

基于改进混沌时间序列的风电功率区间预测方法

黎静华, 黄玉金, 黄 乾

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

摘要:风电功率区间预测是预测给定置信水平下风电功率的上限和下限, 可以反映风电功率的变化范围, 为调度提供有效的辅助信息。考虑风电功率的混沌特性, 提出了基于改进混沌时间序列的风电功率区间预测方法。由于风电功率具有强间歇性和波动性, 传统的混沌时间序列方法在风电功率区间预测中难以获得好的聚类效果和高的预测精度, 影响了功率区间预测的结果。引入蚁群聚类算法和支持向量机, 利用蚁群聚类算法的强搜索能力和支持向量机的强预测能力对传统方法进行改进, 获得了更好的区间预测结果。将改进方法应用于英国和德国风电场的风电功率区间预测中, 对比分析改进方法与基于神经网络的功率区间预测方法和传统方法在不同置信水平下的预测结果, 验证了所提改进方法的有效性。

关键词:风电功率; 区间预测; 混沌时间序列; 蚁群聚类算法; 支持向量机

中图分类号: TM 614

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2019.05.008

0 引言

随着风电的广泛应用, 准确预测风电功率对维持电网的安全运行、降低发电成本、提高风电市场的竞争力具有重要的意义。目前, 关于风电功率的点预测方法已有大量的研究成果, 预测方法主要可以分为物理预测方法和统计预测方法^[1-3]。物理预测方法先基于数值天气预报和风电场的详细地理信息估计风电机组轮毂高度处的风速最优值, 再根据风电机组或风电场的功率曲线将风速转换为风电场的输出功率^[4]; 统计预测方法不考虑风电功率变化的物理过程, 而是基于历史统计数据, 通过曲线拟合、参数估计和数据训练等方法建立影响因素与风电功率的关系, 主要方法包括时间序列法^[5-6]、灰色预测法^[7-8]、卡尔曼滤波法^[9-10]、神经网络^[11-13]、支持向量机^[14-15]和组合方法^[16-18]等。

然而, 目前风电功率点预测的预测精度仍不是十分理想, 仅依赖点预测结果还难以辅助调度进行准确的决策。为了进一步丰富调度的辅助信息, 学者们开始对风电功率的区间预测进行研究。根据不同的区间形成方法, 风电功率的区间预测方法主要分为2类^[19]: 第一类是采用神经网络、极限学习机等方法训练历史数据, 构建风电功率的双输出模型, 预测风电功率可能发生的上界和下界; 第二类是事先假设或估计风电功率的概率分布函数, 通过对概率分布函数进行逆运算, 可以得到给定置信度水平下风电功率的区间。

文献[20-29]属于第一类风电功率区间预测方

法; 文献[20-21]利用神经网络进行预测, 并分别采用估计法和基于模糊理论的估计法生成预测区间; 文献[22-24]分别基于神经网络和小波神经网络设计了风电功率的区间预测模型, 并分别采用模拟退火方法、粒子群优化算法和人工蜂群算法训练网络的参数; 文献[25-26]分别利用极限学习机和核极限学习机构建风电功率区间预测模型, 并运用粒子群优化算法训练参数; 文献[27-28]首先利用聚类经验模态分解与样本熵方法对原始风电功率时间序列进行分解, 然后基于极限学习机建立风电功率区间预测模型, 并分别采用量子粒子群优化算法、混沌萤火虫算法训练参数; 文献[29]首先利用变分模态分解对原始风电功率时间序列进行分解, 然后基于核极限学习机建立风电功率区间预测模型, 并采用人工蜂群算法训练参数。文献[30-35]则属于第二类风电功率区间预测方法; 文献[30]提出一种基于经验分布的非参数重采样概率预测方法; 文献[31]建立风电功率的条件 Copula 联合分布函数; 文献[32]采用非参数估计法估计风电功率预测误差的分布; 文献[33]假设风电功率预测误差服从贝塔分布; 文献[34-35]利用分位数回归对风电功率概率分布的分位点进行预测, 进而计算得到不同置信水平下的预测区间。上述方法为风电功率区间预测提供了很多的思路 and 基础。然而, 上述方法主要从数据训练的角度对风电功率进行区间预测, 没有考虑风电功率时间序列的性质。

目前, 已有文献已经证明了风电功率时间序列具有混沌特性, 并运用混沌理论对风电功率进行了点预测^[36-38]。混沌理论通过对原始序列进行重构将原系统拓展到高维的空间中, 从而以高维的方式直观地表现出非线性系统中隐含的信息特征。基于此, 有学者提出了基于混沌时间序列的电力负荷区间预测方法(本文称之为传统方法)^[39-40]。但是, 风

收稿日期: 2018-05-13; **修回日期:** 2019-03-16

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

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

电功率具有较强的间歇性和波动性,传统方法中的系统聚类算法和加权一阶局域法难以获得好的聚类效果和高的预测精度,从而很难得到好的区间预测结果。因此,本文改进了传统方法,提出了基于蚁群聚类算法和支持向量机的风电功率区间预测方法。

1 基于传统混沌时间序列的风电功率区间预测方法

1.1 传统方法的基本原理

假设长度为 N 的风电功率时间序列 $\mathbf{P} = [P(1), P(2), \dots, P(N)]^T$, 预测目标为 h 时刻后的功率, 将其记为 $P(N+h)$, 即由 $\mathbf{P}$ 预测 $P(N+h)$ 的区间。基于传统混沌时间序列的风电功率区间预测方法的基本过程包括相空间重构、系统聚类、加权一阶局域法预测和区间形成 4 个步骤。下文将分别对每个步骤进行阐述。此外, 本节定义了大量风电功率相关的变量, 具体变量说明见附录 A 中的表 A1。

a. 相空间重构。

对于风电功率序列 $\mathbf{P}$, 相空间重构后形成如下矩阵:

$$\mathbf{P}_w = [\mathbf{P}_w(1), \mathbf{P}_w(2), \dots, \mathbf{P}_w(M)]^T = \begin{bmatrix} P(1) & P(1+\tau) & \dots & P(1+(m-1)\tau) \\ P(2) & P(2+\tau) & \dots & P(2+(m-1)\tau) \\ \vdots & \vdots & & \vdots \\ P(M) & P(M+\tau) & \dots & P(M+(m-1)\tau) \end{bmatrix} \quad (1)$$

其中, $\mathbf{P}_w$ 为 $M \times m$ 阶的重构相空间矩阵, 其每一行称为一个相点; τ 和 m 分别为延迟时间和嵌入维数, 是相空间重构的参数; $M = N - (m-1)\tau$ 为重构相空间中相点的个数。相空间重构的关键是确定延迟时间 τ 和嵌入维数 m 。本文采用互信息法^[41]确定最佳延迟时间, 采用关联维数法^[41]确定最佳嵌入维数。

b. 系统聚类。

采用系统聚类算法^[40]对矩阵 $\mathbf{P}_w$ 中的相点进行聚类, 找到 $\mathbf{P}_w(M)$ 的相似相点, 即聚类结果中与 $\mathbf{P}_w(M)$ 是同一类的相点, 形成 $\mathbf{P}_w(M)$ 的相似相点矩阵 $\mathbf{P}_s$:

$$\mathbf{P}_s = [\mathbf{P}_s(1), \mathbf{P}_s(2), \dots, \mathbf{P}_s(n)]^T = \begin{bmatrix} P(e) & P(e+\tau) & \dots & P(e+(m-1)\tau) \\ P(f) & P(f+\tau) & \dots & P(f+(m-1)\tau) \\ \vdots & \vdots & & \vdots \\ P(g) & P(g+\tau) & \dots & P(g+(m-1)\tau) \end{bmatrix} \quad (2)$$

其中, $e, f, g \in [1, M-1]$, 并且 $e \neq f \neq g$; n 为相似相点的个数。寻找 $\mathbf{P}_w(M)$ 的相似相点是因为 $\mathbf{P}_w(M)$ 是最新的相点, 其与待预测量的时间间隔最短, 相关性较强。

c. 加权一阶局域法预测。

以 $\mathbf{P}_s$ 中的相点 $\mathbf{P}_s(1)$ 为例说明此预测过程。首先, 计算 $\mathbf{P}_s(1)$ 与 $\mathbf{P}_w$ 中除 $\mathbf{P}_s(1)$ 外的其余相点之间的空间欧氏距离, 基于计算结果选出与 $\mathbf{P}_s(1)$ 之

间距离较小的 K 个相点, 将其记为 $\mathbf{P}_{j,1}$:

$$\mathbf{P}_{j,1} = [\mathbf{P}_{j,1}(1), \mathbf{P}_{j,1}(2), \dots, \mathbf{P}_{j,1}(K)]^T = \begin{bmatrix} P(o) & P(o+\tau) & \dots & P(o+(m-1)\tau) \\ P(p) & P(p+\tau) & \dots & P(p+(m-1)\tau) \\ \vdots & \vdots & & \vdots \\ P(q) & P(q+\tau) & \dots & P(q+(m-1)\tau) \end{bmatrix} \quad (3)$$

其中, $o, p, q \in [1, M-h]$, 并且 $o \neq p \neq q$ 。则这 K 个相点对应的 h 时刻后的相点为:

$$\mathbf{P}_{j,1}^h = [\mathbf{P}_{j,1}^h(1), \mathbf{P}_{j,1}^h(2), \dots, \mathbf{P}_{j,1}^h(K)]^T = \begin{bmatrix} P(o+h) & P(o+h+\tau) & \dots & P(o+h+(m-1)\tau) \\ P(p+h) & P(p+h+\tau) & \dots & P(p+h+(m-1)\tau) \\ \vdots & \vdots & & \vdots \\ P(q+h) & P(q+h+\tau) & \dots & P(q+h+(m-1)\tau) \end{bmatrix} \quad (4)$$

然后, 利用加权一阶局域法^[40]拟合 $\mathbf{P}_{j,1}$ 与 $\mathbf{P}_{j,1}^h$ 之间的函数关系式。最后, 将 $\mathbf{P}_s(1)$ 作为函数的自变量代入函数式, 可以得到 $\mathbf{P}_s(1)$ 在 h 时刻后相点的预测值, 记为 $\mathbf{P}_Y(1)$:

$$\mathbf{P}_Y(1) = [\tilde{P}(e+h), \tilde{P}(e+h+\tau), \dots, \tilde{P}(e+h+(m-1)\tau)] \quad (5)$$

其中, $\tilde{P}(e+h)$ 为 $P(e+h)$ 的预测值。按上述方法对 $\mathbf{P}_s$ 中所有相点在 h 时刻后的相点进行预测, 形成预测集 $\mathbf{P}_Y$:

$$\mathbf{P}_Y = [\mathbf{P}_Y(1), \mathbf{P}_Y(2), \dots, \mathbf{P}_Y(n)]^T = \begin{bmatrix} \tilde{P}(e+h) & \tilde{P}(e+h+\tau) & \dots & \tilde{P}(e+h+(m-1)\tau) \\ \tilde{P}(f+h) & \tilde{P}(f+h+\tau) & \dots & \tilde{P}(f+h+(m-1)\tau) \\ \vdots & \vdots & & \vdots \\ \tilde{P}(g+h) & \tilde{P}(g+h+\tau) & \dots & \tilde{P}(g+h+(m-1)\tau) \end{bmatrix} \quad (6)$$

d. 区间形成。

因预测目标为 $P(N)$ 在 h 时刻后的功率 $P(N+h)$, 故先要提取 $\mathbf{P}_Y$ 的最后一列预测值, 将其记为 $\mathbf{P}_{Ym}$ 。由 $\mathbf{P}_{Ym}$ 中的最大值 $P_{Ym}^{\max}$ 、最小值 $P_{Ym}^{\min}$ 形成 $P(N+h)$ 的初始预测区间 $[P_{Ym}^{\min}, P_{Ym}^{\max}]$; 将初始预测区间分成 D 份, 每一份长度为 $I = (P_{Ym}^{\max} - P_{Ym}^{\min})/D$; 计算 $\mathbf{P}_{Ym}$ 中预测值落入区间 $[P_{Ym}^{\min} + rI, P_{Ym}^{\max} - rI]$ (r 为 $1 \sim D/2$ 范围内的整数, 初始值取为 1) 中的可靠度 R , 即计算落入区间 $[P_{Ym}^{\min} + rI, P_{Ym}^{\max} - rI]$ 中的预测值个数 l 与落入区间 $[P_{Ym}^{\min}, P_{Ym}^{\max}]$ 中的预测值个数 L 的比值; 增加 r 直到 R 与预先设定的置信水平 X_{PINC} 相等, 那么此时的区间 $[P_{Ym}^{\min} + rI, P_{Ym}^{\max} - rI]$ 即为满足给定置信水平的区间。

1.2 传统方法存在的不足分析

在基于传统混沌时间序列的风电功率区间预测方法中, 采用系统聚类算法和加权一阶局域法难以得到好的聚类效果和高的预测精度。本节将对系统聚类算法和加权一阶局域法的不足进行分析。

系统聚类算法^[40]将距离最近的样本合并为一类,其操作简单,但存在以下不足:每一个新类的生成都是基于之前类合并的结果;已合并的类不能撤销,类与类之间不能再交换样本;某一次合并的效果会影响整个聚类过程,从而影响最终的聚类结果。

加权一阶局域法^[40]将输入与输出的关系拟合为线性函数,在风电功率相似相点的预测中,其一阶局域线性拟合为:

$$P_{j,1}^h = a\Xi + bP_{j,1} \quad (7)$$

其中, a 和 b 为拟合的参数; Ξ 为 $K \times m$ 阶的全1矩阵。风电功率相点间的关系复杂,不是简单的线性关系,加权一阶局域法的线性模型难以获得高的预测精度。

基于上述不足,本文对传统方法进行了改进,在相空间重构的基础上,采用蚁群聚类算法选择相似相点,采用支持向量机对相似相点进行预测,进而实现风电功率区间预测。

2 基于蚁群聚类算法和支持向量机的改进风电功率区间预测方法

2.1 基于蚁群聚类算法的聚类效果改进

蚁群算法是一种根据大自然中蚁群寻觅食物形成的智能搜索算法。在聚类分析方面,学者们受蚂蚁堆积尸体和分类幼体的启发,将蚁群算法用于聚类分析^[42]。本文将蚁群聚类算法用于风电功率相点选择中,首先定义相点 $P_w(v)$ ($v=1,2,\dots,M$)和类 w ($w=1,2,\dots,A$,其中 A 为类的数目)之间的信息素浓度 $\alpha_{v,w}$,以其大小来表征路径的远近,由此判断相点 $P_w(v)$ 是否归为类 w 。聚类的基本思想是将相点归到信息素浓度最大的一类中。

信息素的更新如式(8)所示。

$$\alpha_{v,w}(t+1) = (1-\rho)\alpha_{v,w}(t) + \frac{Q}{F_{v,w}} \quad (8)$$

其中, $\alpha_{v,w}(t+1)$ 和 $\alpha_{v,w}(t)$ 分别为第 $t+1$ 次和第 t 次迭代中相点 $P_w(v)$ 和类 w 之间的信息素浓度; ρ 为信息素的挥发系数; Q 为常数,表示蚂蚁循环一周所释放的信息素总量; $F_{v,w}$ 为该次迭代中相点 $P_w(v)$ 和类 w 之间的目标函数值。灰色系统理论中的关联度根据曲线间的相似程度来评价关联性^[43],能够在一定程度上反映相点间的变化关系,将其应用于目标函数值中。

以相点 $P_w(v)$ 为参考,类 w 的聚类中心 $P_c(w)$ 与相点 $P_w(v)$ 在第 u ($u=1,2,\dots,m$)个元素的关联系数 $\xi_{v,w}(u)$ 为:

$$\xi_{v,w}(u) = \frac{\min_w \min_u |\Delta P|}{|\Delta P| + \lambda \max_w \max_u |\Delta P|} + \frac{\lambda \max_w \max_u |\Delta P|}{|\Delta P| + \lambda \max_w \max_u |\Delta P|} \quad (9)$$

$$\Delta P = P_w(v, u) - P_c(w, u)$$

其中, $\min_w \min_u |\Delta P|$ 为相点 $P_w(v)$ 与不同聚类中心在第 u 个元素上差值绝对值的最小值; $\max_w \max_u |\Delta P|$ 为相点 $P_w(v)$ 与不同聚类中心在第 u 个元素上差值绝对值的最大值; λ 为分辨系数,取值范围为 $0 \sim 1$,通常取为 0.5 。聚类中心 $P_c(w)$ 与相点 $P_w(v)$ 的关联度 $\delta_{v,w}$ 为:

$$\delta_{v,w} = \frac{1}{m} \sum_{u=1}^m \xi_{v,w}(u) \quad (10)$$

相点 $P_w(v)$ 和类 w 之间的目标函数值为:

$$F_{v,w} = 1 - \delta_{v,w} \quad (11)$$

该次迭代中总的目标函数值为:

$$F = \sum_{w=1}^A \sum_{s=1}^B F_{s,w} \quad (12)$$

其中, F 用于表征总的聚类效果; s 表示相点 $P_w(s)$ 为类 w 中的相点; B 为类 w 中的相点数。

采用蚁群聚类算法对风电功率相点进行聚类的具体流程如下。

a. 初始化蚁群聚类算法参数;设置蚂蚁数目、最大迭代次数、聚类数目、信息素挥发系数、蚂蚁循环一周所释放的信息素总量、初始信息素浓度等。

b. 根据信息素浓度,每只蚂蚁将相点归类到具有最大信息素浓度的类中;根据聚类结果计算每一类的聚类中心,取类中各相点对应元素的平均值;计算目标函数值 $F_{v,w}$ 和 F 。

c. 在所有蚂蚁的聚类结果中选出具有最小 F 值的结果作为本次循环的最优解,并比较每次循环的最小 F 值,记录所有循环中的最优解。

d. 利用 $F_{v,w}$ 根据式(8)更新信息素。

e. 判断迭代次数是否达到最大迭代次数,若达到,则输出最优解,即为最优聚类结果;否则,转步骤b。

与系统聚类算法相比,蚁群聚类算法的主要优势为:每次迭代可以根据信息素调整分类,而不是一次性地只根据距离进行分类;中间某次迭代对聚类结果的影响不大。

2.2 基于支持向量机的预测精度改进

支持向量机是一种常用的分类和拟合方法,它在解决小样本、非线性问题中表现出许多特有的优势,能推广应用到函数拟合等其他机器学习问题中。

在风电功率相似相点的预测中,支持向量机模型可表示为:

$$P_{j,1}^h = \sum_{z=1}^Z c(z) H(P_{j,1}, P_E(z)) + d\Xi \quad (13)$$

其中, Z 为支持向量的数目; $P_E(z)$ 为支持向量; $c(z)$ 为权值; d 为偏置量; $H(\cdot)$ 为核函数,通常采用高斯径向基函数,如式(14)所示。

$$H(\mathbf{P}_{j,1}, \mathbf{P}_E(z)) = \exp\left(-\frac{\|\mathbf{P}_{j,1} - \mathbf{P}_E(z)\|^2}{2\mu^2}\right) \quad (14)$$

其中, μ 为核函数的参数。

与加权一阶局域法相比, 支持向量机可以拟合风电功率相点间的非线性关系, 训练得到更有效的预测模型, 有利于预测精度的提高。

2.3 风电功率区间预测具体步骤

a. 对风电功率时间序列数据进行归一化处理。

b. 利用互信息法^[41]确定风电功率时间序列的最佳延迟时间, 利用关联维数法^[41]确定最佳嵌入维数, 然后对风电功率时间序列进行相空间重构。

c. 采用蚁群聚类算法对重构后相空间中的风电功率相点进行聚类, 找到与 $\mathbf{P}_w(M)$ 同属一类的相点作为 $\mathbf{P}_w(M)$ 的相似相点, 得到相似相点矩阵 $\mathbf{P}_s$ 。

d. 运用支持向量机对 $\mathbf{P}_s$ 中的每个相点在 h 时刻后的相点进行预测, 形成预测矩阵 $\mathbf{P}_Y$ 。

e. 从 $\mathbf{P}_Y$ 中提取出 $\mathbf{P}_{Ym}$, 由 $\mathbf{P}_{Ym}$ 形成初始预测区间 $[P_{Ym}^{\min}, P_{Ym}^{\max}]$, r 的初值取为 1。

f. 计算 $\mathbf{P}_{Ym}$ 中预测值落入区间 $[P_{Ym}^{\min} + rI, P_{Ym}^{\max} - rI]$ 中的可靠度 R 。

g. 若 $R > X_{\text{PINC}}$, 则增加 r 并转步骤 f; 若 $R = X_{\text{PINC}}$, 则转步骤 h。

h. 输出满足给定置信水平的区间 $[P_{Ym}^{\min} + rI, P_{Ym}^{\max} - rI]$ 。

3 风电功率区间预测性能评价指标

目前, 评价风电功率区间预测性能的指标通常有预测区间覆盖率 PICP (Prediction Interval Coverage Probability) X_{PICP} 、预测区间平均宽度 PINAW (Prediction Interval Normalized Average Width) X_{PINAW} 以及累积带宽偏差 AWD (Accumulated Width Deviation) X_{AWD} 。评价指标的计算公式见文献[26]或附录 B 中的式 (B1) — (B4)。

4 算例分析

算例所用的数据为英国的 1 座风电场在 2012 年的风电功率数据 (算例 1) 和德国的 1 座风电场在 2016 年的风电功率数据 (算例 2), 每 15 min 进行一次数据采样, 每天有 96 个采样点。考虑到不同季节的影响, 分别采用基于神经网络的区间预测方法 (神经网络方法)、传统混沌时间序列方法 (传统方法) 和改进混沌时间序列方法 (改进方法) 对 2 个算例在 3 月、6 月、9 月和 12 月最后 7 d 的风电功率进行区间预测。在每一次的预测中, 基于前一个月的数据预测之后 3 h 的风电功率区间, 即每次预测 12 个点, 每天预测 8 次, 连续预测 7 d, 预测 56 次即可得到 7 d 的预测结果。

首先, 为了验证本文所提改进方法的有效性, 将

改进方法与神经网络方法的区间预测结果进行比较。其次, 为了比较传统方法和改进方法的预测效果, 设置 4 种仿真方案: 方案 1 采用系统聚类算法和加权一阶局域法进行预测; 方案 2 采用蚁群聚类算法和加权一阶局域法进行预测; 方案 3 采用系统聚类算法和支持向量机进行预测; 方案 4 采用蚁群聚类算法和支持向量机进行预测。

4.1 预测参数设置

风电功率时间序列的长度 N 为用于预测的一个月的风电功率数据点数。利用互信息法^[41]求出算例 1 的 3 月、6 月、9 月和 12 月的最佳延迟时间分别为 16、15、15 和 14, 算例 2 的 3 月、6 月、9 月和 12 月的最佳延迟时间分别为 14、14、16 和 18; 利用关联维数法^[41]求出算例 1 的 4 个月的最佳嵌入维数分别为 4、5、4 和 6, 算例 2 的 4 个月的最佳嵌入维数分别为 3、3、4 和 4。在蚁群聚类算法中, 蚂蚁数目、最大迭代次数、聚类数目、信息素挥发系数、蚂蚁循环一周所释放的信息素总量分别为 100、100、60、0.1、1, 初始信息素浓度为 0.001 ~ 0.01 之间的随机数。在对相似相点进行预测时, K 取为 50。在形成区间时, D 取为 100。

4.2 改进方法与神经网络方法的对比

为了验证改进方法的有效性, 对改进方法与神经网络方法的区间预测结果进行比较。算例 1 和 2 的结果集中展示于附录 C, 本节仅对算例 1 的结果进行分析。表 1—4 给出了算例 1 中改进方法与神经网络方法预测结果的评价指标。

表 1 算例 1 中改进方法与神经网络方法的评价指标对比 (3 月 25—31 日)

Table 1 Comparison of evaluation indicators between improved method and neural network method in Example 1 (March 25 to 31)

置信水平/%	$X_{\text{PICP}}/\%$		$X_{\text{PINAW}}/\%$		$X_{\text{AWD}}/\%$	
	神经网络方法	改进方法	神经网络方法	改进方法	神经网络方法	改进方法
85	85.42	84.38	14.95	10.00	2.96	2.53
90	90.63	90.33	16.23	11.23	1.78	1.77
95	94.79	95.39	18.59	14.27	0.93	0.89
98	97.92	97.62	19.39	16.10	0.70	0.70

表 2 算例 1 中改进方法与神经网络方法的评价指标对比 (6 月 24—30 日)

Table 2 Comparison of evaluation indicators between improved method and neural network method in Example 1 (June 24 to 30)

置信水平/%	$X_{\text{PICP}}/\%$		$X_{\text{PINAW}}/\%$		$X_{\text{AWD}}/\%$	
	神经网络方法	改进方法	神经网络方法	改进方法	神经网络方法	改进方法
85	84.82	85.57	15.78	12.12	3.00	2.92
90	90.63	89.73	18.87	14.42	1.09	1.04
95	94.79	95.09	20.91	17.04	0.96	0.86
98	97.92	98.51	21.93	18.27	0.60	0.55

表3 算例1中改进方法与神经网络方法的评价指标对比(9月24—30日)

Table 3 Comparison of evaluation indicators between improved method and neural network method in Example 1 (September 24 to 30)

置信水平/%	$X_{PICP}/\%$		$X_{PINAW}/\%$		$X_{AWD}/\%$	
	神经网络方法	改进方法	神经网络方法	改进方法	神经网络方法	改进方法
85	84.97	85.42	15.45	12.37	2.86	2.67
90	90.03	90.18	17.33	14.41	1.92	1.75
95	94.49	94.79	18.78	16.50	1.05	0.80
98	97.77	97.32	20.34	17.84	0.72	0.51

表4 算例1中改进方法与神经网络方法的评价指标对比(12月25—31日)

Table 4 Comparison of evaluation indicators between improved method and neural network method in Example 1 (December 25 to 31)

置信水平/%	$X_{PICP}/\%$		$X_{PINAW}/\%$		$X_{AWD}/\%$	
	神经网络方法	改进方法	神经网络方法	改进方法	神经网络方法	改进方法
85	85.12	84.23	14.64	10.84	3.30	3.19
90	89.88	89.73	16.81	13.49	1.50	1.31
95	95.09	95.54	18.67	16.01	0.77	0.64
98	98.07	97.77	20.66	16.93	0.53	0.36

由表1—4可知:在不同的置信水平下,神经网络方法和改进方法的 X_{PICP} 与给定的置信水平相差不大,偏差不超过 $\pm 1\%$,均能满足置信水平的要求;在同一置信水平下,改进方法的 X_{PINAW} 、 X_{AWD} 均小于神经网络方法,说明改进方法既能获得较窄的区间,又能使落在区间外的点偏离区间的程度较小,具有更好的区间预测效果;无论是神经网络方法还是改进方法,随着置信水平上升,预测区间的宽度会增大,而区间能覆盖的点也增多,落在区间外的点与区间的偏差会减小。经计算,表1—4中改进方法的 X_{PINAW} 和 X_{AWD} 较神经网络方法分别平均减少了20.33%和11.18%,由此验证了改进方法的有效性。

4.3 改进方法与传统方法的对比

为了比较改进方法和传统方法的预测效果,对4种仿真方案的预测结果进行分析。考虑到算例2中3月、6月、9月和12月最后一天的风电功率曲线在变化范围和变化方向上具有不同的特点,具有较强的可比性,所以本节重点对这4天的结果进行分析。

4.3.1 采用蚁群聚类算法的改进效果分析

为了验证蚁群聚类算法的改进效果,对算例2中方案1和方案2的结果进行分析。这2种方案的预测结果和预测结果的评价指标分别如图1和表5所示(图1中的风电功率为标幺值,后同)。

由图1可看出,3月31日的风电功率曲线变化范围较小且变化方向相对单一,6月30日的风电功率曲线变化范围较小但变化方向复杂,9月30日的风电功率曲线变化范围较大且变化方向复杂,12月




图1 算例2中方案1、2在90%置信水平下的预测结果

Fig.1 Predictive results of Scheme 1 and 2 under 90% confidence level in Example 2

表5 算例2中方案1、2在90%置信水平下的评价指标

Table 5 Evaluation indicators of Scheme 1 and 2 under 90% confidence level in Example 2

预测日期	$X_{PICP}/\%$		$X_{PINAW}/\%$		$X_{AWD}/\%$	
	方案1	方案2	方案1	方案2	方案1	方案2
3月31日	89.58	90.63	14.64	13.31	2.21	1.73
6月30日	89.58	89.58	16.73	14.49	2.78	2.12
9月30日	90.63	89.58	16.60	14.72	2.43	1.90
12月31日	90.63	90.63	14.12	13.10	2.08	1.65

31日的风电功率曲线变化范围较大但变化方向相对单一,无论是哪天的风电功率曲线,预测区间都能够较大程度地覆盖,并跟随风电功率曲线的变化而变化,且与方案1相比,方案2的预测区间跟随风电功率曲线变化的效果更好。由表5可知,在这4天的预测中,2种方案的 X_{PICP} 都很接近给定的置信水平90%,而方案2的 X_{PINAW} 和 X_{AWD} 均小于方案1,说明方案2能获得更好的区间预测结果,验证了蚁群聚类算法的改进效果。

4.3.2 采用支持向量机的改进效果分析

为了验证支持向量机的改进效果,对算例2中方案1和方案3的结果进行对比分析。图2和表6分别给出了这2种方案的预测结果和预测结果的评价指标。

价指标。




图2 算例2中方案1、3在90%置信水平下的预测结果

Fig.2 Predictive results of Scheme 1 and 3 under 90% confidence level in Example 2

表6 算例2中方案1、3在90%置信水平下的评价指标

Table 6 Evaluation indicators of Scheme 1 and 3 under 90% confidence level in Example 2

预测日期	$X_{PICP}/\%$		$X_{PINAW}/\%$		$X_{AWD}/\%$	
	方案1	方案3	方案1	方案3	方案1	方案3
3月31日	89.58	90.63	14.64	13.66	2.21	1.67
6月30日	89.58	90.63	16.73	14.27	2.78	2.03
9月30日	90.63	90.63	16.60	14.54	2.43	1.79
12月31日	90.63	89.58	14.12	12.77	2.08	1.82

由图2可以看出,方案1、3都能够有效地对风电功率进行区间预测,其预测区间都能较好地覆盖实际值,且方案3的预测区间更窄,其变化更符合实际风电功率的变化规律。由表6可知,在这4天的预测中,2种方案的 X_{PICP} 都与90%很接近,但方案3的 X_{PINAW} 和 X_{AWD} 均小于方案1,即方案3能获得更好的区间预测结果,验证了支持向量机的改进效果。

4.3.3 改进方法的预测效果分析

为了验证改进方法的综合改进效果,对算例2中方案1和方案4的结果进行对比分析。图3和表7分别为这2种方案的预测结果和预测结果的评价指标。




图3 算例2中方案1、4在90%置信水平下的预测结果

Fig.3 Predictive results of Scheme 1 and 4 under 90% confidence level in Example 2

表7 算例2中方案1、4在90%置信水平下的评价指标

Table 7 Evaluation indicators of Scheme 1 and 4 under 90% confidence level in Example 2

预测日期	$X_{PICP}/\%$		$X_{PINAW}/\%$		$X_{AWD}/\%$	
	方案1	方案4	方案1	方案4	方案1	方案4
3月31日	89.58	89.58	14.64	10.69	2.21	1.47
6月30日	89.58	90.63	16.73	11.75	2.78	1.71
9月30日	90.63	89.58	16.60	12.41	2.43	1.60
12月31日	90.63	89.58	14.12	10.16	2.08	1.45

由图3可以看出,方案1和方案4的预测区间都能较大程度地覆盖实际值,但方案4的预测区间更窄,且其跟随实际风电功率变化的能力更强,具有更好的跟随效果。由表7可知,方案1和方案4的 X_{PICP} 都在90%附近,但是方案4的 X_{PINAW} 和 X_{AWD} 均小于方案1。其中,方案4的 X_{PINAW} 较方案1平均减少了27.51%,方案4的 X_{AWD} 较方案1平均减少了34.11%。因此,与传统方法相比,改进方法具有更好的预测效果。另外,还可以看出,6月30日和9月30日的预测效果比3月31日和12月31日的预测效果差。由此可知,传统方法和改进方法对于像3月31日和12月31日的变化方向相对单一的风电功率预测效果较好,而对于像6月30日和9月30

日的变化方向复杂的风电功率预测效果较差。这是因为当风电功率发生较大变化,即上爬坡或下爬坡时,相比于非爬坡阶段,此时的风电功率变化更加复杂,即使基于相似相点进行预测,也难以及时准确跟踪此时风电功率的变化,且相似相点的变化方向、变化时间和变化大小与此时风电功率的差别较大,从而导致此时的预测效果相对较差,区间预测结果有上偏或下偏。

为了进一步分析改进方法的预测效果,对算例2采用3种方法在不同置信水平下的预测结果进行对比分析,具体结果见附录C中的表C5—C8。由表中结果可得:在不同的置信水平下,改进方法均能获得更好的区间预测结果;随着置信水平的上升,预测区间宽度增大,落在区间外的点与区间的偏差减小。

5 结论

本文考虑风电功率的混沌特性,采用蚁群聚类算法和支持向量机对传统混沌时间序列方法进行改进,提出了基于改进混沌时间序列的风电功率区间预测方法。由算例分析结果可得以下结论:

a. 本文所提改进方法能够有效地实现风电功率区间预测,且与基于神经网络的区间预测方法相比,改进方法具有更好的区间预测效果;

b. 与传统混沌时间序列方法相比,改进方法分别采用蚁群聚类算法和支持向量机进行聚类和预测,能够获得好的聚类效果和高的预测精度,从而得到更好的区间预测结果。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 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.
QIAN Zheng, PEI Yan, CAO Lixiao, et al. Review of wind power forecasting method[J]. High Voltage Engineering, 2016, 42(4): 1047-1060.
- [2] FOLEY A M, LEAHY P G, MARVUGLIA A, et al. Current methods and advances in forecasting of wind power generation[J]. Renewable Energy, 2012, 37(1):1-8.
- [3] 黎静华,赖昌伟. 考虑气象因素的短期光伏出力预测的奇异谱分析方法[J]. 电力自动化设备,2018,38(5):50-57,76.
LI Jinghua, LAI Changwei. Singular spectrum analysis method for short-term photovoltaic output prediction considering meteorological factors[J]. Electric Power Automation Equipment, 2018, 38(5): 50-57, 76.
- [4] 冯双磊,王伟胜,刘纯,等. 风电场功率预测物理方法研究[J]. 中国电机工程学报,2010,30(2):1-6.
FENG Shuanglei, WANG Weisheng, LIU Chun, et al. Study on the physical approach to wind power prediction[J]. Proceedings of the CSEE, 2010, 30(2):1-6.
- [5] ERDEM E, SHI J. ARMA based approaches for forecasting the tuple of wind speed and direction[J]. Applied Energy, 2011, 88(4): 1405-1414.
- [6] 冬雷,王丽婕,郝颖,等. 基于自回归滑动平均模型的风力发电容量预测[J]. 太阳能学报,2011,32(5):617-622.
DONG Lei, WANG Lijie, HAO Ying, et al. Prediction of wind power generation based on autoregressive moving average model[J]. Acta Energiae Solaris Sinica, 2011, 32(5):617-622.
- [7] EL-FOULY T H M, EL-SAADANY E F, SALAMA M M A. Improved grey predictor rolling models for wind power prediction[J]. IET Generation, Transmission & Distribution, 2007, 1(6):928-937.
- [8] 杨茂,黄宾阳,江博. 基于概率分布量化指标和灰色关联决策的风电功率实时预测研究[J]. 中国电机工程学报,2017,37(24):7099-7107.
YANG Mao, HUANG Binyang, JIANG Bo. Real-time wind power prediction based on probability distribution and gray relational decision-making[J]. Proceedings of the CSEE, 2017, 37(24): 7099-7107.
- [9] 潘迪夫,刘辉,李燕飞. 基于时间序列分析和卡尔曼滤波算法的风电场风速预测优化模型[J]. 电网技术,2008,32(7):82-86.
PAN Difu, LIU Hui, LI Yanfei. A wind speed forecasting optimization model for wind farms based on time series analysis and Kalman filter algorithm[J]. Power System Technology, 2008, 32(7): 82-86.
- [10] CHEN K L, YU J. Short-term wind speed prediction using an unscented Kalman filter based state-space support vector regression approach[J]. Applied Energy, 2014, 113:690-705.
- [11] KARINIOTAKIS G N, STAVRAKAKIS G S, NOGARET E F. Wind power forecasting using advanced neural networks models[J]. IEEE Transactions on Energy Conversion, 1996, 11(4):762-767.
- [12] LI G, SHI J. On comparing three artificial neural networks for wind speed forecasting[J]. Applied Energy, 2010, 87(7):2313-2320.
- [13] LEE D, BALDICK R. Short-term wind power ensemble prediction based on gaussian processes and neural networks[J]. IEEE Transactions on Smart Grid, 2014, 5(1):501-510.
- [14] 程启明,陈路,程尹曼,等. 基于EEMD和LS-SVM模型的风电功率短期预测方法[J]. 电力自动化设备,2018,38(5):27-35.
CHENG Qiming, CHEN Lu, CHENG Yinman, et al. Short-term wind power forecasting method based on EEMD and LS-SVM model[J]. Electric Power Automation Equipment, 2018, 38(5): 27-35.
- [15] ZENG J W, QIAO W. Short-term wind power prediction using a wavelet support vector machine[J]. IEEE Transactions on Sustainable Energy, 2012, 3(2):255-264.
- [16] TASICIKARAOGLU A, UZUNOGLU M. A review of combined approaches for prediction of short-term wind speed and power[J]. Renewable & Sustainable Energy Reviews, 2014, 34(6):243-254.
- [17] 叶林,刘鹏. 基于经验模态分解和支持向量机的短期风电功率组合预测模型[J]. 中国电机工程学报,2011,31(31):102-108.
YE Lin, LIU Peng. Combined model based on EMD-SVM for short-term wind power prediction[J]. Proceedings of the CSEE, 2011, 31(31): 102-108.
- [18] LIU H, TIAN H, LIANG X, et al. New wind speed forecasting approaches using fast ensemble empirical model decomposition, genetic algorithm, mind evolutionary algorithm and artificial neural networks[J]. Renewable Energy, 2015, 83(11):1066-1075.
- [19] 黎静华,桑川川,甘一夫,等. 风电功率预测技术研究综述[J]. 现代电力,2017,34(3):1-11.
LI Jinghua, SANG Chuanchuan, GAN Yifu, et al. A review of researches on wind power forecasting technology[J]. Modern Electric Power, 2017, 34(3):1-11.
- [20] KHOSRAVI A, NAHAVANDI S, CREIGHTON D. Prediction intervals for short-term wind farm power generation forecasts[J]. IEEE Transactions on Sustainable Energy, 2013, 4(3):602-610.

- [21] KAVOUSI-FARD A, KHOSRAVI A, NAHAVANDI S. A new fuzzy-based combined prediction interval for wind power forecasting[J]. IEEE Transactions on Power Systems, 2016, 31(1): 18-26.
- [22] KHOSRAVI A, NAHAVANDI S, CREIGHTON D, et al. Lower upper bound estimation method for construction of neural network-based prediction intervals[J]. IEEE Transactions on Neural Networks, 2011, 22(3): 337-346.
- [23] QUAN H, SRINIVASAN D, KHOSRAVI A. Short-term load and wind power forecasting using neural network-based prediction intervals[J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25(2): 303-315.
- [24] 陈杰, 沈艳霞, 陆欣, 等. 一种风电功率概率区间多目标智能优化预测方法[J]. 电网技术, 2016, 40(8): 2281-2287.
CHEN Jie, SHEN Yanxia, LU Xin, et al. An intelligent multi-objective optimized method for wind power prediction intervals[J]. Power System Technology, 2016, 40(8): 2281-2287.
- [25] WAN C, XU Z, PINSON P, et al. Optimal prediction intervals of wind power generation[J]. IEEE Transactions on Power Systems, 2014, 29(3): 1166-1174.
- [26] 杨锡运, 关文渊, 刘玉奇, 等. 基于粒子群优化的核极限学习机模型的风电功率区间预测方法[J]. 中国电机工程学报, 2015, 35(增刊1): 146-153.
YANG Xiyun, GUAN Wenyan, LIU Yuqi, et al. Prediction intervals forecasts of wind power based on PSO-KELM[J]. Proceedings of the CSEE, 2015, 35(Supplement 1): 146-153.
- [27] ZHANG G Y, WU Y G, WONG K P, et al. An advanced approach for construction of optimal wind power prediction intervals[J]. IEEE Transactions on Power Systems, 2015, 30(5): 2706-2715.
- [28] 张亚超, 刘开培, 秦亮, 等. 基于聚类经验模态分解-样本熵和优化极限学习机的风电功率多步区间预测[J]. 电网技术, 2016, 40(7): 2045-2051.
ZHANG Yachao, LIU Kaipei, QIN Liang, et al. Wind power multi-step interval prediction based on ensemble empirical mode decomposition-sample entropy and optimized extreme learning machine[J]. Power System Technology, 2016, 40(7): 2045-2051.
- [29] HU M Y, HU Z J, YUE J P, et al. A novel multi-objective optimal approach for wind power interval prediction[J]. Energies, 2017, 10(4): 419.
- [30] PINSON P, KARINIOTAKIS G. Conditional prediction intervals of wind power generation[J]. IEEE Transactions on Power Systems, 2010, 25(4): 1845-1856.
- [31] 兰飞, 桑川川, 梁浚杰, 等. 基于条件 Copula 函数的风电功率区间预测[J]. 中国电机工程学报, 2016, 36(增刊1): 79-86.
LAN Fei, SANG Chuanchuan, LIANG Junjie, et al. Interval prediction for wind power based on conditional copula function[J]. Proceedings of the CSEE, 2016, 36(Supplement 1): 79-86.
- [32] 周松林, 茆美琴, 苏建徽. 风电功率短期预测及非参数区间估计[J]. 中国电机工程学报, 2011, 31(25): 10-16.
ZHOU Songlin, MAO Meiqin, SU Jianhui. Short-term forecasting of wind power and non-parametric confidence interval estimation[J]. Proceedings of the CSEE, 2011, 31(25): 10-16.
- [33] 刘兴杰, 谢春雨. 基于贝塔分布的风电功率波动区间估计[J]. 电力自动化设备, 2014, 34(12): 26-30, 57.
LIU Xingjie, XIE Chunyu. Wind power fluctuation interval estimation based on Beta distribution[J]. Electric Power Automation Equipment, 2014, 34(12): 26-30, 57.
- [34] 李智, 韩学山, 杨明, 等. 基于分位点回归的风电功率波动区间分析[J]. 电力系统自动化, 2011, 35(3): 83-87.
LI Zhi, HAN Xueshan, YANG Ming, et al. Wind power fluctuation interval analysis based on quantile regression[J]. Automation of Electric Power Systems, 2011, 35(3): 83-87.
- [35] ZHANG Y C, LIU K P, QIN L, et al. Deterministic and probabilistic interval prediction for short-term wind power generation based on variational mode decomposition and machine learning methods[J]. Energy Conversion and Management, 2016, 112: 208-219.
- [36] 张学清, 梁军. 风电功率时间序列混沌特性分析及预测模型研究[J]. 物理学报, 2012, 61(19): 70-81.
ZHANG Xueqing, LIANG Jun. Chaotic characteristics analysis and prediction model study on wind power time series[J]. Acta Physica Sinica, 2012, 61(19): 70-81.
- [37] 江岳春, 张丙江, 邢方方, 等. 基于混沌时间序列 GA-VNN 模型的超短期风功率多步预测[J]. 电网技术, 2015, 39(8): 2160-2166.
JIANG Yuechun, ZHANG Bingjiang, XING Fangfang, et al. Super-short-term multi-step prediction of wind power based on GA-VNN model of chaotic time series[J]. Power System Technology, 2015, 39(8): 2160-2166.
- [38] 王兰, 李华强, 吴星, 等. 基于改进局域 Volterra 自适应滤波器的风电功率混沌时间序列预测模型[J]. 电力自动化设备, 2016, 36(8): 40-44.
WANG Lan, LI Huaqiang, WU Xing, et al. Wind power chaotic time series prediction model based on improved local Volterra adaptive filter[J]. Electric Power Automation Equipment, 2016, 36(8): 40-44.
- [39] 方仍存. 电力系统负荷区间预测[D]. 武汉: 华中科技大学, 2008.
FANG Rengcun. Power system load interval forecasting[D]. Wuhan: Huazhong University of Science & Technology, 2008.
- [40] 郭杰昊. 基于混沌时间序列的短期负荷预测研究[D]. 上海: 上海交通大学, 2015.
GUO Jiehao. Research on short-term load algorithm for chaotic time series[D]. Shanghai: Shanghai Jiaotong University, 2015.
- [41] 韩敏. 混沌时间序列预测理论与方法[M]. 北京: 中国水利水电出版社, 2007: 61-89.
- [42] 裴振奎, 李华, 宋建伟, 等. 蚁群聚类算法研究及应用[J]. 计算机工程与设计, 2008, 29(19): 5009-5013.
PEI Zhenkui, LI Hua, SONG Jianwei, et al. Investigation and application of ant colony clustering algorithms[J]. Computer Engineering and Design, 2008, 29(19): 5009-5013.
- [43] 蒋传文, 袁智强, 侯志俭, 等. 高嵌入维混沌负荷序列预测方法研究[J]. 电网技术, 2004, 28(3): 25-28.
JIANG Chuanwen, YUAN Zhiqiang, HOU Zhijian, et al. Research of forecasting method on chaotic load series with high embedded dimension[J]. Power System Technology, 2004, 28(3): 25-28.

作者简介:



黎静华

黎静华(1982—),女,广西博白人,教授,博士,主要研究方向为电力系统优化运行与控制、大规模风电并网技术等(**E-mail**: happyjinghua@163.com);

黄玉金(1994—),男,广西陆川人,硕士研究生,主要研究方向为高比例可再生能源电力系统预测(**E-mail**: huangyujin.gxu@qq.com);

黄乾(1989—),男,广西宾阳人,博士研究生,主要研究方向为高比例再生能源电力系统预测(**E-mail**: q.huang.gxu@qq.com)。

(下转第68页 continued on page 68)

Application of optimizing state number Markov chain Monte Carlo algorithm in wind power generation

XU Shenzhi¹, AI Xiaomeng¹, ZOU Jiaxin², ZHANG Shujie², LI Pai³, HUANG Yuehui³, WEN Jinyu¹

(1. Hubei Electric Power Security and High Efficiency Key Laboratory, State Key Laboratory of Advanced Electromagnetic Engineering and Technology, School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China; 2. Key Laboratory of Photovoltaic Power Generation and Grid Integration, State Grid Qinghai Electric Power Research Institute, Xining 810008, China; 3. State Key Laboratory of Operation and Control of Renewable Energy & Storage Systems, China Electric Power Research Institute, Beijing 100192, China)

Abstract: The state number selection of traditional MCMC (Markov Chain Monte Carlo) method often depends on personal experience, it is difficult to simulate the probability distribution and autocorrelation characteristics of original wind power series at the same time when the method is applied in wind power series modelling, for which, an OSN-MC (Optimizing State Number Markov Chain Monte Carlo) algorithm is proposed. Firstly, the state number selection range of MCMC method is given. Secondly, the optimal state number is determined based on the principle of minimizing the square sum of autocorrelation function error of generated series and original series. Then the cumulative distribution function in the corresponding power range of each state is adopted to generate random wind power, which improves the simulation accuracy of generated wind power series to the probability distribution of original series. The OSN-MC and MCMC methods are applied to generate wind power series for 12 wind farms in China, the United States and Europe, and the comparison with the original measured series shows that the simulation effect of wind power series generated by OSN-MC algorithm on the distribution and autocorrelation characteristics of original series is better than that of MCMC algorithm.

Key words: wind power; Markov chain; Monte Carlo method; optimizing state number; series generation

(上接第 60 页 continued from page 60)

Interval prediction method of wind power based on improved chaotic time series

LI Jinghua, HUANG Yujin, HUANG Qian

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

Abstract: Wind power interval prediction is to predict the upper and lower limits of wind power at a given confidence level, which can reflect the variation ranges of wind power and provide effective auxiliary information for scheduling. An interval prediction method of wind power based on improved chaotic time series is proposed considering the chaotic characteristics of wind power. Due to the strong intermittency and fluctuation of wind power, the traditional chaotic time series method is difficult to obtain good clustering effect and high prediction accuracy in wind power interval prediction, which affects the prediction results. The ant colony clustering algorithm and support vector machine are introduced to improve the traditional method by using the strong searching ability of ant colony clustering algorithm and the strong predictive ability of support vector machine, and then better interval prediction results are obtained. The improved method is applied to the wind power interval prediction of wind farms in Britain and Germany. The interval prediction results of the improved method, the interval prediction method based on neural network and the traditional method are compared and analyzed at different confidence levels, and the validity of the proposed improved method is verified.

Key words: wind power; interval prediction; chaotic time series; ant colony clustering algorithm; support vector machines

附录 A

表 A1 变量说明
Table A1 Variable declaration

变量	含义
$\boldsymbol{P}$	原始风电功率序列
$\boldsymbol{P}_w$	相空间重构后形成的矩阵
$\boldsymbol{P}_w(M)$	$\boldsymbol{P}_w$ 中最新的一个相点
$\boldsymbol{P}_s$	$\boldsymbol{P}_w(M)$ 的相似相点集
$\boldsymbol{P}_s(1)$	$\boldsymbol{P}_s$ 中的第一个相点
$\boldsymbol{P}_{j,1}$	与 $\boldsymbol{P}_s(1)$ 距离较小的 K 个相点
$\boldsymbol{P}_{j,1}^h$	$\boldsymbol{P}_{j,1}$ 中每个相点对应的 h 时刻后的相点
$\boldsymbol{P}_Y(1)$	$\boldsymbol{P}_s(1)$ 在 h 时刻后相点的预测值
$\boldsymbol{P}_Y$	$\boldsymbol{P}_s$ 中所有相点在 h 时刻后相点的预测值
$\boldsymbol{P}_{Ym}$	$\boldsymbol{P}_Y$ 的最后一列预测值

附录 B

$$X_{\text{PICP}} = \frac{1}{L_w} \sum_{i=1}^{L_w} \omega_i \quad (\text{B1})$$

其中, L_w 为预测风电功率的点数; ω_i 为布尔量, 当对应时刻风电功率的实际值落在预测区间内时, $\omega_i = 1$, 否则 $\omega_i = 0$ 。

$$X_{\text{PINAW}} = \frac{1}{L_w G_1} \sum_{i=1}^{L_w} (\bar{U}_i - \underline{U}_i) \quad (\text{B2})$$

其中, G_1 用于归一化处理; $\bar{U}_i$ 和 $\underline{U}_i$ 分别为预测区间的上界和下界。

第 i 个预测点的带宽偏差为:

$$X_{\text{AWD},i}(P(i)) = \begin{cases} \frac{\underline{U}_i - P(i)}{\bar{U}_i - \underline{U}_i} & P(i) < \underline{U}_i \\ 0 & \underline{U}_i \leq P(i) \leq \bar{U}_i \\ \frac{P(i) - \bar{U}_i}{\bar{U}_i - \underline{U}_i} & P(i) > \bar{U}_i \end{cases} \quad (\text{B3})$$

其中, $P(i)$ 为要预测的风电功率的实际值。

累积带宽偏差为:

$$X_{\text{AWD}} = \frac{1}{L_w G_2} \sum_{i=1}^{L_w} X_{\text{AWD},i}(P(i)) \quad (\text{B4})$$

其中, G_2 用于归一化处理。

附录 C

表 C1 算例 1 中 3 种区间预测方法的结果对比 (3 月 25—31 日)
Table C1 Result comparison among three interval prediction methods in Example 1(March 25 to 31)

置信水平/%	$X_{\text{PICP}}/\%$			$X_{\text{PINAW}}/\%$			$X_{\text{AWD}}/\%$		
	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法
85	84.82	84.38	85.42	14.18	10.00	14.95	2.71	2.53	2.96
90	90.03	90.33	90.63	16.00	11.23	16.23	2.00	1.77	1.78
95	94.94	95.39	94.79	18.81	14.27	18.59	0.95	0.89	0.93
98	98.07	97.62	97.92	20.03	16.10	19.39	0.75	0.70	0.70

表 C2 算例 1 中 3 种区间预测方法的结果对比（6 月 24—30 日）

Table C2 Result comparison among three interval prediction methods in Example 1(June 24 to 30)

置信水平/%	$X_{PICP}/\%$			$X_{PINAW}/\%$			$X_{AWD}/\%$		
	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法
85	85.27	85.57	84.82	14.94	12.12	15.78	3.21	2.92	3.00
90	89.88	89.73	90.63	17.34	14.42	18.87	1.56	1.04	1.09
95	95.09	95.09	94.79	19.88	17.04	20.91	1.07	0.86	0.96
98	98.21	98.51	97.92	21.87	18.27	21.93	0.73	0.55	0.60

表 C3 算例 1 中 3 种区间预测方法的结果对比（9 月 24—30 日）

Table C3 Result comparison among three interval prediction methods in Example 1(September 24 to 30)

置信水平/%	$X_{PICP}/\%$			$X_{PINAW}/\%$			$X_{AWD}/\%$		
	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法
85	85.27	85.42	84.97	15.60	12.37	15.45	2.94	2.67	2.86
90	90.48	90.18	90.03	17.87	14.41	17.33	2.11	1.75	1.92
95	94.64	94.79	94.49	19.49	16.50	18.78	1.00	0.80	1.05
98	97.17	97.32	97.77	21.07	17.84	20.34	0.76	0.51	0.72

表 C4 算例 1 中 3 种区间预测方法的结果对比（12 月 25—31 日）

Table C4 Result comparison among three interval prediction methods in Example 1(December 25 to 31)

置信水平/%	$X_{PICP}/\%$			$X_{PINAW}/\%$			$X_{AWD}/\%$		
	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法
85	84.67	84.23	85.12	13.23	10.84	14.64	3.82	3.19	3.30
90	89.58	89.73	89.88	16.70	13.49	16.81	1.79	1.31	1.50
95	95.39	95.54	95.09	19.65	16.01	18.67	0.90	0.64	0.77
98	98.36	97.77	98.07	20.89	16.93	20.66	0.61	0.36	0.53

表 C5 算例 2 中 3 种区间预测方法的结果对比（3 月 25—31 日）

Table C5 Result comparison among three interval prediction methods in Example 2(March 25 to 31)

置信水平/%	$X_{PICP}/\%$			$X_{PINAW}/\%$			$X_{AWD}/\%$		
	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法
85	84.38	84.97	84.67	13.66	9.85	12.29	4.02	3.15	3.53
90	90.03	89.58	89.73	15.41	10.79	14.25	2.17	1.49	1.93
95	95.09	94.79	95.09	18.13	13.80	16.95	1.30	0.99	1.19
98	97.62	97.92	97.77	19.24	15.44	18.65	0.87	0.62	0.82

表 C6 算例 2 中 3 种区间预测方法的结果对比（6 月 24—30 日）

Table C6 Result comparison among three interval prediction methods in Example 2(June 24 to 30)

置信水平/%	$X_{PICP}/\%$			$X_{PINAW}/\%$			$X_{AWD}/\%$		
	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法
85	85.12	84.67	85.42	13.57	10.15	13.41	3.90	3.32	3.78
90	90.18	89.29	89.43	16.25	12.85	15.69	2.33	1.81	2.12
95	94.49	95.24	94.94	17.82	14.08	17.15	1.20	1.11	1.34
98	98.07	97.77	98.21	19.75	15.33	18.79	0.97	0.48	0.69

表 C7 算例 2 中 3 种区间预测方法的结果对比（9 月 24—30 日）

Table C7 Result comparison among three interval prediction methods in Example 2(September 24 to 30)

置信水平/%	$X_{PICP}/\%$			$X_{PINAW}/\%$			$X_{AWD}/\%$		
	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法
85	85.27	84.52	85.12	13.16	9.64	12.41	3.70	3.09	3.28
90	89.58	89.73	90.18	15.44	12.46	14.80	2.21	1.72	2.30
95	94.94	94.35	94.79	17.29	13.38	17.07	1.14	1.03	1.06
98	97.32	97.47	98.21	18.76	14.87	19.10	0.90	0.56	0.75

表 C8 算例 2 中 3 种区间预测方法的结果对比（12 月 25—31 日）

Table C8 Result comparison among three interval prediction methods in Example 2(December 25 to 31)

置信水平/%	$X_{PICP}/\%$			$X_{PINAW}/\%$			$X_{AWD}/\%$		
	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法	传统方法	改进方法	神经网络方法
85	85.42	84.82	85.27	14.35	10.35	15.14	4.26	3.44	3.63
90	89.43	89.88	90.03	16.03	11.45	17.11	2.37	1.60	1.85
95	94.79	94.64	95.24	19.04	14.22	18.54	1.38	1.08	1.22
98	98.36	98.21	98.07	20.42	16.39	19.55	0.96	0.66	0.79