

DOI: 10.19783/j.cnki.pspc.200981

基于聚类分析和混合自适应进化算法的短期风电功率预测

李福东¹, 曾旭华², 魏梅芳², 丁敏³

(1. 北京信息科技大学, 北京 100192; 2. 长沙电力职业技术学院, 湖南 长沙 410131;
3. 中国地质大学, 湖北 武汉 430074)

摘要: 针对传统风电功率预测方法难以满足精细化、动态化建模要求, 存在易陷入局部最优等问题, 提出了基于聚类分析和混合自适应进化算法(KHEA)的风电功率智能预测方法。首先, 采用 K 均值聚类算法对全年风速和功率数据进行聚类, 剔除不合理的数据。然后, 采用小波变换(WT)识别功率数据的行为特征, 获得解构序列集, 进而建立 BP 神经网络模型对未来时间段的功率解构序列进行预测。为减少预测误差, 采用进化粒子群算法(EPHO)对模型的权值和阈值进行调整和优化, 实现 EPHO 进化特性与神经网络自学习能力的功能互补。最后, 运用逆小波变换对预测序列进行重构, 获得最终的功率预测值。运用中国南方某风电场数据开展仿真实验, 并与其他模型进行对比, 表明 KHEA 具有更高的风电功率短期预测精度和可靠性, 为提高风电功率预测精度和优化调度管理提供了新的技术方案。

关键词: 风电功率预测; K 均值聚类算法; 进化粒子群算法; 小波变换; 神经网络

Short-term wind power forecasting based on cluster analysis and a hybrid evolutionary-adaptive methodology

LI Fudong¹, ZENG Xuhua², WEI Meifang², DING Min³

(1. Beijing Information Science and Technology University, Beijing 100192, China;
2. Changsha Electric Power Vocational and Technical College, Changsha 410131, China;
3. China University of Geosciences, Wuhan 430074, China)

Abstract: It is difficult for traditional wind power forecasting methods to meet the requirements of refined and dynamic modeling. It is also easy for them to fall into local optimality. Thus an intelligent wind power forecasting method based on cluster analysis and a Hybrid Adaptive Evolution Algorithm (KHEA) is proposed. First, the K -means clustering algorithm is used to cluster the annual wind speed and power data to eliminate unreasonable data. Then, Wavelet Transform (WT) is used to identify the behavioral characteristics of the power data, and the set of deconstructed sequences is obtained. Then a BP neural network model is established to predict the power deconstructed sequence in a future time period. In order to reduce the prediction error, the Evolutionary Particle Swarm Optimization (EPHO) is used to adjust and optimize the weights and thresholds of the model, so as to realize the function complementation of EPHO evolution characteristics and neural network self-learning capabilities. Finally, the inverse wavelet transform is used to reconstruct the prediction sequence to obtain the final power prediction value. Using the data of a wind farm in southern China to carry out simulation experiments, and comparing with other models, it shows that KHEA has higher wind power short-term prediction accuracy and reliability, and provides new technical solutions for improving wind power prediction accuracy and optimizing dispatch management.

This work is National Natural Science Foundation of China (No. 61503348).

Key words: wind power prediction; K -means clustering algorithm; evolutionary particle swarm optimization; wavelet transform; neural network

0 引言

风能作为重要的清洁能源, 近年来得到了快速

发展和应用。由于风能的不确定性, 大规模风电并网对电力系统安全所造成的影响也得到广泛关注, 提高风电功率预测准确度和可靠性, 是风电领域关注的技术热点。风电预测按周期可分为超短期预测、短期预测和中长期预测^[1-2]。基于时间序列的预测方法典型的包括统计模型和人工智能模型, 利用风电场历史数据和风速、温度和湿度等气象数据进

基金项目: 中国博士后科学基金面上项目资助(163612); 国家自然科学基金项目资助(61503348); 国网湖南省电力有限公司科技项目资助(SGTYHT/19-JS-217)

行建模和预测,如自回归滑动平均(ARMA)模型^[3]和自回归综合滑动平均模型(ARIMA)^[4]已经应用于风速和风能预测。尽管时间序列模型是简单的预测方法,并且易于实现,但其中大多数是线性预测器,而风能通常是其输入特征的非线性函数。

人工智能方法一般多用于超短期和短期预测,典型的有神经网络法、支持向量机法、遗传算法等^[5-8],特别是神经网络方法得到广泛研究。递归神经网络^[9-10]、径向基函数(RBF)神经网络^[11]和多层感知器(MLP)神经网络^[12]已用于风电功率预测。神经网络可以对非线性输入/输出映射函数进行建模,但采用传统训练机制的单个神经网络学习能力有限,可能无法正确学习风电场相关信息的复杂行为^[13]。为解决这一问题,将神经网络与模糊系统等结合的方法得到研究,如自适应神经模糊推理系统(ANFIS)^[14-16]、结合MLP神经网络的混合迭代预测。但以上方法模糊逻辑模型的规则数量很多,导致方法复杂度很高和处理时间过长^[17]。

解决风电时间序列复杂行为的另一种方法是使用小波变换。文献[18]介绍了小波可以有效地用于平稳和非平稳时间序列分析的功能,这是该方法能在很多领域和场合都得到应用的原因之一。现有基于小波变换的风速和功率预测方法中,包括将小波变换作为分解风速/功率时间序列的预处理器,应用到ANFIS^[19]、自回归滑动平均(ARMA)^[20]、人工神经网络(ANN)^[20]和支持向量回归(SVR)^[21-23]中。但支持向量机方法高度依赖于参数的适当调整,涉及复杂的优化过程^[23]。小波也可以作为神经元的激活函数应用于神经网络结构。文献[24]提出了小波神经网络用于风速预测,并通过扩展卡尔曼滤波器进行训练,由于以上模型是以母波为基础,按比例缩放和移位得到的许多小波组成,因此依赖于有效的算法来训练模型,并且要避免在寻找模型的最佳输入/输出映射函数时不会陷入局部最优。文献[25]提出一种基于粒子群和遗传算法的改进人工神经网络,用于短期风电预测。文献[26]提出了一种风电功率预测策略,包括改进的混合神经网络和增强型粒子群算法(EPHO)。近年来,运用深度学习捕获多个风电场之间的空间和时间相关性,开展基于深度学习的新型时空风电功率预测也受到关注^[27-29]。另外,利用粒子群算法和遗传算法等优化风电功率预测模型参数的方法虽有较多研究,但存在收敛过早及精度不足的问题。万有引力搜索算法与其他智能优化算法相比,具有结构简单、寻优能力强等特点,但其早熟收敛、局部最优、搜索能力不足的问题仍然存在^[30-32]。人工智能方法的自适应、自学习

能力较突出,但对数据的规模和质量要求高,需要较长训练时间,影响其实用性^[33-35]。

基于以上研究现状,本文以风电功率数值聚类分析为基础,提出了一种基于聚类分析和混合自适应进化算法(K-means clustering and hybrid evolutionary adaptive methodology, KHEA)的短期风电功率预测方法。该方法以输入变量聚类分析为基础,采取小波变换(Wavelet Transform, WT)、进化粒子群算法(Evolutionary Particle Swarm Optimization, EPSO)和BP神经网络结合,建立风电功率预测模型。最后,运用现场数据进行实验,将本文方法与差分自回归移动平均模型(ARIMA)、BP神经网络、小波-神经网络(BPWT)等模型进行对比,验证了本文提出的KHEA预测模型的性能。

1 风电场季节和时段特征识别

1.1 数据预处理

本论文是基于风电场历史数据开展分析和建模,考虑现场数据采集和调节控制之间的时间滞后、测量误差、数据噪点等影响数据准确性的因素,对原有以1 min为采集周期的各类原始数据,均按15 min为时间间隔求取平均值进行预处理。图1为该风电场某一台风机历史运行数据中风速及有功功率曲线。经关联分析可知,风速是影响有功功率及发电绘制风速-功率关系量的关键因素。

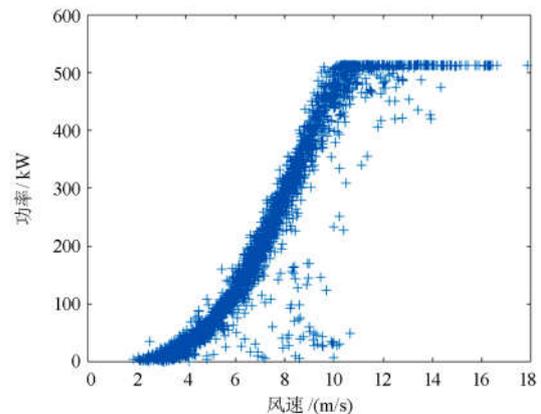


图1 风速和功率关系图

Fig. 1 Wind turbine output power and wind speed

1.2 风电场数据聚类分析

利用历史数据进行风电功率预测,数据的质量对预测准确度有很大的影响,此外,了解风速、功率在不同时段的变化特性,有助于建立预测模型时,采取针对性、差异化的参数配置,提高预测算法的效率和模型对具体数据的适应性。基于以上考虑,

本文采取 K 均值聚类算法进行风电场 2019 年全年功率和风速数据的分析处理。 K 均值聚类算法是一种基于划分和迭代求解的聚类方法, 其基本思路是预将数据划分为 K 组, 每一组随机选取一个对象作为该组的初始聚类中心, 然后计算每个对象与各聚类中心之间的距离, 按照与聚类中心最近距离原则将各对象进行分配, 完成分配后, 最后重新计算聚类中心, 不断重复以上过程直到满足终止条件^[36]。本文采用 K 均值聚类算法, 通过调试适当的聚类中心数, 对风速、功率输入样本中的无效数据进行识别和剔除, 然后划分出若干样本类别, 为每一类分别建立预测模型, 以此提高风电功率预测的准确性。风速和功率 K 均值聚类结果在本文第 3 部分进行了详细介绍。

2 基于 KHEA 算法的风电功率预测

2.1 KHEA 算法的基本思路

本文提出的 KHEA 算法以经过聚类后的输入数据为基础, 综合运用 WT 和 BP 神经网络, 并利用 EPSO 对参数进行优化。运用 WT 对风电功率序列进行分解, 以更好地识别功率数据的行为特征。基于小波分解的序列, 通过 BP 神经网络模型对未来一段时间的风电功率解构序列集进行预测。为减少预测误差, 采用 EPSO 对神经网络模型的权值和阈值参数进行调整和优化, 以提高预测模型的性能。与传统粒子群算法相比, EPSO 具有更好的收敛性能, 同时, EPSO 的进化特性与 BP 神经网络的自学习能力实现功能的互补。通过对 BP 神经网络参数优化达到预测效果后, 运用逆 WT 进行预测序列的重构, 获得最终的风电功率预测结果。

2.2 功率数据小波变换

时间序列中的非平稳行为主要由该序列的均值和方差的不稳定性引起。WT 用于非固定或时变集时, 对输入集的不确定性具有很强的敏感性, 能够有效识别集合中的不同非平稳信息而不影响原始信号, 因此可以减少集合中的噪声且不会降低信号的质量。离散小波变换定义如式(1)所示。

$$Q(m, n) = 2^{-(m/2)} \sum_{t=0}^{T-1} f(t) \varphi\left(\frac{t-v}{u}\right) \quad (1)$$

式中: 变量 T 表示信号 $f(t)$ 的长度; 参数 φ 的缩放和平移分别通过 $u = 2^m$ 和 $v = n2^m$ 实现; 时间步长由 t 给定。本文针对风电功率序列建立离散 WT 的三级分解模型。本文离散 WT 算法基于四个滤波器, 分为两组: 低通和高通滤波器中的分解以及低通和

高通滤波器中的重构。

2.3 EPSO 算法

EPSO 对应于一种元启发式方法, 其中规则和优化概念包含在进化策略和自适应属性中。每个粒子由对象参数和策略参数描述。因此, EPSO 的公式由对象参数 X 和对应于权重的策略参数 ω 组成。EPSO 的移动规则定义为

$$X_i^{\text{new}} = X_i + V_i^{\text{new}} \quad (2)$$

$$V_i^{\text{new}} = \omega_{i0}^* V_i + \omega_{i1}^* (b_i - X_i) + \omega_{i2}^* (b_g^* - X_i) \quad (3)$$

式中: V_i 表示粒子 i 的速度; b_i 和 b_g^* 分别是实时位置和全局最佳位置。

假设粒子 X_i 完成第 t 次寻优, 获得历史适应度均值 $\overline{\text{suit}}(t)$ 为

$$\overline{\text{suit}}(t) = \frac{1}{N} \sum_{i=1}^N \text{suit}_i(t) \quad (4)$$

为实现权重的自适应调整, 本文引入一个自适应权重系数, 具体公式为

$$\omega_i(t) = (\omega_{\max} - \omega_{\min}) \exp\left(-a \left(\frac{M}{M_{\max}}\right)^2\right) \quad (5)$$

式中: a 分布于 $[10, 25]$; $\omega_i(t)$ 表示粒子 p_i 在第 t 次寻优时对应的权重; ω_{\max} 、 ω_{\min} 分别表示自适应权重系数值的上限和下限; M_{\max} 为最大迭代数。由以上公式可知, 通过自适应修正, 可以均衡粒子的局部搜索和全局搜索能力, 避免粒子陷入局部最优, 提高算法的寻优速度和收敛精度。

2.4 KHEA 算法的步骤

具体步骤描述如下:

Step 1: 数据的预处理。将原有以 1 min 为周期的数据转换为 15 min 为周期的数据样本。

Step 2: 对风速和功率数据进行 K 均值聚类分析, 得到若干个类。

Step 3: 判断聚类中心是否发生变化或是否达到最大迭代数, 记录结果作为 WT 的输入。

Step 4: 对功率样本进行离散小波分解并保存结果。

Step 5: 建立 BP 神经网络, 采用单隐层结构, 隐含层神经元的个数通过试凑法或经验公式确定。

Step 6: 基于小波分解的序列, 建立 BP 神经网络。

Step 7: 运用 EPSO 算法, 依据式(3)对粒子的速度进行更新。

Step 8: 依据式(2)对粒子的位置进行更新。

Step 9: 计算全局最优值 b_g^* , 通过以上计算确

定适应度。

Step 10: 判断粒子群是否获得最佳适应度或是否收敛, 若未获得最佳适应度或未收敛, 则重复步骤 Step7—Step9 的过程, 直到获得最优参数, 将其输入神经网络。

Step 11: 利用 K 均值聚类处理后的输入数据和 EPSO 给定的优化参数训练神经网络, 若神经网络未收敛, 则回到 Step6; 若神经网络达到精度目标 0.01, 则回到 Step2 重新计算。当网络收敛或达到最好结果, 则执行逆 WT 对预测序列进行重构, 得到功率的预测值。

Step 12: 用不同的误差标准计算风电功率预测误差, 以验证本文方法的性能, 将获得的结果与其他方法进行比较。

2.5 预测误差评价指标

本文采用均方根误差 (RMSE) 和平均绝对误差 (MAE) 来评估短期风电功率预测精度。RMSE 可评估一段时期内的整体误差, 而 MAE 偏重代表系统实时偏差^[5]。以上指标定义如下。

(1) 均方根误差 E_{RMSE}

$$E_{RMSE} = \frac{1}{G_{cap}} \sqrt{\frac{1}{N} \sum_{t=1}^N (G_t^{act} - G_t^{pred})^2} \quad (6)$$

(2) 平均绝对误差 E_{MAE}

$$E_{MAE} = \frac{1}{NG_{cap}} \sum_{t=1}^N |G_t^{act} - G_t^{pred}| \quad (7)$$

式中: G_{cap} 为预测对象的装机容量; N 为样本数量; G_t^{pred} 、 G_t^{act} 分别表示在 t 时刻风电场或单台机组输出功率的预测值、实际值。

3 实例仿真与分析

3.1 数据选择与模型参数初始化

(1) 风电样本数据选取

实验测试中, 选取中国湖南某风电场 2019 年 1 月 1 日至 2019 年 12 月 31 日的风机实际运行数据及该地区数值天气数据为例进行研究, 该风电场装机容量为 50 MW, 包括 25 台单机容量为 2 MW 的风机。

处理后数据样本的间隔时间为 15 min。经数据归一化处理并采用 K 均值聚类, 选取该风电场气象数据和历史输出功率数据(5 200 个)作为预测模型的输入样本数据, 其中, 前 4 200 个数据作为训练样本, 其余数据作为测试样本, 学习目标为实测功率。

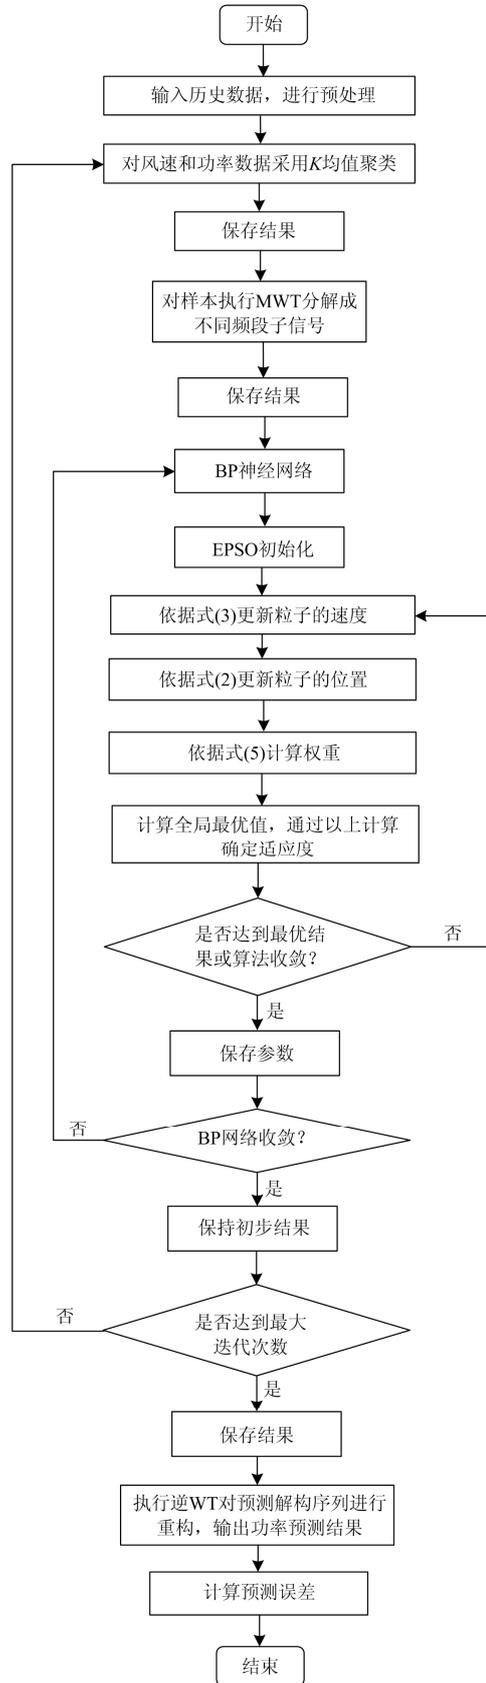


图 2 风电功率预测流程图

Fig. 2 Flowchart of wind power prediction

(2) 预测模型及参数初始化

本文针对功率预测建立 3 层 BP 神经网络, 包括输入层、隐含层和输出层。输入层神经元和输出层神经元各为 1 个, 采取单隐层结构, k 为隐含层神经元的数量, 通过式(8)确定。

$$k = \sqrt{p+q+c} \quad (8)$$

式中: p 、 q 分别代表输入层和输出层的数量; c 为介于[1,10]之间的常数。 c 的具体值在实验中通过经验和试错方法确定最佳值。为尽量提高模型训练质量, 但又应避免过度拟合对预测带来的不利影响, 将 BP 神经网络训练按 0.01 精度作为收敛目标值。

EPSO 算法中, 粒子数设置为 60, 适应度加速值为 2, 初始惯性权重和最终惯性权重分别为 0.9 和 0.4, 最大迭代次数为 300, 更新位置最大值和最小值分别为 1 500 和 5。在达到最大迭代次数 300 后, 若算法继续迭代 50 次不再收敛, 则可以确保算法已经收敛。

3.2 风电场数据 K 均值聚类分析结果

图 3 为该风电场某台风机 2019 年全年的风速和功率数据经 K 均值聚类后的结果, 横轴为风速, 纵轴为功率。为区分不同的类, 设置了若干种颜色(因实际得到的类的数量大于实验平台中可设置的颜色数量, 因此, 同一颜色但在不同位置的两个类, 其实属于不同的类)。通过聚类结果可以得到以下结论:

(1) K 均值聚类可有效剔除明显不合理的数据, 如聚类图中底部红色的数据类, 是风速大于 5 m/s 但无输出功率的样本点集合, 表示具备发电风速条件但由于其他原因未输出功率的状况, 这类数据如不进行有效剔除, 将对预测模型性能产生很大的负面影响。

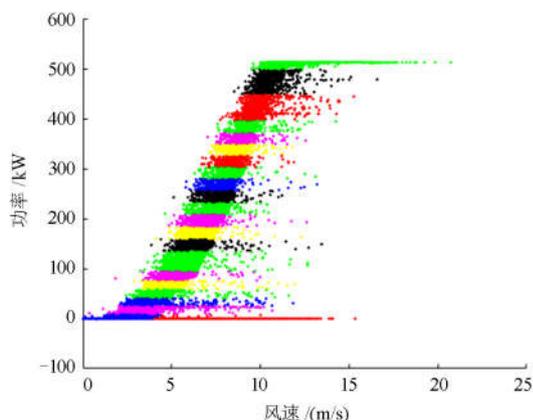


图 3 风速和功率 K 均值聚类结果图

Fig. 3 Wind speed and power K mean clustering result graph

(2) 根据不合理数据识别和聚类情况, 以及各类数据聚类的效果进行不同类数量的调整测试, 最终得到 25 个数据类(图中自上而下有 3 个宽度明显大一些的数据集, 实际各包括 2 个不同的类, 因颜色分配的随机性导致这些相邻的类具有相同的颜色所致)。通过得到的风速和功率数据类, 可有针对性地针对功率预测模型参数进行匹配, 从而提高预测过程中对不同数据的识别, 提高预测的效率。

3.3 算法性能对比分析

本文仿真实验在 Matlab 2016a 环境下对本文提出的 KHEA 方法进行仿真实验, 并与自回归综合滑动平均模型(ARIMA)、BP 神经网络、小波神经网络(BPWT)三种预测方法进行对比。分别统计 4 个模型的性能指标结果, 如表 1 所示。

表 1 各预测方法的评价指标

Table 1 Evaluation index of each forecasting method				
模型/误差	ARIMA	BP	BPWT	KHEA
$R_{RMSE}/\%$	8.46	5.06	4.77	4.02
$R_{MAE}/\%$	7.28	4.12	3.64	3.12

从表 1 结果可以看出, KHEA 模型的所有预测性能指标均优于其余 3 种模型(ARIMA、BP、BPWT)。

3.4 不同模型对风电功率预测效果对比分析

为验证本文所提模型的风电功率预测效果, 取风电场 48 h 共 192 个实际运行数据作为测试数据对 4 个模型(ARIMA、BP、BPWT、KHEA)的预测性能进行验证, 得出的预测结果与实际值数据比较如图 4 所示。

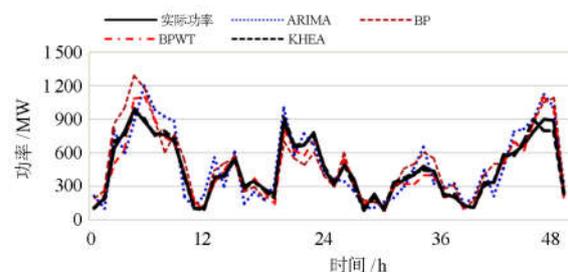


图 4 不同模型预测值与实际值比较

Fig. 4 Comparison of predicted and actual values of different models

图 5 为不同模型预测误差对比曲线。由图 4、图 5 可以明显看出, KHEA 模型在跟踪实际功率曲线变化趋势方面的性能指标均优于其余 3 种模型的性能指标。通过对 4 种方法的预测误差结果, 分别

统计出 4 种预测模型预测误差小于 2%、小于 4%、小于 10%的点数及其占总预测点数的百分比, 统计结果如表 2 所示。

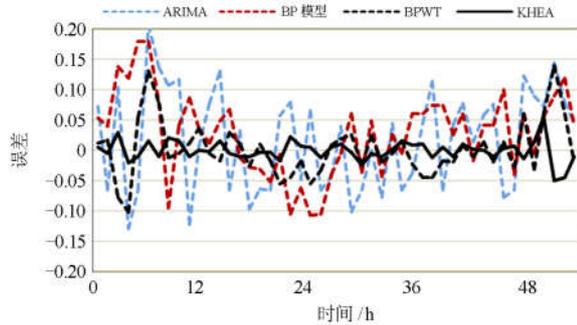


图 5 不同模型预测误差对比曲线
Fig. 5 Comparison curves of prediction errors of different models

表 2 不同模型预测精度统计对比

Table 2 Statistics of prediction accuracy of different models

误差范围/模型		ARIMA	BP	BPWT	KHEA
<2%	quantity	35	46	78	130
	%	18.23%	23.96%	40.63%	67.71%
<4%	quantity	67	85	124	177
	%	34.90%	44.27%	64.58%	92.19%
<10%	quantity	132	150	179	192
	%	68.75%	78.13%	93.23%	100.00%

由表 2 可知, KHEA 模型的绝对误差小于 2%、小于 4%、小于 10%的预测点占比分别为 67.71%、92.19%、100%, 三项指标均优于其余 3 种对比模型。以上结果表明, KHEA 模型具有更高的功率预测精度, 适用于中型风电场开展短期风电功率预测。

为进一步验证, 将同样的测试样本应用于本文建立的预测模型, 对比输入数据未经 K 均值聚类 and 经过 K 均值聚类的性能指标, 结果如表 3 所示。由表 3 可知, 通过采用 K 均值聚类分析对不合理数据的识别和剔除, 对风速和功率进行聚类, 有助于改善模型性能, 提高风电功率预测的精度。

表 3 聚类分析的效果对比

Table 3 Comparison of the effects of cluster analysis

模型	$R_{RMSE}/\%$	$R_{MAE}/\%$	误差小于 2% 的比例	误差小于 4% 的比例	误差小于 10% 的比例
未聚类处理的 KHEA	4.48	3.34	62.56	90.53	100
基于聚类的 KHEA	4.02	3.12	67.71	92.19	100

4 结论

本文在分析现有风电功率智能预测方法特点的基础上, 建立了基于 KHEA 模型的风电功率预测方法。通过现场数据统计分析, 采用聚类分析方法对风速和功率数据进行识别和筛选, 合理获得若干数据类, 根据不同的输入数据类, 有针对性地优化预测模型参数。通过 WT 有效识别功率数据的行为特征, 得到解构系列集。通过 BP 神经网络模型对经 WT 后的解构序列集进行预测。为减少预测误差, 采用 EPSO 对模型参数进行调整和优化, 以提高预测模型的性能。与传统粒子群算法相比, EPSO 算法具有更好的收敛性能, 同时, EPSO 的进化特性与 BP 的自学习能力实现功能的互补。BP 神经网络参数通过优化参数达到预测效果后, 对预测的功率解构序列执行逆 WT, 获得预测的功率值。

通过基于现场数据开展仿真实验结果显示, 本文提出的 KHEA 风电功率短期预测模型的均方根误差、平均绝对误差均优于其余 3 种模型 (ARIMA、BP、BPWT)。通过与 ARIMA、BP、BPWT 模型的仿真结果相比, 本文所提方法具有更高的风电功率短期预测精度和可靠性。为风电场开展精细化、动态化建模, 实现可靠的功率预测, 最终为优化调度管理提供了一种新的技术方法。

参考文献

- [1] 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.
- [2] 杨阳, 杨璐, 郎劲, 等. 基于 LS-SVM 算法的多场景风电功率预测研究[J]. 智慧电力, 2017, 45(7): 58-63.
YANG Yang, YANG Lu, LANG Jin, et al. Study on multi-scenario wind power prediction based on LS-SVM algorithm[J]. Smart Power, 2017, 45(7): 58-63.
- [3] ERDEM E, SHI J. ARMA based approaches for forecasting the tuple of wind speed and direction[J]. Applied Energy, 2011, 88: 1405-1414.
- [4] SFETSOS A. A novel approach for the forecasting of mean hourly wind speed time series[J]. Renew Energy, 2002, 27: 163-174.
- [5] YANG J. A novel short-term multi-input-multi-output prediction model of wind speed and wind power with LSSVM based on improved ant colony algorithm optimization[J]. Cluster Computing, 2019, 22(S2):

- 3293-3300.
- [6] 马彦宏, 汪宁渤, 马明, 等. 基于神经网络的酒泉风电基地超短期风电功率预测方法[J]. 电力建设, 2013, 34(9): 1-5.
MA Yanhong, WANG Ningbo, MA Ming, et al. Ultra-short-term wind power prediction method based on neural network for Jiuquan wind power base[J]. Electric Power Construction, 2013, 34(9): 1-5.
- [7] 范高锋, 王伟胜, 刘纯. 基于人工神经网络的风电功率短期预测系统[J]. 电网技术, 2008, 32(22): 72-76.
FAN Gaofeng, WANG Weisheng, LIU Chun. Artificial neural network based wind power short term prediction system[J]. Power System Technology, 2008, 32(22): 72-76.
- [8] 琚垚, 祁林, 刘帅. 基于改进乌鸦算法和 ESN 神经网络的短期风电功率预测[J]. 电力系统保护与控制, 2019, 47(4): 58-64.
JU Yao, QI Lin, LIU Shuai. Short-term wind power forecasting based on improved crow search algorithm and ESN neural network[J]. Power System Protection and Control, 2019, 47(4): 58-64.
- [9] BARBOUNIS T, THEOCHARIS J. Locally recurrent neural networks for long-term wind speed and power prediction[J]. Neurocomputing, 2006, 69: 466-496.
- [10] RODRÍGUEZ F, FLOREZ-TAPIA A M, FONTA L. Very short-term wind power density forecasting through artificial neural networks for microgrid control[J]. Renewable Energy, 2020, 145: 1517-1527.
- [11] SIDERATOS G, HATZIARGYRIOU N. Using radial basis neural networks to estimate wind power production[C] // IEEE Power Engineering Society General Meeting, June 24-28, 2007, Tampa, FL, USA: 1-7.
- [12] METHAPRAYOON K, YINGVIVATANAPONG C, LEE W J, et al. An integration of ANN wind power estimation into unit commitment considering the forecasting uncertainty[J]. IEEE Transactions on Industrial Application, 2007, 43(6): 1441-1448.
- [13] MARUGÁN A P, MÁRQUEZ F P G, PEREZ J M P, et al. A survey of artificial neural network in wind energy systems[J]. Applied Energy, 2018, 228: 1822-1836.
- [14] POTTER C, NEGNEVITSKY M. Very short-term wind forecasting for Tasmanian power generation[J]. IEEE Transactions on Power Systems, 2006, 21(2): 965-972.
- [15] POUSINHO H, MENDES V, CATALAO J. A hybrid PSO-ANFIS approach for short-term wind power prediction in Portugal[J]. Energy Conversion Management, 2011, 52: 397-402.
- [16] 徐龙博, 王伟, 张滔, 等. 基于神经网络平均影响值的超短期风电功率预测[J]. 电力系统自动化, 2017, 41(21): 46-51.
XU Longbo, WANG Wei, ZHANG Tao, et al. Ultra-short term wind power prediction based on mean impact value of neural network[J]. Automation of Electric Power Systems, 2017, 41(21): 46-51.
- [17] TASCIKARA OGLU A, UZUNOGLU M. A review of combined approaches for prediction of short-term wind speed and power[J]. Renewable and Sustainable Energy Reviews, 2014, 34: 243-254.
- [18] CATALÃO J, POUSINHO H M I, MENDES V. Hybrid intelligent approach for short-term wind power forecasting in Portugal[J]. IET Renewable Power Generation, 2011, 5: 251-257.
- [19] FARIA D, CASTRO R, PHILIPPART C, et al. Wavelets pre-filtering in wind speed prediction[C] // 2009 International Conference on Power Engineering, Energy and Electrical Drives, March 18-20, 2009, Lisbon, Portugal: 168-173.
- [20] DE AQUINO R R B, LIRA M M S, DE OLIVEIRA J, et al. Application of wavelet and neural network models for wind speed and power generation forecasting in a Brazilian experimental wind park[C] // 2009 International Joint Conference on Neural Networks, June 14-19, 2009, Atlanta, GA, USA: 172-178.
- [21] CHEN P, CHEN H, YE R. Chaotic wind speed series forecasting based on wavelet packet decomposition and support vector regression[C] // 2010 Conference Proceedings IPEC, October 27-29, 2010, Singapore, Singapore: 256-261.
- [22] 田璧源, 刘琪, 张新燕, 等. 基于 APSO-GSA 和相关向量机的短期风电功率预测[J]. 电力系统保护与控制, 2020, 48(2): 107-114.
TIAN Biyuan, LIU Qi, ZHANG Xinyan, et al. Short-term wind power prediction based on APSO-GSA and correlation vector machine[J]. Power System Protection and Control, 2020, 48(2): 107-114.
- [23] 乔颖, 鲁宗相, 闵勇. 提高风电功率预测精度的方法[J]. 电网技术, 2017, 41(10): 3261-3269.
QIAO Ying, LU Zongxiang, MIN Yong. Research & application of raising wind power prediction accuracy[J]. Power System Technology, 2017, 41(10): 3261-3269.
- [24] RICALDE L J, CATZIN G, ALANIS A Y, et al. Higher order wavelet neural networks with Kalman learning for wind speed forecasting[C] // 2011 IEEE Symposium on

- Computational Intelligence Applications in Smart Grid (CIASG), April 11-15, 2011, Paris, France: 1-6.
- [25] VIET D T, PHUONG V V, DUONG M Q, et al. Models for short-term wind power forecasting based on improved artificial neural network using particle swarm optimization and genetic algorithms[J]. Energy, 2020, 13: 1-22.
- [26] AMJADY N, KEYNIA F, ZAREIPOUR H. Wind power prediction by a new forecast engine composed of modified hybrid neural network and enhanced particle swarm optimization[J]. IEEE Transactions on Sustainable Energy, 2011, 2: 265-276.
- [27] HU Tianyu, WU Wenchuan, GUO Qinglai, et al. Very short-term spatial and temporal wind power forecasting: a deep learning approach[J]. CSEE Journal of Power and Energy Systems, 2020, 6(2): 432-443.
- [28] 韩自奋, 景乾明, 张彦凯, 等. 风电预测方法与新趋势综述[J]. 电力系统保护与控制, 2019, 47(24): 178-187.
HAN Zifen, JING Qianming, ZHANG Yankai, et al. Review of wind power forecasting methods and new trends[J]. Power System Protection and Control, 2019, 47(24): 178-187.
- [29] HONG Y Y, RIOFLFLORIDO C L P P. A hybrid deep learning-based neural network for 24-h ahead wind power forecasting[J]. Applied Energy, 2019, 250: 530-539.
- [30] CHEN Hao, ZHANG Jianzhong, TAO Yubo, et al. Asymmetric GARCH type models for asymmetric volatility characteristics analysis and wind power forecasting[J]. Protection and Control of Modern Power Systems, 2019, 4(4): 356-366. DOI: 10.1186/s41601-019-0146-0.
- [31] 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.
- [32] 阎洁, 李宁, 李莉, 等. 短期风电功率动态云模型不确定性预测方法[J]. 电力系统自动化, 2019, 43(3): 17-23.
YAN Jie, LI Ning, LI Li, et al. Uncertainty prediction method of dynamic cloud model for short-term wind power[J]. Automation of Electric Power Systems, 2019, 43(3): 17-23.
- [33] 田波, 朴在林, 郭丹, 等. 基于改进 EEMD-SE-ARMA 的超短期风功率组合预测模型[J]. 电力系统保护与控制, 2017, 45(1): 72-79.
TIAN Bo, PIAO Zailin, GUO Dan, et al. Wind power ultra short-term model based on improved EEMD-SEARMA[J]. Power System Protection and Control, 2017, 45(1): 72-79.
- [34] LI Fudong, LIAO Huanyu. An intelligent method for wind power forecasting based on integrated power slope events prediction and wind speed forecasting[J]. IEEE Transactions on Electrical and Electronic Engineering, 2018, 13(8): 1931-1940.
- [35] SAROHA S, AGGARWAL S K. Wind power forecasting using wavelet transforms and neural networks with tapped delay[J]. CSEE Journal of Power and Energy Systems, 2018, 4(2): 197-209.
- [36] 刘美玲, 黄名选, 汤卫东. 基于离散量优化初始聚类中心的 k-means 算法[J]. 计算机工程与科学, 2017, 39(6): 1164-1170.
LIU Meiling, HUANG Mingxuan, TANG Weidong. A k-means algorithm for optimized initial clustering center based on discrete quantity[J]. Computer Engineering & Science, 2017, 39(6): 1164-1170.

收稿日期: 2020-08-12; 修回日期: 2020-10-16

作者简介:

李福东(1982—), 男, 博士, 副教授, 研究方向为风电功率预测、新能源并网、智慧能源系统; E-mail: lifudong0635@sina.com.cn

曾旭华(1968—), 男, 通信作者, 硕士, 副教授, 研究方向为电力仿真、新能源技术; E-mail: 14300806@qq.com

魏梅芳(1982—), 女, 硕士, 副教授, 研究方向为新能源并网、智慧能源系统。E-mail: weimf@csepte.net

(编辑 张爱琴)