

基于Critic权重法与反熵权法组合的风电功率概率 预报

屈伯阳¹, 李宏伟², 付立思²

(1. 沈阳工业大学电气工程学院, 沈阳 110870; 2. 沈阳农业大学信息与电气工程学院, 沈阳 110866)

摘要: 为了提升风电功率概率区间预报性能, 提出了一种基于Critic权重法与反熵权法(anti-entropy weight method)的变带宽混合滑动 Gaussian 核密度估计(variable bandwidth hybrid sliding Gaussian kernel density estimation, VHSKDE(Gaussian))与正态滑动指数迭代估计(normal sliding exponential iteration, NSEI)组合的风电功率区间概率预报方法。该组合方法简称为 VHSKDE(Gaussian)-NSEI。首先, 通过基于变分模态分解与长短期记忆神经网络(variational mode decomposition-long short-term memory, VMD-LSTM)点预报得到偏差。然后, 分别利用 VHSKDE(Gaussian)和 NSEI 估计预报偏差的概率分布, 得出对应的置信概率下的预报区间。最后, 利用4种客观权重赋值法分别对 VHSKDE(Gaussian)环节及 VHSKDE(Gaussian)-NSEI 组合环节进行两次加权组合生成最终的风电功率预报区间。研究结果表明, VHSKDE(Gaussian)-NSEI 预报模型在不同置信度情况下能够兼顾 PICP 与 PIAW 的优良性能, 与 NSEI 和 VHSKDE(Gaussian)相比具有更高的可靠性和准确性, 为风电功率概率预报提供了重要参考。

关键词: 风电功率; 概率预报; Critic; 反熵权法; 均方积分偏差; 核密度估计

Probability Prediction of Wind Power Based on the Combination of Critic Weight Method and Anti-Entropy Weight Method

QU Boyang¹, LI Hongwei², FU Lisi²

(1. School of Electrical Engineering, Shenyang University of Technology, Shenyang 110870, China; 2. College of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110866, China)

Abstract: In order to improve the performance of wind power probability interval prediction, a wind power interval probability prediction method is proposed which is the combination of variable bandwidth hybrid sliding Gaussian kernel density estimation (VHSKDE(Gaussian)) and normal sliding exponential iteration (NSEI) based on critical weight method and anti-entropy weight method. The combination method is called VHSKDE(Gaussian)-NSEI for short. Firstly, the error is obtained by point prediction based on variational mode decomposition and long short-term memory neural network(VMD-LSTM). Then, VHSKDE(Gaussian) and NSEI are used to estimate the probability distribution of the prediction errors, and forecast interval is obtained under corresponding confidence probability. Finally, four objective weight assignment methods are used to weight the VHSKDE(Gaussian) link and the VHSKDE(Gaussian)-NSEI combination link twice to generate the final wind power prediction interval. The research results show that the excellent performances of PICP and PIAW can be compatible by using the proposed VHSKDE(Gaussian)-NSEI prediction model under different levels of confidence. The VHSKDE(Gaussian)-NSEI prediction model has higher reliability and accuracy than NSEI and VHSKDE(Gaussian), and provides an important reference for wind power probability prediction.

Key words: wind power; probability prediction; Critic; anti-entropy method; mean integrated square error; kernel density estimation

基金项目: 国家自然科学基金资助项目(52007124); 辽宁省兴辽英才计划项目(XLYC2008005)。

Foundation item: Supported by the National Natural Science Foundation of China(52007124); the Xing Liao Ying Cai Project of Liaoning Province (XLYC2008005).

0 引言

输出功率的随机性是风电面对一系列并网问题的根本要素之一,风电功率概率预报方法近年来得到了广泛关注和研究。由于风电功率点预报值未能足够反映风电输出功率的随机性,以风电功率点预报为前提的调度措施难以顾及风电波动导致的后果。概率预报是凭借风电随机性的风电功率预报方法,它通过针对风电功率的后验概率分布进行预报,以概率形式考量将来分别不同时刻风电功率预报的波动范畴,有益于在考虑风电随机性的规划问题中做出可靠的决策,从而补充确定性预报欠缺随机性信息的不足。

风电功率概率预报是对风电功率随机性进行建模。目前比较广泛的采用以点预报的结果看作概率预报的基准,依据点预报的偏差作为实验的首要目标,得到偏差的预报区间或概率分布函数后,然后将该区间植入在原本的点预报结果上,产生点与不同置信概率区间组合的预报结果。

当前,已有许多研究人员对风电功率点预报做了大规模研究,关键包括物理法和统计法。此中,物理方法依据数值天气预报信息对风机临近的物理信息进行连贯,实施较为复杂。统计方法运用相应的历史时间功率序列等信息进行预报。现存的统计方法参考如下,文献[1]提出一种基于时空相关性的风电功率超短期自适应预报方法,预报结果更加准确。文献[2-5]针对深度学习开发了多种改进模型进行风电预报。文献[6]所提出的 VMD-LSTM 风电功率预报方法显著优于其他基准方法,并在风电场功率预报的准确性和稳定性方面提供了非常满意的预报结果。

为了拟合风电预报偏差的概率分布,使用正态分布近似函数是适用的。文献[7]运用高斯过程回归模型、分块缓存与更新方法实现参数拟合更新。文献[8]提出了一种基于 Beta 混合概率分布的风力发电预报偏差区间估计方法,根据 Beta 分布的特点更加准确地估计了风力发电预报偏差的分布模型。尽管参数方法可以简单直接地预报风力发电的预报偏差,但当项目内的实际偏差分布不遵循先验分布模型时,估计值就会出现偏差。

非参数方法通常不需要实施有关预报偏差分布的先验假设,每个点的概率由实际数据决定。文献[9]

提出时序混合密度网络,较准确地确定风力发电预报偏差的概率密度函数。文献[10]采用动态 R 藤 Copula 的拓扑结构进行风电概率预测,具有一定的优势。文献[11]建立了基于径向基神经网络的分位数回归模型,完成天气预报变量与风力发电之间的非线性映射。文献[12]提出了一种多窗宽核密度估计方法,根据不同的置信水平生成不同窗宽的核密度估计,以实现风电发电量的超短期自适应随机预报。文献[13]提出了一种基于分位数回归的新型遗忘门长短期记忆(NFGLSTM)网络和结合核密度估计的风力发电功率概率预报方法。文献[14]表明,将 Epanechnikov 核函数与各种最优窗宽选择方法相结合,选择最优窗宽可以提高预报精度。文献[15]提出基于扩散的核密度估计器(DiE)用于实现非平稳风电时间序列的高质量区间预报。DiE 配备了模糊推理系统和三级自适应功能。文献[16]提出了一种使用无偏交叉验证方法进行带宽选择的新型核密度估计器(KDE)模型,用于估计风速和太阳辐照度概率密度。证实了所提出模型的核密度估计的准确性和鲁棒性。非参数方法在预测模型精度上有一定劣势。在估计风电预报偏差的概率分布时,参数方法和非参数方法各有优缺点,两者结合可以在一定程度上互补^[17]。

针对上述研究现状,本文提出一种基于改进正态分布的滑动指数迭代估计参数法(normal sliding exponential iterative, NSEI)和变带宽混合滑动核密度估计非参数法(variable bandwidth hybrid sliding kernel density estimation, VHSKDE(Gaussian))的风电功率概率组合预报方法。该方法首先利用变分模态分解与长短期记忆神经网络组合预报方法(VMD-LSTM)得到风电功率精准的点预报值;然后分别用 NSEI 和 VHSKDE(Gaussian)组合方法对 VMD-LSTM 的点预报偏差分布^[6]进行概率化建模,以获得确切精准的不同置信度概率预报区间;最后利用 Critic 权重法和反熵权法(anti-entropy weight method)进行加权整合,以获得预报精度更高的概率预报结果。以东北某沿海风电场实测数据为案例,证实本文研究的方法有效提升了风电功率概率区间预报的精度。

1 研究理论

1.1 正态滑动指数迭代估计

假定风电功率点预报偏差 ξ 满足均值为 μ , 标

准差为 σ 的正态分布(normal distribution),在特定置信度下的置信区间上、下限可以表示为:

$$\hat{Q}_{t+1}(1-\alpha/2) = \mu + z_{1-\alpha/2}\sigma \quad (1)$$

$$\hat{Q}_{t+1}(\alpha/2) = \mu - z_{1-\alpha/2}\sigma \quad (2)$$

式中: $z_{1-\alpha/2}$ 为标准正态分布参数; $\hat{Q}_{t+1}(1-\alpha/2)$ 和 $\hat{Q}_{t+1}(\alpha/2)$ 分别为置信概率的上分位数和下分位数; α 为显著性水平。

正态分布系数 μ 和 σ 对区间预报的性能至关重要,属于典型的参数法估计。目前针对正态分布系数的确定主要采用之前 n 个时刻的预报偏差得以确定,此时存在问题:计算 $t+1$ 时刻的预报偏差分布时,通常将 t 时刻到 $t-n+1$ 时刻的偏差进行均值处理;但实际上待预报时间段近邻范围内的预报偏差值与较远时刻相比起到的作用更大,较远时刻偏差会对正态估计的准确性产生一定程度的干扰。因此,引入滑动指数迭代方法改进正态分布参数估计(NSEI)。

通过滑动指数迭代方法可以对待预报时刻正态分布参数 σ_{t+1} 进行更为精确的估计。该方法依据滑动指数进行加权,偏差平方权值呈现指数级降低,表达式如下。

$$\sigma_{t+1}^2 = \zeta \xi_t^2 + (1-\zeta)\sigma_t^2 \quad (3)$$

式中: ξ_t 为 t 时刻预报偏差; σ_t 为 t 时刻预报偏差概率分布的标准差; ζ 为平滑参数, $0 < \zeta < 1$ 。

式(3)经过多次展开迭代如下。

$$\sigma_{t+1}^2 = \zeta \xi_t^2 + \zeta(1-\zeta)\xi_{t-1}^2 + \zeta(1-\zeta)^2\xi_{t-2}^2 + \dots + \zeta(1-\zeta)^{t-1}\xi_1^2 + (1-\zeta)^t\sigma_1^2 \quad (4)$$

式中 $\sigma_1^2 = \xi_1^2$ 。

$t+1$ 时刻预报偏差在 $1-\alpha$ 的置信概率的上分位数 $\hat{Q}_{t+1}(1-\alpha/2)$ 和下分位数 $\hat{Q}_{t+1}(\alpha/2)$ 分别可表示为:

$$\hat{Q}_{t+1}(1-\alpha/2) = \mu + z_{1-\alpha/2}\sigma_{t+1} \quad (5)$$

$$\hat{Q}_{t+1}(\alpha/2) = \mu - z_{1-\alpha/2}\sigma_{t+1} \quad (6)$$

因此,置信概率为 $1-\alpha$ 的置信区间为:

$$[L_1, U_1] = [P_{\text{pred}} + \hat{Q}_{t+1}(\alpha/2), P_{\text{pred}} + \hat{Q}_{t+1}(1-\alpha/2)] \quad (7)$$

式中: U_1 为置信区间上限; L_1 为置信区间下限; P_{pred} 为风电功率点预测值。

1.2 变带宽混合滑动核密度估计

由于风电的随机性和波动性,风电预报偏差值概率分布相似或部分服从正态分布,概率预报的精

度会受到一定程度影响。然而,以核密度估计(kernel density estimation, KDE)为研究目标的非参数估计方法无需进行某种概率分布模式设定,通常以实际点预报所得到的偏差数据进行建模,进而得到偏差概率分布函数或概率密度函数,该方法相较于参数化估计更具有普适性。

核密度估计是利用未知随机变量来估计其拟合的概率密度函数(probability density function, PDF),无需知晓该随机变量受制于何种分布函数以及先验知识,仅受限于样本数据本身进行估计。设风电功率点预报偏差样本空间为 x ,即概率预报模型的输入。概率密度函数为 $\hat{f}(X)$, X 为独立同分布的随机变量,表示对预报集再预报的偏差。

核密度估计函数 $\hat{f}(X)$ 表示如下。

$$\hat{f}(X) = \frac{1}{Nh} \sum_{i=1}^N K\left(\frac{X-x_i}{h}\right) = \frac{1}{N} \sum_{i=1}^N K_h(X-x_i) \quad (8)$$

式中: x_i 为风电功率点预报偏差的单个观测值; $K(\cdot)$ 为权重核函数,且 $K_h(X-x_i) = K(X-x_i/h)/h$; h 为带宽(BW),决定密度函数 $\hat{f}(X)$ 的光滑程度; N 为偏差样本数量。因此带宽选择对于基于核密度估计概率预报性能发挥显著作用。

核函数主要包含伊潘涅切科夫核函数(Epanechnikov)、四次项核函数(Biweight)、高斯核函数(Gaussian)、Cosine核函数及三角核函数(Triangle)。通常采用智能算法寻优来确定BW,但该方法存在适应性不强、计算效率低以及易陷入局部最优等相关问题。针对BW的选择,应以均方偏差(mean square error, MSE)为衡量标准,使得 $\min(\hat{f}(x) - f(x))$,即求解最优BW为 h^* 。 $f(x)$ 为偏差样本空间所对应的概率密度函数(PDF), $\hat{f}(x)$ 为表示估计的PDF。针对MSE进行积分,即均方积分偏差(mean integrated square error, MISE),以此求解整个定义域内最优 h^* 。

$$\begin{aligned} M'(h) &= \int M(\hat{f}(x))dx \\ &= \frac{\zeta}{nh} + \frac{1}{4} \int (f''(x))^2 dx \xi^2 h^4 + o\left(\frac{1}{nh}\right) + o(h^4) \end{aligned} \quad (9)$$

最优带宽 h^* 为:

$$h^* = \arg \min M'(h) \quad (10)$$

式中: $f''(x)$ 为 x 处的二阶导数; ξ 为 $\int u^2 K(u)du$ 的

平方积分; ζ 为 $\int K^2(u)du$ 的平方积分; $M'(h)$ 为均方积分偏差(MISE)的近似值; $M(\cdot)$ 为均方偏差函数; $o(\cdot)$ 为高阶无穷小函数。

利用移动窗宽对偏差样本进行核密度估计时,窗宽值过大或者过小也会对核密度估计的性能产生影响。可以从两个方向考虑普通核密度估计方法:其一,选择最优的 BW;其二,在风电功率预报偏差中,待预报时间段近邻范围内的预报偏差值作用更突出。

针对两方面问题,本文采用变带宽混合和滑动窗宽的组策略来进一步优化普通核密度估计非参数化方法,提出了变带宽混合滑动核密度估计(VHSKDE)。

所谓“变带宽混合”是依据差异带宽核密度估计获得的预报偏差概率密度函数,按照合适的权重系数对概率密度函数实行加权叠加构成。权重系数用 Critic 权重法实行判断。基于差异带宽计算获得的概率密度函数具备不同的偏差,采用偏差叠加效能机制彼此弥补,使得组合概率密度函数 $f_{\text{VHSKDE}}(x)$ 更准确的估计概率预报偏差,表达式如下。

$$\hat{f}_k(x) = \frac{1}{Nh_k} \sum_{i=1}^N K\left(\frac{x - x_i}{h_k}\right) \quad (11)$$

$$f_{\text{VHSKDE}}(x) = \sum_{k=1}^M \beta_k \hat{f}_k(x) \quad (12)$$

式中: h_k 为第 k 个带宽; $\hat{f}_k(x)$ 为采用 h_k 估计出的概率密度函数; M 为带宽数量; β_k 为 $\hat{f}_k(x)$ 的权重系数,且满足:

$$\sum_{k=1}^M \beta_k = 1 \quad (13)$$

“滑动”是指核密度估计样本依据时间序列按照滑动方式转换。假如考虑计算基于滑动核密度的时间 $t+1$ 处的预报偏差概率密度函数,则使用的样本是最接近时间 $t+1$ 的 n 个时刻。预报偏差是从 $t-n+1$ 到时间 t 的预报偏差。对于 $t+1$ 时刻特殊设定带宽的核密度估计,预报偏差概率密度函数解析式如式(14)所示。

$$\hat{f}_{k,t+1}(X) = \frac{1}{nh_k} \sum_{i=1}^n K\left(\frac{X - x_i}{h_k}\right) \quad (14)$$

结合以上两种思路,得到了变带宽混合滑动核密度估计公式。针对 $t+1$ 对应时刻的预报偏差概率密度函数的具体解析式如下:

$$f_{\text{VHSKDE},t+1}(X) = \sum_{k=1}^M \beta_k \hat{f}_{k,t+1}(X) \quad (15)$$

对 $f_{\text{VHSKDE},t+1}(X)$ 进行积分可获得累积分布函数 $F_{\text{VHSKDE},t+1}(\xi)$, 接下来可以计算获得置信区间解析式为:

$$[L_2, U_2] = [P_{\text{pred}} + \hat{F}_{\text{VHSKDE}}(\alpha_1), P_{\text{pred}} + \hat{F}_{\text{VHSKDE}}(\alpha_2)] \quad (16)$$

式中: L_2 和 U_2 分别由此通过 VHSKDE 方法获得的置信区间对应的上限和下限; $\alpha_1 = \alpha/2$; $\alpha_2 = 1 - \alpha/2$; $\hat{F}_{\text{VHSKDE}}(\cdot)$ 为 $F_{\text{VHSKDE}}(\xi)$ 的反函数^[18]。

基于变带宽混合滑动核密度估计有针对性的克服规则核密度带宽和固定样本窗宽度面向估计精度影响的关键窘境,因而可以考虑亟需运用该方法作出更为恰当的概率预报。

1.3 Critic 权重法

Critic 权重法是 Diakoulaki(1995)提议的一种从客观的角度来衡量赋予相应权重的科学方法^[19]。该方法是基于对比度和矛盾(冲突)性来解释说明。对比度以标准差的形式来表现,表明了在同一指标内各方案的取值差距的大小。从研究背景角度出发,冲突性是考虑参数相关性的一种论证手段。当参数间存在强正相关性时,冲突性处于较低的水平。

首先对参数进行正向化及规范化,即设有 m 个待评对象, e 个评价指标,可以构成数据矩阵 $X = (x_{ij})_{m \times e}$, 设数据矩阵内元素经过指标正向化处理后的元素为 x'_{ij} 。

若 x_j 为负向指标(越小越优型指标),则有:

$$x'_{ij} = \frac{\max(x_j) - x_{ij}}{\max(x_j) - \min(x_j)} \quad (17)$$

若 x_j 为正向指标(越大越优型指标),则有:

$$x'_{ij} = \frac{x_{ij} - \min(x_j)}{\max(x_j) - \min(x_j)} \quad (18)$$

之后计算信息承载量,用标准差表示第 j 项指标的对比性。

$$\sigma_j = \sqrt{\frac{\sum_{i=1}^m (x'_{i,j} - \bar{x}'_j)^2}{m - 1}} \quad (19)$$

式中 $\bar{x}'_j$ 为平均指标。

矛盾性是考虑不同参数彼此间相关性的一种论证标准。当参数彼此间存在强正相关性时,矛盾性处于较低的水平。设定变量 f_j 来衡量参数 j 和余下参数彼此间矛盾性,如式(20)所示。

$$f_j = \sum_{i=1}^m (1 - r_{ij}) \quad (20)$$

式中 r_{ij} 为参数 i 及 j 之间相关系数。利用皮尔逊相关系数为评价准则。

设指标 j 的信息承载量为 C_j , 信息承载量计算如式(21)所示, 其中对比性指标 σ_j 越强, 数据差异大; 矛盾性 f_j 越强, 相关性弱; 只有同时满足 σ_j 和 f_j 均增加时 C_j 递增, 从而在后续赋权中获得更高权重。它是“客观赋权法”的关键桥梁, 通过“区分能力(对比性)+信息独特性(矛盾性)”的双维度乘积, 量化每个指标的“信息价值”, 避免单一维度导致的权重偏差。

$$C_j = \sigma_j f_j \quad (21)$$

最后计算权重和评分分别如式(22)—(23)所示, 信息承载量越大可认为权重越大。

$$w_j = \frac{C_j}{\sum_{j=1}^e C_j} \quad (22)$$

$$S_i = \sum_{j=1}^e w_j x'_{ij} \quad (23)$$

式中: w_j 为第 j 个评价指标的权重值; C_j 为信息承载量; S_i 为第 i 个待评对象的综合评价值; x'_{ij} 为数据矩阵内经过指标正向化处理后的元素。式(22)是客观权重归一化的核心步骤, 通过“信息承载量的比例分配”, 实现了“数据驱动、客观赋权”的评价逻辑。

1.4 反熵权法

针对乱序程度用熵来衡量, 熵权法计算的熵值与乱序程度成正比。而熵权法计算出的权重与乱序程度成反比。在赋权中, 存在指标无序程度敏感性过大导致其出现权重分配不平衡, 出现极端情况。为应对上述问题, 考虑运用反熵权法客观赋权来解决^[20]。

设定反熵值 G' 计算如式(24)所示。

$$G' = - \sum_{j=1}^l p_j \cdot \ln(1 - p_j) \quad (24)$$

式中: l 为系统状态数量; p_j 为系统在状态 j 时的概率, 且满足 $0 \leq p_j \leq 1$, 且 $\sum_{j=1}^m p_j = 1$ 。

反熵与熵表现为相反的特征量, 各个指标计算出的反熵值与反熵权重均与乱序程度成正比。乱序程度变大时, 则反熵值也会变大, 分配的权重也随之变大。

反熵权法确定权重的计算流程如下。首先构建

评价指标矩阵。假设有 f 个评价对象, p 个评价指标, 构造指标数据为 b_{jk} ($j = 1, 2, \dots, p$; $k = 1, 2, \dots, f$), 构造评价指标矩阵为:

$$B = [b_{jk}]_{p \times f} \quad (25)$$

之后计算各指标反熵为:

$$G'_j = - \sum_{k=1}^f s_{jk} \cdot \ln(1 - s_{jk}) \quad (26)$$

式中 $s_{jk} = b_{jk} / \sum_{k=1}^f b_{jk}$ 。

最后指标权重确定, 对反熵进行归一化进而得出各指标的客观反熵权重 s_j 计算如式(27)所示

$$s_j = G'_j / \sum_{j=1}^p G'_j \quad (27)$$

1.5 反熵权法的VHSKDE-NSEI估计

采用参数法和非参数法进行重组在一定程度上对预报精度的提升起到加强作用。因此利用预报组合偏差分摊机制, 设计VHSKDE和NSEI方法进行组合预报。组合模式权重采用反熵权法确定。

将VHSKDE-NSEI估计作为评价对象, 反熵权法采用预报区间宽度和覆盖率作为衡量标准。经过反熵权法确定采用的VHSKDE(非参数法)和NSEI(参数法)的预报区间混合权重值分别为 w_1 和 w_2 。进而得到最终混合预报结果的区间 $[L_H, U_H]$ 。VHSKDE-NSEI方法预报区间表达如下。

$$L_H = w_1 L_1 + w_2 L_2 \quad (28)$$

$$U_H = w_1 U_1 + w_2 U_2 \quad (29)$$

式中 L_1 、 U_1 和 L_2 、 U_2 由1.1节和1.2节推导而来。

2 风电功率概率预报整体流程

2.1 概率预报整体流程

本文通过基于变分模态分解与长短期记忆神经网络(VMD-LSTM)点预报得到偏差值, 然后利用偏差值分别采用基于Critic权重法的变带宽混合滑动核密度估计VHSKDE(Gaussian)、正态滑动指数迭代估计(NSEI)以及基于反熵权法的组合模型VHSKDE(Gaussian)-NSEI进行95%和85%置信度的风电功率区间概率预报结果分析, 其中以渐进积分均方偏差最小的原则推导出基准带宽。最后采用PICP, PIAW和Winkler进行评价。本文风电概率预报研究路线如图1所示。

2.2 评价方法

区域覆盖率(PICP)的解析式可表示为:




图1 研究路线

Fig. 1 Research rout

$$P_{ICP} = \frac{1}{U} \sum_{u=1}^U A_u \quad (30)$$

式中: $u = 1, 2, \dots, U$, U 为风电功率预报的时长, U 取 96 步; A_u 为示性函数, 具体解析式如下。

$$A_u = \begin{cases} 1, & V_u \in [\underline{V}_u, \bar{V}_u] \\ 0, & V_u \notin [\underline{V}_u, \bar{V}_u] \end{cases} \quad (31)$$

式中 $\bar{V}_u$ 、 $\underline{V}_u$ 分别为预报结果中的上下界区间。当 A_u 取值为 1 时表示风电功率真实值处于预报区间中。当偏离预报区间时, A_u 取值为 0。处于相同置信度下, PICP 值处于同高水平时, 真实值落入预报区间的个数显著增加, 预报性能得到提升。

针对区间平均宽度 (PIAW) 解析式如下。

$$P_{IAW} = \frac{1}{U} \sum_{u=1}^U (\bar{V}_u - \underline{V}_u) \quad (32)$$

PIAW 值处于低水平时表明预报区间越窄, 精度越高。

本文采用 Winkler 分数评定标准。设定预报区间 $\hat{I} = [\hat{L}, \hat{U}]$, $1 - \beta$ 为其对应的置信概率。针对预报区间而设定的上下界分别用 $\hat{U}$ 和 $\hat{L}$ 来表示。Winkler 分数计算解析式^[21]如式 (33) 所示。

$$S(\hat{I}, x) = \begin{cases} \delta, & \hat{L} \leq x \leq \hat{U} \\ \delta + 2(\hat{L} - x)/\beta, & x < \hat{L} \\ \delta + 2(x - \hat{U})/\beta, & x > \hat{U} \end{cases} \quad (33)$$

式中: $\delta = \hat{U} - \hat{L}$ 就是预报区间宽度; x 为真实值。

根据式 (33), 当实际值落在预报区间中时, Winkler 分数就对应区间宽度; 当实际值落在预报区间外时, 则根据偏离程度给予相应惩罚。

Winkler 分数是负向的打分规则, 其数值越小, 概率预报效果越好。

3 算例分析

3.1 数据源及预处理

数据源于东北沿海地区某风场, 装机容量为 15 MW, 于 2021 年 10 月成功并网。该电厂配备了 5 台 Envision Energy 风力发电机组 (Envision Energy/EN-156/3.0), 每台机组容量为 3 MW, 并设有一座风测塔。利用每台风力发电机的 SCADA 系统采集风场输出总功率时间序列数据, 采集时间间隔为 1 min。实例分析利用 2022 年 1 月采集的数据, 通过方差变点分位数方法对 44 640 条数据中的异常值进行清洗过滤, 采用近邻法则进行填充, 最后将处理后的数据均值转换为 2 976 条时间分辨率为 15 min 的风电功率时间序列数据集如图 2 所示。为了预报 1 月 30 日的时长为 24 h, 分辨率为 15 min 的风电功率概率预报效果, 利用 VMD-LSTM 方法进行确定性预报, 其中数据集中前 83 % (2 400) 作为训练集, 后 17 % (480) 作为验证集。




图2 风电功率时间序列

Fig. 2 Wind power time series

下面对 VMD-LSTM 点预测建模方式进行明确说明。在 VMD 变分模态分解的实施过程中, 如式 (34)–(36) 所示。

$$\hat{u}_k^{n+1}(\omega) \leftarrow \frac{F(\omega) - \sum_{i < k} \hat{u}_i^{n+1}(\omega) - \sum_{i > k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (34)$$

$$\omega_k^{n+1} \leftarrow \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (35)$$

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau \left(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (36)$$

式中: $\hat{u}_k^{n+1}(\omega)$ 为傅里叶变换得到的第 k 模态中心频率为 ω 所对应的第 $n+1$ 代的本征模态分量; $F(\omega)$ 为原始信号通过傅里叶变换得到的中心频率为 ω 的信号; $\hat{u}_i^n(\omega)$ 为第 i 模态中心频率为 ω 第 n 代更新的本征模态分量; $\hat{\lambda}^n(\omega)$ 为中心频率为 ω 第 n 代的拉格朗日乘子; α 为惩罚因子, 控制约束强度; ω_k^n 为第 k 模态第 n 代中心频率; τ 为迭代步长。

VMD 方法执行步骤如下所述。

1) 首先设置初始化值: $\hat{u}_k^1(\omega)$ 、 ω_k^1 、 $\hat{\lambda}^1(\omega)$, 其中 $\hat{u}_k^1(\omega)$ 为傅里叶变换得到的第 k 模态中心频率为 ω 所对应的第 1 代的本征模态分量; ω_k^1 为第 k 模态第 1 代中心频率; $\hat{\lambda}^1(\omega)$ 为中心频率为 ω 第 1 代的拉格朗日乘子; 设定 $n=1$;

2) $n=n+1$, 进入循环;

3) 根据公式更新两个参数 $\hat{u}_k^{n+1}(\omega)$ 和 ω_k^{n+1} , 当被分解的数量达到 K 时, 停止内部循环;

4) 根据更新后的公式更新 $\hat{\lambda}^{n+1}(\omega)$;

5) 给定精度 ε , 如果满足式 (37) 所示停止条件:

$$\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \varepsilon \quad (37)$$

则停止循环; 否则, 继续进行步骤 (2)。

本文采用 VMD 分解方法将风电时间序列功率分解成不同频率分量, 算法参数设置如下。

K (分解模态数)=10; f_s (采样频率)=1/3 600; T (分解信号的时长)=2 880; t_{ol} (噪声容忍度)= 1×10^{-6} ; α (核心频率)=2 000。

风电预测的时间尺度为面向电力系统日前调度的风电短期预测, 因此预测时长为 24 h, 分辨率为 15 min。通过皮尔逊相关系数对气象因素与风电有功出力进行相关性分析, 风速特征相比风向、温度、湿度、气压与有功功率之间的相关性更强, 所以特征量只考虑风速。不同高度风速与风电有功出力相关性统计如表 1 所示。

其中, 120 m 风速、10 m 风速时有功功率的出力最高为 0.45 p. u., 且两处风速的相关性达到 0.97, 因此为了提升计算效率, 可以从两处风速中选择一种作为风速特征量输入。同理, 90 m 风速与 30 m 风速、70 m 风速与 50 m 风速类似。由于风电机组 (Envision Energy/ EN-156/3.0) 轮毂高度为

表 1 不同高度风速与风电有功功率出力相关性统计

Tab. 1 Statistics on the correlation between wind speed at different heights and wind power active output

相关性分析	50 m 风速	30 m 风速	10 m 风速	有功功率/p. u.
120 m 风速	0.98	0.97	0.97	0.45
90 m 风速	0.96	0.96	0.95	0.43
70 m 风速	0.96	0.96	0.95	0.44
50 m 风速	1	0.96	0.95	0.44
30 m 风速	0.96	1	0.95	0.43
10 m 风速	0.95	0.95	1	0.45

110 m, 因此, 本文选择与有功功率相关性较高的 120 m 风速、90 m 风速及 70 m 风速作为气象特征量输入, 从时空维度考虑更符合风机轮毂高度的工况。为了得到精准的预测效果, 通过理论分析结合实验调参, 基于 VMD-LSTM 点预测的输入特征量为 120 m 风速、90 m 风速、70 m 风速及前 4 个时刻的 VMD 分解的功率时间序列信号, 因此输入层节点数为 7 维。采用 VMD-LSTM 的点预测模型的输入输出映射设定如表 2 所示。

表 2 VMD-LSTM 映射结构

Tab. 2 VMD-LSTM mapping structure

表目	数值
输入层节点数量	7
隐含层节点数量	5
输出层节点数量	1
每次迭代次数 (epochs)	300
训练分批次 (batch)	20

在概率预报阶段, 480 点预报结果中, 前 384 点作为验证集, 对 1 月 30 日中 96 个分辨率为 15 min 时刻进行概率预报。非参数核密度估计的 KDE 滑动样本观察窗实验数据的时间分辨率为 15 min, 对应 96 个风功率时间序列。因此, 本文在计算 $t+1$ 时刻的预报偏差概率密度函数时, 通过利用滑动选取 $t+1$ 时刻之前的 20 个预报偏差作为样本。

本次仿真基于 Tensorflow 框架的 python 语言实现, 仿真硬件平台设置: CPU 为 Intel Core i5-6300 3.20 GHz, 内存 RAM 为 8 GB, GPU 为 Nvidia GeForce GTX 960 8 G。

通过利用 VMD-LSTM 风电功率时间序列点预报值与真实值之间偏差, 确立确定性预报功率与实际预报功率之间的映射关系, 拟合特定预报功率下的实际预报功率分布得到概率预报结果。由于确定

性预报功率与实际预报功率之间的关系可以通过预报偏差反映出来,对偏差进行估计,再将预报偏差分布叠加到确定性预报功率结果上得到风功率概率预报结果,称之为基于预报偏差的概率预报。通过VMD-LSTM得出的预报偏差分布如图3所示。




图3 基于VMD-LSTM的预报偏差百分比
Fig. 3 Relative error percentage based on VMD-LSTM

3.2 概率预报方法仿真对比分析

3.2.1 单模型定带宽区间预测对比分析

基于VMD-LSTM预报的结果,为了探究差异核函数对KDE估计的结果具有何种程度的影响进行建模。图4绘制了95%置信度不同时刻下,采用5种核函数KDE估计概率预报结果,并将其叠加在基于VMD-LSTM确定性功率预报结果中,BW设定为1。从图4可以看出采用在蓝色的Gaussian核密度估计区间的上下限相较于其他核密度估计方法区间宽度更窄且更趋于平稳。




图4 基于多种核函数估计的概率预报结果对比(1月30日)
Fig. 4 Comparison of probability prediction results based on multiple kernel function estimations(January 30)

图5绘制仅采用NSEI参数估计的95%置信度的概率预报结果。

表3罗列了上述6种方法获得的预报区间在95%




图5 基于NSEI估计的概率预报结果(1月30日)
Fig. 5 Probabilistic prediction results based on NSEI estimation (January 30)

置信度下的PICP指标、PIAW指标和Winkler分数。

表3 95%置信度的各概率预报方法对比结果(1月30日)

方法	PICP值/%	PIAW值/kW	Winkler分数
NSEI	85.417	570.793	1 103.896
Gaussian	100	1 567.040	1 567.040
Biweight	100	1 599.003	1 599.003
Triangle	100	1 610.912	1 610.912
Cosine	100	1 614.920	1 614.920
Epanechnikov	100	1 616.078	1 616.078

从表3中可得出,5种核函数的核密度估计概率预报区间覆盖率(PICP)为100%,而预报区间平均带宽(PIAW)达到1 500 kW以上,NSEI覆盖率上明显比KDE方法降低,但PIAW性能上有较为明显提升,仅为KDE方法的三分之一。因此可以说明基于5种核函数的KDE方法以更宽的预报区间带宽为代价,完全覆盖了实际功率值。Winkler分数是针对概率预报性能评价而设计,可以有效衡量PICP和PIAW的综合效果。利用Winkler分数可以准确合理地评估各置信区间下概率预报模型的优劣。Winkler分数满足负向打分规则,其数值越小,代表性能优越。通过结果数据分析,参数化NSEI方法最优,而针对非参数化KDE方法,依次为Gaussian与Biweight核密度估计效果更佳。因此,需要对上述3种模型(NSEI,Gaussian,Biweight)进一步优化,以提升风电功率概率预报精度。

3.2.2 变带宽混合滑动核密度估计(VH KDE)对比分析

在VH KDE预报方法中,以渐进积分均方偏

差最小化的规则推导出基准 BW, 分别采用基准 BW(h)、BW(0.5 h)、BW(1.5 h)、以 Critic 客观权重赋值来组合叠加上 3 个带宽的不同估计结果。采用 Critic 权重法, 基于 Gaussian 核 95 % 置信度的混合概率预报结果如图 6 所示。




图 6 95 % 置信度 Gaussian 核密度混合概率预报对比 (1 月 30 日)

Fig. 6 Comparison of 95 % confidence Gaussian kernel density mixed probability prediction results (January 30)

从图 6 可知, 采用 VHSKDE(Gaussian) 估计方法, 相较于 KDE(Gaussian), 其预报 PIAW 显著变窄, 黄色预报区间未覆盖蓝色曲线中少数真实值。采用 Critic 权重法, 基于 Biweight 核 95 % 置信度的混合概率预报结果如图 7 所示。




图 7 95 % 置信度 Biweight 核密度混合概率预报对比 (1 月 30 日)

Fig. 7 Comparison of 95 % confidence Biweight kernel density mixed probability prediction results (January 30)

从图 7 可知, 采用 VHSKDE(Biweight) 估计方法相较于 KDE(Biweight) 效果与图 6 相同。

95 % 置信度的核密度混合概率预报模型对比结果如表 4 所示。

从表 4 可知, 采用 VHSKDE(Gaussian) 和 VHSKDE(Biweight) 相较于 KDE(Gaussian, Biweight) 方法牺

表 4 95 % 置信度的核密度混合概率预报模型对比结果 (1 月 30 日)

Tab. 4 Comparison results of kernel density mixed probability prediction models with 95 % confidence (January 30)

方法	PICP 值/%	PIAW 值/kW	Winkler 分数
VHSKDE(Gaussian)	94.792	718.891	984.556
VHSKDE(Biweight)	94.792	727.626	992.505
Gaussian	100	1 567.040	1 567.040
Biweight	100	1 599.003	1 599.003

牲了 5.208 % 的 PICP 来换取更低的 PIAW, 同时 Winkler 分数降到 1 000 以内且 VHSKDE(Gaussian) 预报效果最佳。在置信度为 95 % 下, VHSKDE(Gaussian, Biweight) 方法在 Winkler 分数上明显低于 KDE(Gaussian, Biweight) 和 NSEI 方法。这是由于变带宽混合滑动核密度估计利用渐进积分均方偏差最小的原则推导出不同基准带宽 BW(0.5 h、1 h、1.5 h) 所对应的 Critic 权值组合和滑动数据窗口的思想, 提高了概率密度曲线提取的准确性, 从而生成了更精准的预报区间。因此, 通过 VHSKDE(Gaussian) 方法可以显著提升风电概率预报精度。

3.2.3 变带宽混合滑动核密度估计 VHSKDE(Gaussian) 与 NSEI 组合分析

根据本文分析, 通过 NSEI 方法与 VHSKDE(Gaussian) 方法的结果得出, 对于单一种类区间预报方法有各自优势和劣势。基于 VHSKDE(Gaussian) 方法与 NSEI 方法相比有较高水平的区间覆盖率 (PICP) 和较宽的平均宽度 (PIAW)。而 NSEI 方法则具有较低的 PICP 和较窄的 PIAW。因此设计最优的客观赋值加权方法来权衡各自的优劣, 构建核密度混合概率预报与 NSEI 组合模型 VHSKDE(Gaussian)-NSEI 进一步提升风电功率概率预报效果。采用 Anti-Entropy 客观权重赋值法, 基于 95 % 置信度的 VHSKDE(Gaussian)-NSEI 组合概率预报结果如图 8 所示。

从图 8 可知, 采用 VHSKDE(Gaussian)-NSEI 估计方法, 相较于 VHSKDE(Gaussian), 其预报 PIAW 变窄, 粉色预报区间未覆盖蓝色曲线中少数真实值。由图 8 局部放大图可以看出, 基于 95 % 置信度 VHSKDE(Gaussian) 方法预测区间宽度最大, 基于 95 % 置信度 NSEI 方法预测区间宽度最小, 基于 VHSKDE(Gaussian)-NSEI 预测区间宽度适中。在 86 与 91 处可以发现, NSEI 方法虽然预测区间最




图8 95 %置信度VHSKDE(Gaussian)-NSEI组合概率预测对比(1月30日)

Fig. 8 Comparison of 95 % confidence VHSKDE (Gaussian)-NSEI combination probability prediction results(January 30)

小PIAW较优，但没有覆盖真实值，PICP较差。基于VHSKDE(Gaussian)-NSEI方法与NSEI相比其PIAW较差，但完全覆盖真实值其PICP较优。

为了进一步揭示VHSKDE(Gaussian)-NSEI组合方法中Anti-Entropy客观权重赋值方法和VHSKDE(Gaussian)中Critic权重法的预报的性能，对95 %置信度对应Critic、Balance、Entropy、Anti-Entropy 4种权重赋值法下16种组合进行建模实验，选取了最优的4种组合所对应的PICP、PIAW及Winkler指标如表5所示。

表5 基于不同客观权重赋值方法的95 %置信度VHSKDE (Gaussian)与NSEI组合性能对比(1月30日)

Tab. 5 Comparison of 95 % confidence VHSKDE (Gaussian) and NSEI combination performance based on different objective weight assignment methods(January 30)

VHSKDE 权重法	VHSKDE-NSEI 权重法	PICP值/%	PIAW值/ kW	Winkler 分数
Critic	Anti-Entropy	91.667	644.994	940.995
Entropy	Anti-Entropy	91.667	644.973	941.000
Anti-Entropy	Anti-Entropy	91.667	644.890	941.018
Balance	Anti-Entropy	91.667	644.945	941.020

从表5可知，Critic权重法与反熵权法(Anti-Entropy weight method)组合中虽然PICP和PIAW与其他3组合相比几乎一致，但其Winkler分数为940.995稍低于其他3种组合。因此，95 %置信度下，采用VHSKDE(Gaussian)-NSEI组合方法预报性能最佳。85 %置信度下4种组合的结果如表6所示。

表6 基于不同客观权重赋值方法的85%置信度VHSKDE (Gaussian)与NSEI组合性能对比(1月30日)

Tab. 6 Comparison of 85% confidence VHSKDE (Gaussian) and NSEI combination performance based on different objective weight assignment methods(January 30)

VHSKDE 权重法	VHSKDE-NSEI 权重法	PICP值/%	PIAW值/ kW	Winkler 分数
Critic	Anti-Entropy	78.125	471.421	687.595
Balance	Anti-Entropy	77.083	467.713	695.335
Entropy	Anti-Entropy	77.083	468.597	696.107
Anti-Entropy	Anti-Entropy	77.083	470.461	698.246

从表6可知，基于Critic权重法与反熵权法(Anti-Entropy weight method)组合，在85 %置信度下的VHSKDE(Gaussian)-NSEI组合方法的Winkler分数为687.595最优，预报性能仍处于最优。

表7和表8分别罗列上述3种方法获得的预报区间在95%置信度和85 %置信度下的PICP指标、PIAW指标及Winkler指标。

表7 95 %置信度的核密度混合概率预报模型对比结果(1月30日)

Tab. 7 Comparison results of kernel density mixed probability prediction models with 95 % confidence(January 30)

方法	PICP值/%	PIAW值/ kW	Winkler 分数
VHSKDE(Gaussian)-NSEI	91.667	644.994	940.995
VHSKDE(Gaussian)	94.792	718.891	984.556
NSEI	85.417	570.793	1103.896

表8 85 %置信度的核密度混合概率预报模型对比结果(1月30日)

Tab. 8 Comparison results of kernel density mixed probability prediction models with 85 % confidence(January 30)

方法	PICP值/%	PIAW值/kW	Winkler 分数
VHSKDE(Gaussian)-NSEI	78.125	471.421	687.595
VHSKDE(Gaussian)	80.208	516.318	739.583
NSEI	75.000	419.229	756.748

在95 %和85 %置信度下，VHSKDE(Gaussian)方法的PICP指标优于NSEI，而其PIAW指标则劣于NSEI。本文提出的VHSKDE(Gaussian)-NSEI方法分别针对VHSKDE(Gaussian)环节使用Critic权重法赋值，针对VHSKDE(Gaussian)和NSEI组合环节采用反熵权法(Anti-Entropy weight method)法进行了两次加权组合，综合了2种方法的优势。在

95 %置信度和85 %置信度下, VHSKDE(Gaussian)-NSEI 方法的区间覆盖率分别为 91.667 %和 78.125 %, PIAW 指标分别为 644.994 和 471.421。VHSKDE (Gaussian)-NSEI 在不同置信度情况下, 能够兼顾PICP与PIAW的优良性能, 具有更高的可靠性和准确性。

为了验证本文所提出模型的有效性, 接下来选取1月29日与1月31日两天来对比验证概率预测结果。采用Critic权重法与反熵权法(Anti-Entropy weight method)组合优化的基于95 %置信度的VHSKDE(Gaussian)-NSEI组合概率预报(1月29日与1月31日)对比结果分别如图9与10所示。




图9 95 %置信度 VHSKDE(Gaussian)-NSEI 组合概率预报对比(1月29日)

Fig. 9 Comparison of 95 % confidence VHSKDE (Gaussian)-NSEI combination probability prediction results (January 29 th)




图10 95 %置信度 VHSKDE(Gaussian)-NSEI 组合概率预报对比(1月31日)

Fig. 10 Comparison of 95 % confidence VHSKDE (Gaussian)-NSEI combination probability prediction results(January 31)

从图9与图10可知采用VHSKDE(Gaussian)-NSEI方法预测区间相较于其他方法既不过窄也不过宽, 且几乎覆盖了实际值。

表9和表10分别为1月29日采用上述3种方法

获得的预报区间在95 %置信度和85 %置信度下的PICP指标、PIAW指标及Winkler指标。

表9 95 %置信度的核密度混合概率预报模型对比结果(1月29日)

Tab. 9 Comparison results of kernel density mixed probability prediction models with 95 % confidence (January 29)

方法	PICP值/%	PIAW值/kW	Winkler分数
VHSKDE(Gaussian)-NSEI	86.458	727.193	1 525.224
VHSKDE(Gaussian)	89.583	791.672	1 589.832
NSEI	81.250	662.290	1 725.087

表10 85%置信度的核密度混合概率预报模型对比结果(1月29日)

Tab. 10 Comparison results of kernel density mixed probability prediction models with 85% confidence (January 29)

方法	PICP值/%	PIAW值/kW	Winkler分数
VHSKDE(Gaussian)-NSEI	75.000	522.441	1 020.353
VHSKDE(Gaussian)	78.125	558.416	1 032.528
NSEI	68.750	486.431	1 082.773

本文采用Winkler指标进行综合判定, 基于VHSKDE(Gaussian)-NSEI方法在不同置信度情况下, 能够兼顾PICP与PIAW的优良性能, 相较于其他方法所得到的Winkler分数最低, 具有更高的可靠性和准确性。

同理, 表11和表12分别为1月31日采用上述3种方法获得的预报区间在95 %置信度和85 %置信度下的PICP指标、PIAW指标及Winkler指标。

表11 95 %置信度的核密度混合概率预报模型对比结果(1月31日)

Tab. 11 Comparison results of kernel density mixed probability prediction models with 95 % confidence (January 31)

方法	PICP值/%	PIAW值/kW	Winkler分数
VHSKDE(Gaussian)-NSEI	82.292	1 578.408	2 807.120
VHSKDE(Gaussian)	81.250	1 536.106	2 898.733
NSEI	83.333	1 620.846	2 900.918

表12 85 %置信度的核密度混合概率预报模型对比结果(1月31日)

Tab. 12 Comparison results of kernel density mixed probability prediction models with 85 % confidence (January 31)

方法	PICP值/%	PIAW值/kW	Winkler分数
VHSKDE(Gaussian)-NSEI	76.042	1 341.521	1 957.851
VHSKDE(Gaussian)	67.708	1 129.080	1 971.732
NSEI	77.083	1 554.672	2 083.788

基于 VHSKDE(Gaussian)-NSEI 方法在不同置信度情况下仍能够兼顾 PICP 与 PIAW 的优良性能,相较于其他方法得到最优的预测效果。

为了验证所提出基于 VHSKDE (Gaussian)-NSEI 组合概率预报模型的泛化能力,本文对训练集与测试集的数据长度进一步扩充,进行长时间的预测与评价。仍然采用 SCADA 系统提取的时间间隔为 1 min 时间序列数据,利用 2022 年 1 月、2 月及 3 月数据,分别通过上文的方法进行预处理后得到了 8 640 条时间分辨率为 15 min 的风电功率时间序列数据集(90 天)。为了预报 3 月 29 日、3 月 30 日及 3 月 31 日的时长为 72 h,分辨率为 15 min 的风电功率概率预报效果,仍然利用 VMD-LSTM 方法进行确定性预报,其中数据集中前 83 %(7 200)作为训练集,时间跨度为 2022 年 1 月 1 日—2022 年 3 月 16 日,共 75 天。后 17 %(1 440)作为验证集,时间跨度为 2022 年 3 月 17 日—2022 年 3 月 31 日,共 15 天。在概率预报阶段,1 440 个点(15 天)预报结果中,前 1 152 个点(12 天)作为验证集,对 3 月 29 日、3 月 30 日及 3 月 31 日中 288 个分辨率为 15 min 时刻进行概率预报。

在 95 %置信度下,采用 VHSKDE (Gaussian)-NSEI 组合概率预报(3 月 29 日、30 日、31 日)对比结果如图 11 所示。




图 11 95 %置信度 VHSKDE (Gaussian)-NSEI 组合概率预报对比(3 月 29—31 日)

Fig. 11 Comparison of 95 % confidence VHSKDE (Gaussian)-NSEI combination probability prediction results(March 29—31)

从图 11 中可以直观看出采用 VHSKDE(Gaussian)-NSEI 方法兼顾了 VHSKDE(Gaussian)与 NSEI 方法的预测性能,预测区间宽度适中,且几乎覆盖

了实际值。

表 13 和表 14 分别为 3 月 29 日、30 日、31 日采用上述 3 种方法获得的预报区间在 95 %置信度和 85 %置信度下的 PICP 指标、PIAW 指标及 Winkler 指标。

表 13 95 %置信度的核密度混合概率预报模型对比结果(3 月 29—31 日)

Tab. 13 Comparison results of kernel density mixed probability prediction models with 95 % confidence(March 29—31)

方法	PICP 值/%	PIAW 值/kW	Winkler 分数
VHSKDE(Gaussian)-NSEI	91.667	1 740.734	2 684.253
VHSKDE(Gaussian)	92.014	1 741.038	2 733.144
NSEI	89.931	1 739.850	2 836.674

表 14 85 %置信度的核密度混合概率预报模型对比结果(3 月 29—31 日)

Tab. 14 Comparison results of kernel density mixed probability prediction models with 85 % confidence(March 29—31)

方法	PICP 值/%	PIAW 值/kW	Winkler 分数
VHSKDE(Gaussian)-NSEI	80.556	1 275.959	1 937.287
VHSKDE(Gaussian)	81.250	1 273.745	1 959.922
NSEI	77.778	1 277.865	2 002.350

通过 Winkler 指标判定, VHSKDE (Gaussian)-NSEI 方法在不同置信度情况下,所得到的 Winkler 分数最佳。因此进一步验证了该预测模型在长时间尺度预测时具有较强的泛化能力。

4 结论

本文以基于变分模态分解与长短期记忆神经网络(VMD-LSTM)点预报偏差为基础建立核密度估计与正态滑动指数迭代相结合的组合概率预报模型,结合东北沿海风场算例研究,得到精度较高的风电功率点预报值和预报区间,且概率预报结果更加准确可靠。主要结论如下。

1)利用 VMD-LSTM 点预报偏差分布特征,采用多种核密度估计建模,研究发现基于 Gaussian 核密度估计效果最佳。

2)利用 VMD-LSTM 点预报偏差分布特征,采用 NSEI 和 VHSKDE (Gaussian)相结合,兼顾 PICP 与 PIAW 的优良性能,显著提升了风电功率概率预报可靠性和准确性。

3)通过由 Critic、Anti-Entropy、Entropy、Balance 4 种客观权重赋值法进行 16 种组合建模。在

95%和85%置信度下,采用基于VHSKDE(Gaussian)-NSEI组合方法可生成兼顾可靠性和准确性的风电功率预报区间,为VHSKDE(Gaussian)环节和VHSKDE(Gaussian)-NSEI组合环节客观权重赋值提供重要参考。

参考文献

- [1] 赵永宁,李卓,叶林.基于时空相关性的风电功率超短期自适应预测方法[J].电力系统保护与控制,2023,51(6):94-105.
ZHAO Yongning, LI Zhuo, YE Lin. A very short-term adaptive wind power forecasting method based on spatio-temporal correlation[J]. Power System Protection and Control, 2023, 51(6): 94-105.
- [2] 赵凌云,刘友波,沈晓东.基于CEEMDAN和改进时间卷积网络的短期风电功率预测模型[J].电力系统保护与控制,2022,50(1):42-50.
ZHAO Lingyun, LIU Youbo, SHEN Xiaodong. Short-term wind power prediction model based on CEEMDAN and an improved time convolutional network[J]. Power System Protection and Control, 2022, 50(1): 42-50.
- [3] 史加荣,赵丹梦,王琳华.基于RR-VMD-LSTM的短期风电功率预测[J].电力系统保护与控制,2021,49(21):63-70.
SHI Jiarong, ZHAO Danmeng, WANG Linhua. Short-term wind power prediction based on RR-VMD-LSTM[J]. Power System Protection and Control, 2021, 49(21): 63-70.
- [4] 黄慧,贾嵘,师小雨.考虑机组动态特性的超短期风电功率预测及不确定性量化分析[J].电力系统保护与控制,2021,49(8):109-117.
HUANG Hui, JIA Rong, SHI Xiaoyu, et al. Ultrashort-term wind power prediction considering the dynamic characteristics of a unit and uncertainty quantitative analysis[J]. Power System Protection and Control, 2021, 49(8): 109-117.
- [5] 汪欣,蔡旭,李征.结合交叉局部异常因子和注意力机制的超短期风电功率预测方法[J].电力系统保护与控制,2020,48(23):92-99.
WANG Xin, CAI Xu, LI Zheng, et al. Ultra-short-term wind power forecasting method based on a cross LOF preprocessing algorithm and an attention mechanism[J]. Power System Protection and Control, 2020, 48(23): 92-99.
- [6] QU Boyang, LIU Yang, CHEN Lei. Research on short-term output power forecast model of wind farm based on neural network combination algorithm[J]. Wind Energy, 2022, 25(10): 1710-1734.
- [7] 王耀健,顾洁,温洪林.基于在线高斯过程回归的短期风电功率概率预测[J].电力系统自动化,2024,48(11):197-207.
WANG Yaojian, GU Jie, WEN Honglin. Short-term wind power probability prediction based on online gaussian process regression[J]. Automation of Electric Power Systems, 2024, 48(11): 197-207.
- [8] 李丹,方泽仁,缪书唯,等.考虑训练样本分布不均衡的超短期风电功率概率预测[J].电网技术,2023,48(3):1133-1147.
LI Dan, FANG Zeren, MIAO Shuwei, et al. Probability prediction of ultra-short-term wind power considering unbalanced distribution of training samples[J]. Power System Technology, 2023, 48(3): 1133-1147.
- [9] 董晓翀,孙英云,蒲天骄.基于时序混合密度网络的超短期风电功率概率预测[J].电力系统自动化,2022,46(14):93-100.
DONG Xiaochong, SUN Yingyu, PU Tianjiao. Ultra-short-term probabilistic forecasting of wind power based on temporal mixture density network[J]. Automation of Electric Power Systems, 2022, 46(14): 93-100.
- [10] 涂青宇,苗世洪,林毓军.基于动态R藤Copula模型的区域风电集群超短期功率区间预测方法[J].高电压技术,2022,48(2):456-470.
TU Qingyu, MIAO Shihong, LIN Yujun. Ultra-short-term interval forecasting method for regional wind farms based on dynamic R-vine Copula model[J]. High Voltage Engineering, 2022, 48(2): 456-470.
- [11] 王钊,王勃,冯双磊.区域多风电场功率的分位数回归概率预测方法[J].电网技术,2020,44(4):1368-1375.
WANG Zhao, WANG Bo, FENG Shuanglei. Probabilistic forecasts based on quantile regression for regional wind farms[J]. Power System Technology, 2020, 44(4): 1368-1375.
- [12] 王森,孙永辉,侯栋宸.基于多窗宽核密度估计的风电功率超短期自适应概率预测[J].高电压技术,2024,50(7):3070-3079.
WANG Sen, SUN Yonghui, HOU Dongchen. Very short-term adaptive probabilistic forecasting of wind power based on multi-band width kernel density estimation[J]. High Voltage Engineering, 2023, 2024, 50(7): 3070-3079.
- [13] 王晓东,鞠邦国,刘颖明,等.基于QR-NFGLSTM与核密度估计的风电功率概率预测[J].太阳能学报,2022,43(2):480-485.
WANG Xiaodong, JU Bangguo, LIU Yingming, et al. Probability prediction of wind power based on QR-NFGLSTM and kernel density estimation[J]. Acta Energetica Sinica, 2022, 43(2): 480-485.
- [14] 何耀耀,闻才喜,许启发.基于Epanechnikov核与最优窗宽组合的中期电力负荷概率密度预测方法[J].电力自动化设备,2016,36(11):120-126.
HE Yaoyao, WEN Caixi, XU Qifa. Mid-term power load probability density forecast based on Epanechnikov kernel and optimal window bandwidth[J]. Electric Power Automation Equipment, 2016, 36(11): 120-126.
- [15] KHORRAMDEL B, CHUNG C Y, SAFARI N. A fuzzy adaptive probabilistic wind power prediction framework using diffusion kernel density estimators[J]. IEEE Transactions on Power Systems, 2018, 33(6): 7109-7121.
- [16] WAHBAH M, MOHANDS B, EL-FOULY T H M. Unbiased cross-validation kernel density estimation for wind and PV probabilistic modelling[J]. Energy Conversion and Management, 2022, 266(115): 8-11.
- [17] 杨锡运,张艳峰,叶天泽,等.基于朴素贝叶斯的风电功率组合概率区间预测[J].高电压技术,2020,46(3):1096-1105.
YANG Xiyun, ZHANG Yanfeng, YE Tianze, et al. Prediction of combination probability interval of wind power based on naive Bayes[J]. High Voltage Engineering, 2020, 46(3): 1096-1105.
- [18] 叶瑞丽,郭志忠,刘瑞叶.基于置信区间估计及储能装置优化配置的风电场可靠出力研究[J].电力自动化设备,2017,37(5):85-91.

(下转第71页 Continued on Page 71)