为:

$$W' = \{v' \mid v' = 2V_{\max} - v, v \in W\} \quad (10)$$

合并2个区段的风速数据,并保留对应位置的功率值,得到对称的腰部样本分布为:

$$W_{\Sigma} = W \cup W' \quad (11)$$

其中, V_{\min}, V_{\max} 分别为最小及最大风速值; W_{Σ} 为腰部对称化分布集合。

(2)已知隶属度逆向云发生器求取腰部参数。在所述模型中,由于已知腰部数据的隶属度,利用MATLAB对风速-功率散点进行高斯拟合,并获得拟合式和包络线,进而求取其腰部参数。

(3)未知隶属度逆向云发生器求取上部参数。将上部数据投影至纵轴时,其隶属度未知,采用未知隶属度的逆向云获取上部参数。

3.4 随机功率云滴生成

当 $v < v_n$ 时,风速与功率之间存在明显的递增关系,采用 X 条件云输出腰部云滴;当 $v_n \leq v < v_{out}$ 时,采用正向云输出上部功率云滴。以上述求取的数字特征 E_{xw} 、 E_{nw} 、 H_{ew} 与 E_{xu} 、 E_{nu} 、 H_{eu} 为约束条件,取一组风速作为输入,云滴生成过程分别见 1.3 和 1.4 节。

4 算例分析

4.1 数据准备

选取东北某风电场的 33 台风机为研究对象,以图 1 中的风机为例,对其 2015 年 3 月至 6 月的 10 min 级实测风速、功率数据进行分析。风机基本参数如下:额定装机容量为 1.5 MW,切入、额定及切出风速分别为 2、10、23 m/s。

采用混合半云模型及相应评价指标进行功率曲线量化建模,研究内容为:①混合半云模型建模误差分析;②功率频率分布;③风电转换不确定性预测。

4.2 算例验证

首先使用最优组内云熵算法对风机异常数据进行识别,辨识效果见图 3。以云区间 8 为例,附录 A 中图 A1 和图 A2 分别为其熵值曲线及异常数据的辨识结果。剔除上、下部异常数据,各云区间的平均剔除率在 15% 左右,得到预处理后的实测风速-功率散点。

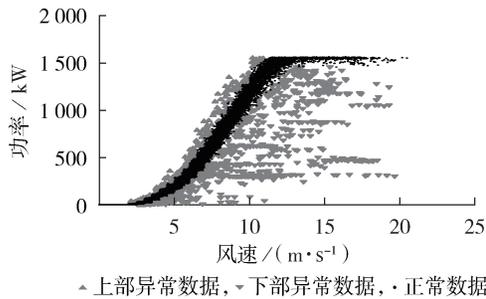


图 3 风电机组异常数据识别结果

Fig.3 Recognition results of abnormal data for wind turbine

然后,对清洗后的数据进行划分,获得两部分功率数据见附录 A 中图 A3,同时将切入风速、分界点风速及额定功率分别修正为 3.77、11.76 m/s 及 1520 kW。

利用 3.3 节所述的参数求取方法,当包络概率为 97.795% 时,得到腰部样本的拟合过程及其参数分别如图 4 和附录 A 中表 A1 所示。

故可求取腰部数据的参数如附录 A 中表 A2 所示。附录 A 表 A3 为上部数据参数,云模型 E_{xu} 愈大,风机期望输出功率值愈高;而熵值越小,表示风机状态越平稳,出力波动越小。

分别采用 X 条件云和正向云模型生成两部分云

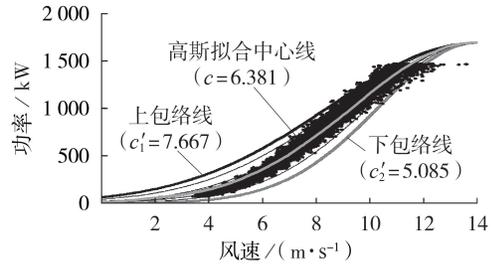


图 4 腰部样本的高斯拟合过程图

Fig.4 Schematic diagram of Gaussian fitting process for waist sample

滴,结果见图 5,从附录中表 A2 和图 5 可知,腰部数据的超熵为 0.432,有 $3H_c = 3 \times 0.432 < E_n = 6.381$,呈现出“泛正态”分布状态,腰部散点总体呈“尖峰厚尾”形态,风速愈小对应的功率愈离散;随着风速增大,额定风速下的功率云滴表现出良好的凝聚性,在物理上解释为未达到额定风速前,风电转换不稳定等因素导致的腰部风速-功率对应关系较模糊。同时,上部云滴较分散,其超熵达到 4.212,符合上部实测数据的定性特征。因此,超熵可用于定量描述风机出力的稳定性。为验证该模型的通用性,对另一风电场的单机实测数据进行混合云建模,结果见附录 B 中表 B1、B2 和图 B1。

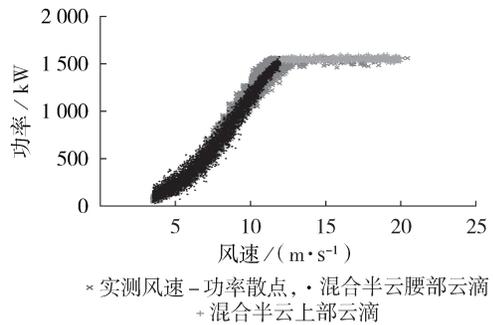


图 5 基于混合半云模型的不确定性风速-功率曲线

Fig.5 Uncertainty wind speed-power curve based on hybrid half-cloud model

4.3 建模误差分析

4.3.1 拟合优度检验

(1)残差值。将生成的云滴及历史功率按升序排列,定义混合半云功率云滴集合的残差值检验公式:

$$r_w = \sum_{i=1}^N |p'_w(i) - p_w(i)| \quad (12)$$

其中, $p'_w(i)$ 、 $p_w(i)$ 分别为第 i 个腰部逆向云生成的数据及历史功率样本。

(2)拟合优度。为评价混合半云刻画风速-功率散点的合适程度,引入拟合优度检验:

$$\chi^2 = \left[1 - \frac{r_w}{\sum_{i=1}^N (p_w(i) - \bar{p}_w)^2} \right] \times 100\% \quad (13)$$

其中, \bar{p}_w 为样本均值。可近似认为 χ^2 越大, 模型的拟合优度越好。

4.3.2 精度评价方法

定义平均绝对误差(MAE)、平均绝对误差百分比(MAPE)和均方根误差(RMSE)作为建模性能评价指标^[12]。

$$\delta_{MAE} = \frac{1}{N} \sum_{i=1}^N |P_e(i) - P_r(i)| \quad (14)$$

$$\delta_{MAPE} = \frac{1}{N} \sum_{i=1}^N \frac{|P_e(i) - P_r(i)|}{(|P_e(i)| + |P_r(i)|)/2} \times 100\% \quad (15)$$

$$\delta_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_e(i) - P_r(i))^2} \quad (16)$$

其中, δ_{MAE} 、 δ_{MAPE} 、 δ_{RMSE} 分别为 MAE、MAPE 和 RMSE; $P_e(i)$ 、 $P_r(i)$ 分别为第 i 个模拟样本及实测功率样本。

4.3.3 误差分析

为与本文模型对比, 根据建模思路的不同, 计及数据质量的影响, 设置 2 个对比场景进行误差分析。

场景 1: 剔除异常数据, 选取原始数据构成建模样本, 对最大值法(记为模型 1)、K-means 聚类法(记为模型 2)、高斯拟合法(记为模型 3)、本文方法(记为模型 4)进行对比。

场景 2: 剔除异常数据, 将最优组内云熵预处理后的数据构成测试样本, 对最大值法(记为模型 5)、K-means 聚类法(记为模型 6)、高斯拟合法(记为模型 7)、本文方法(记为模型 8)进行对比。本文更关注于异常数据剔除与否, 而不局限于清洗算法的对比。

(1) 腰部残差值与拟合优度检验。表 1 给出了不同建模方法的对比结果, 剔除异常数据后, 风速-功率散点分布趋于集中, 所述模型的残差值为 156.07 kW, 拟合优度为 99.12%, 其中残差值较未处理之前误差降低了 65.9%, 体现出异常数据清洗的必要性; 相较于模型 5—7, 本文模型的残差值分别减少了 2 768.77、298.48、236.57 kW, 拟合优度分别提高了 6.71%、6.09%、2.17%。综上, 相较于 3 种单值映射功率曲线, 混合半云生成的随机散点与实测值更加贴合, 拟合效果更好。

表 1 不同模型残差值与拟合优度对比

Table 1 Comparison of residuals and goodness fitting among different models

模型	残差值 / kW	拟合优度 / %
无预处理	1	5261.93
	2	761.97
	3	638.69
	4	457.64
预处理	5	2924.84
	6	454.55
	7	392.64
	8	156.07

(2) 上部建模性能评价指标。各模型误差见表 2。

表 2 不同模型建模误差

Table 2 Modeling errors of different models

模型	δ_{MAE} / kW	δ_{MAPE} / %	δ_{RMSE} / %
无预处理	1	20.46	1.35
	2	164.78	11.42
	3	9.75	1.29
	4	5.28	0.82
预处理	5	18.47	1.22
	6	11.59	1.01
	7	7.06	0.86
	8	2.15	0.39

从表 2 可以发现, 预处理后, 混合半云模型的 MAE、MAPE、RMSE 较其余 3 种方法分别平均降低了 10.2 kW、0.64%、7.24%, 建模误差基本是按照最大值法、K-means 聚类法、高斯拟合法、混合半云模型的顺序依次递减。

4.4 风电功率频率分布分析

在实测风速下, 由场景 2 中不同模型生成的风功率频率分布如图 6 所示。为了有效对比各类模型功率频率分布的差异, 分别计算 4 种方法与实测功率的线性相关系数, 结果如表 3 所示。

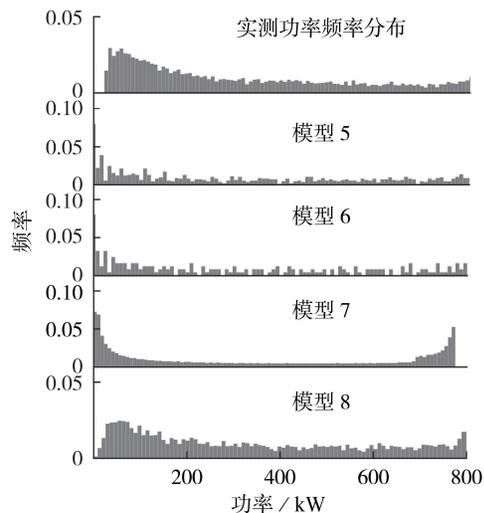


图 6 不同模型下的风电功率频率分布

Fig.6 Wind power frequency distribution of different models

表 3 风功率频率分布相关性

Table 3 Correlation of wind power frequency distribution

方法	频率相关系数	方法	频率相关系数
最大值法	0.6811	高斯拟合法	0.7580
K-means 聚类法	0.6930	本文方法	0.9060

从图 6 及表 3 可知, 与最大值法与 K-means 聚类法相比, 混合半云模型的功率频率分布形态与实测值更为接近, 且比高斯拟合法更能反映实测功率频率分布的不确定性, 其中本文方法与实测功率的相关系数达到 0.906, 而拟合法仅为 0.758。因此, 本文方

法在频率分布及风机整体运行特性上有一定优势。

4.5 风电功率不确定性预测分析

以风速预测为先导的风电功率预测能够为电网调度决策、备用安排等提供指导信息。在忽略各机组风速空间分散性的前提下,以某一10 min采样粒度的实测风速序列为输入,将其分别传入混合半云模型及理论功率曲线,生成整场风电功率超短期预测(对未来4 h的出力进行多步预测)结果,并以基于参数法、半参数法的概率预测模型作为2种对比方法,预测结果如图7及附录B中表B3所示。

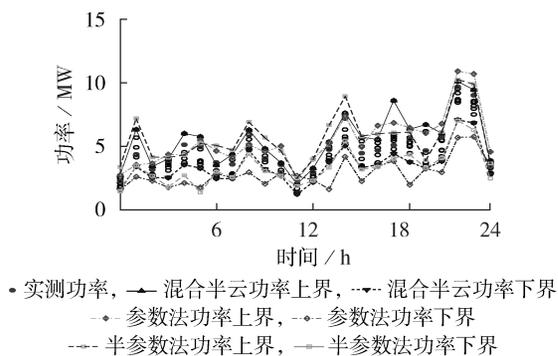


图7 风电功率预测结果对比

Fig.7 Comparison of wind power prediction results

从图7可以看出:混合半云模型可输出随机功率点值,更加符合实际风电功率的不确定性,由此生成的不确定性功率预测区间亦可为系统调度提供相应的出力预测信息;混合半云功率上、下界均可较好地反映实测功率的变化趋势,偏差点是由上、下界为预测功率可能出现的极值引起的均值偏移所致。采用文献[20]中的精度评价指标,得到如附录中表B3所示的预测误差结果,相较于参数法和半参数法(90%置信度下),混合半云模型的区间覆盖率平均提高了6.2%,而区间带宽则下降了5.8%,能够更有效地覆盖实测出力范围,显示出了不确定性混合半云功率曲线在风电功率区间预测上的优势。

5 结论

风速-功率散点的不确定性增加了功率曲线建模复杂度,本文基于异常数据处理驱动的混合半云模型对风机功率曲线进行建模,主要结论如下。

(1)经风电场实测数据验证,混合半云模型应用于不确定性风功率曲线建模具有较高的精度,相比于最大值法、K-means聚类法、高斯拟合法以及无数据预处理法,其MAE、MAPE、RMSE分别平均降低了8.45 kW、0.59%、6.16%,这表明期望、熵、超熵等统计特征适用于定量描述风机出力的整体性和不确定性。

(2)混合半云模型能够有效应用于风电场输出功率的建模与不确定性预测,风电场出力位于某一功率带中,可为电网调度提供更多可用信息。

(3)风速-功率散点映射关系的数字特征随时空推移可能会发生改变,未来还需考虑动态因素的影响;风机运行状态有客观内蕴复杂性,故应将云模型与其他不确定理论相结合,揭示风机出力的整体行为。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 国家能源局. 2019年风电并网运行情况[EB/OL]. [2020-03-03]. http://www.nea.gov.cn/2020-02/28/c_138827910.htm.
- [2] 陈昊,高山,王玉荣,等. 基于广义自回归条件异方差偏度峰度模型的风电功率预测方法[J]. 中国电机工程学报, 2017, 37(12):3456-3461, 3673.
CHEN Hao, GAO Shan, WANG Yurong, et al. Wind power forecasting method based on generalized autoregressive conditional heteroskedasticity with skewness and kurtosis model[J]. Proceedings of the CSEE, 2017, 37(12):3456-3461, 3673.
- [3] 杨茂,黄宾阳,江博,等. 基于卡尔曼滤波和支持向量机的风电功率实时预测研究[J]. 东北电力大学学报, 2017, 37(2): 45-51.
YANG Mao, HUANG Binyang, JIANG Bo, et al. Real-time prediction for wind power based on Kalman filter and support vector machines[J]. Journal of Northeast Dianli University, 2017, 37(2):45-51.
- [4] 王勃,冯双磊,刘纯. 考虑预报风速与功率曲线因素的风电功率预测不确定性估计[J]. 电网技术, 2014, 38(2): 463-468.
WANG Bo, FENG Shuanglei, LIU Chun. Uncertainty evaluation of wind power prediction considering impacts of power curve and predicted wind speed[J]. Power System Technology, 2014, 38(2):463-468.
- [5] YAN J, ZHANG H, LIU Y Q, et al. Uncertainty estimation for wind energy conversion by probabilistic wind turbine power curve modelling[J]. Applied Energy, 2019, 239:1356-1370.
- [6] 杨茂,杨琼琼. 基于云分段最优熵算法的风电机组异常数据识别研究[J]. 中国电机工程学报, 2018, 38(8): 2294-2301, 2539.
YANG Mao, YANG Qiongqiong. The identification research of the wind turbine abnormal data based on the cloud segment optimal entropy algorithm[J]. Proceedings of the CSEE, 2018, 38(8):2294-2301, 2539.
- [7] GILL S, STEPHEN B, GALLOWAY S. Wind turbine condition assessment through power curve Copula modeling[J]. IEEE Transactions on Sustainable Energy, 2012, 3(1):94-101.
- [8] 黎静华,黄玉金,黄乾. 基于改进混沌时间序列的风电功率区间预测方法[J]. 电力自动化设备, 2019, 39(5):53-60, 68.
LI Jinghua, HUANG Yujin, HUANG Qian. Interval prediction method of wind power based on improved chaotic time series [J]. Electric Power Automation Equipment, 2019, 39(5): 53-60, 68.
- [9] 杨茂,杨琼琼. 风电机组风速-功率特性曲线建模研究综述[J]. 电力自动化设备, 2018, 38(2):34-43.
YANG Mao, YANG Qiongqiong. Review of modeling of wind speed-power characteristic curve for wind turbine[J]. Electric Power Automation Equipment, 2018, 38(2):34-43.
- [10] CARRILLO C, OBANDO MONTAÑO A F, CIDRÁS J, et al. Review of power curve modelling for wind turbines[J]. Renewable and Sustainable Energy Reviews, 2013, 21:572-581.
- [11] 胡阳,乔依林. 基于置信等效边界模型的风功率数据清洗方法[J]. 电力系统自动化, 2018, 42(15):18-23, 149.
HU Yang, QIAO Yilin. Wind power data cleaning method based on confidence equivalent boundary model[J]. Automata-

- tion of Electric Power Systems, 2018, 42(15):18-23, 149.
- [12] JIN Y Q, JU P, REHTANZ C, et al. Equivalent modeling of wind energy conversion considering overall effect of pitch angle controllers in wind farm[J]. Applied Energy, 2018, 222: 485-496.
- [13] BÖTTCHER F, PEINKE J, KLEINHANS D, et al. Handling systems driven by different noise sources: implications for power curve estimations[M]//PEINKE J, SCHAUMANN P, BARTH S. Wind Energy. Berlin, Germany: Springer, 2007: 179-182.
- [14] FEIJOO A, VILLANUEVA D. Four-parameter models for wind farm power curves and power probability density functions [J]. IEEE Transactions on Sustainable Energy, 2017, 8(4): 1783-1784.
- [15] TASLIMI-RENANI E, MODIRI-DELSHAD M, ELIAS M F M, et al. Development of an enhanced parametric model for wind turbine power curve[J]. Applied Energy, 2016, 177: 544-552.
- [16] 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.
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.
- [17] PANDIT R K, INFELD D, CARROLL J. Incorporating air density into a Gaussian process wind turbine power curve model for improving fitting accuracy[J]. Wind Energy, 2019, 22(2): 302-315.
- [18] MANOBEL B, SEHNKE F, LAZZÚS J A, et al. Wind turbine power curve modeling based on Gaussian processes and artificial neural networks[J]. Renewable Energy, 2018, 125: 1015-1020.
- [19] YESILBUDAK M. Implementation of novel hybrid approaches for power curve modeling of wind turbines[J]. Energy Conversion and Management, 2018, 171: 156-169.
- [20] 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, 5522.
- 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, 5522.
- [21] YOU M D, LIU B J, BYON E, et al. Direction-dependent power curve modeling for multiple interacting wind turbines [J]. IEEE Transactions on Power Systems, 2018, 33(2): 1725-1733.
- [22] 吴晓刚, 孙荣富, 乔颖, 等. 基于风电场功率特性的风电预测误差分布估计[J]. 电网技术, 2017, 41(6): 1801-1807.
WU Xiaogang, SUN Rongfu, QIAO Ying, et al. Estimation of error distribution for wind power prediction based on power curves of wind farms [J]. Power System Technology, 2017, 41(6): 1801-1807.
- [23] 陈绍南, 陈碧云, 韦化, 等. 改进混合半云模型在不规则风速概率分布拟合中的应用[J]. 电力自动化设备, 2017, 37(4): 60-66.
CHEN Shaonan, CHEN Biyun, WEI Hua, et al. Application of improved mixed half cloud model in probability distribution fitting for irregular wind speed [J]. Electric Power Automation Equipment, 2017, 37(4): 60-66.

作者简介:



杨 茂

杨 茂(1982—),男,吉林吉林人,教授,博士,研究方向为电力系统稳定控制、风电功率预测(E-mail: yangmao820@163.com);

张罗宾(1994—),男,山东临沂人,硕士研究生,研究方向为电力系统分析及新能源发电技术(E-mail: 1447303581@qq.com)。

(编辑 王锦秀)

Wind speed-power curve modeling method based on hybrid half-cloud model

YANG Mao¹, ZHANG Luobin¹, CUI Yang¹, YANG Qionqiong², HUANG Binyang³

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology, Ministry of Education, Northeast Electric Power University, Jilin 132012, China;

2. Baoji Power Supply Company of State Grid Shaanxi Electric Power Company, Baoji 721004, China;

3. Maintenance Branch of State Grid Chongqing Electric Power Supply Company, Chongqing 400039, China)

Abstract: Accurate wind speed-power curve modeling is one of the key basics for situation assessment of wind turbine output and wind power forecasting. Considering the uncertainty of wind power mapping relationship and the distribution pattern of power curve, a modeling strategy based on HHC (Hybrid Half-Cloud model) is proposed for mining and modeling of the inherent and random distribution characteristics of wind power data. The OSCE (Optimal Segmentation Cloud Entropy) algorithm is introduced to eliminate the abnormal data quickly and effectively. The backward cloud generator is adopted to obtain the digital characteristics of expectation, entropy and hyper-entropy for quantify the uncertainty of wind speed-power relationship, and a semi-cloud model of waist data is constructed. The power cloud droplets of waist and upper data are calculated by X condition cloud generator and forward cloud generator respectively, and the transformation from the qualitative features to quantitative data is realized. Taking the measured data of a large scale wind farm in Northeast China as an example, HHC is analyzed from the perspectives of data quality, frequency distribution and wind power forecasting, which verifies the feasibility of the proposed method.

Key words: hybrid half-cloud model; wind speed-power curve; X condition cloud generator; optimal segmentation cloud entropy algorithm; uncertainty forecasting

附录 A:

云区间 8 的熵值曲线及异常数据分离结果分别如图 A1、A2 所示。

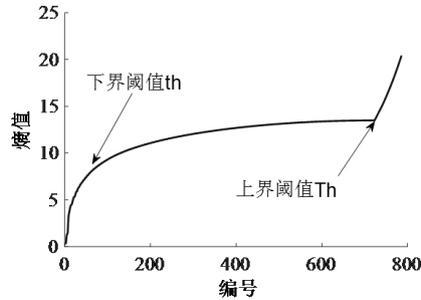


图 A1 云区间 8 的熵值曲线

Fig.A1 Entropy curve of Cloud segmentation 8

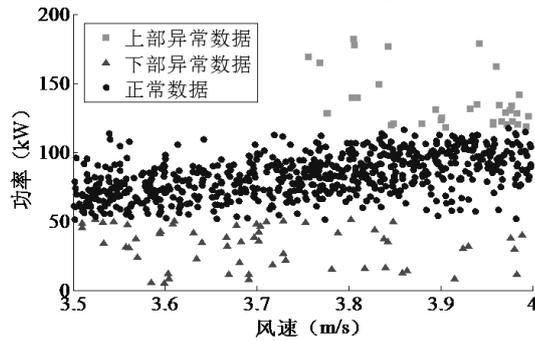


图 A2 云区间 8 的数据分离结果

Fig.A2 Data separation results of Cloud segmentation 8

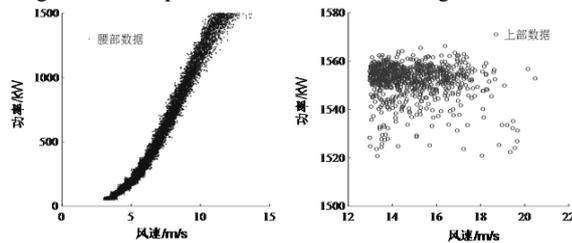


图 A3 功率数据划分结果

Fig.A3 Results of wind power data dividing

表 A1 腰部拟合参数

Table A 1 Fitting parameters of waist sample

曲线	a	b	c
拟合曲线	1685	13.970	6.381
拟合包络线	1685	13.970	7.677
拟合对称包络线	1685	13.970	5.085

表 A2 混合半云模型腰部参数

Table A2 Waist parameters of hybrid half-cloud model

E_{xu}	E_{nu}	H_{eu}
13.970	6.381	0.432

表 3 混合半云模型上部量化参数

Table A3 Upper parameters of hybrid half-cloud model

E_{xu}	E_{nu}	H_{eu}
1 545.330	14.793	4.212

附录 B:

另一含有 33 台风机的风电场中 29 号风机实测数据为例，采样时间为 2016 年 2 月至 4 月的 10 min 级风速、功率样，得到具体参数与建模结果分别如表 B1、B2 与图 B1 所示，实测功率与模拟功率的相关性在 0.9 以上，验证了混合半云模型的通用性。

表 B1 混合半云模型腰部参数 (29 号风机)

Table B1 Waist parameters of hybrid half-cloud model (Wind turbine No.29)

E_{xw}	E_{nw}	H_{ew}
13.380	6.107	0.421

表 B2 混合半云模型上部参数 (29 号风机)

Table B2 Upper parameters of hybrid half-cloud model (Wind turbine No.29)

E_{xu}	E_{nu}	H_{eu}
1 547.520	10.922	5.180

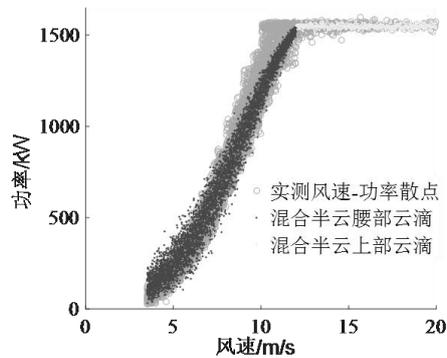


图 B1 29 号风机的不确定性混合半云功率曲线建模结果

Fig.B1 Uncertainty power curve modeling of Wind turbine No.29 based on hybrid half-cloud model

混合半云模型及理论功率曲线的风电转换误差如附表 1 所示。

表 B3 风电功率不确定性预测误差对比

Table B3 Comparison of wind power uncertainty prediction errors

方法	区间覆盖率/%	平均宽度百分比/%
参数法	87.50	41.96
半参数法	91.67	40.91
本文方法	95.83	35.63