

DOI:10.19651/j.cnki.emt.2106876

短期风电功率预测中的 IOFA-SVM 算法实现<sup>\*</sup>谢波<sup>1</sup> 高建宇<sup>2</sup> 张惠娟<sup>1</sup> 刘金委<sup>2</sup>

(1. 河北工业大学 省部共建电工装备可靠性与智能化国家重点实验室 天津 300130; 2. 华北理工大学 轻工学院 唐山 063000)

**摘要:** 在风电等清洁能源的开发和应用中,为提高风电输出功率预测精度,设计出改进最优觅食算法-优化支持向量机(IOFA-SVM)预测模型,在传统最优觅食算法中加入柯西变异和差分进化策略来提高算法的全局寻优能力以获取 SVM 的最优参数。用改进后的 IOFA-SVM 模型进行预测,并将预测结果与 BP、GWO-SVM、OFA-SVM 模型进行对比,在相同的条件和参数下,该模型 3 种评价指标 MAE、NMAE 和 NRMSE 至少下降 0.59%、0.53% 和 0.50%,表明 IOFA-SVM 模型确实提高了风电功率预测精度和准确性,对电能调度和电网稳定运行具有重要意义。

**关键词:** 风电功率预测;最优觅食算法;支持向量机;柯西变异优化;差分进化策略

**中图分类号:** TM614 **文献标识码:** A **国家标准学科分类代码:** 460.4047

## Improved optimal foraging algorithm for support vector machine of short-term wind power prediction

Xie Bo<sup>1</sup> Gao Jianyu<sup>2</sup> Zhang Huijuan<sup>1</sup> Liu Jinwei<sup>2</sup>

(1. State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300130, China;

2. Qingong College, North China University of Science and Technology, Tangshan 063000, China)

**Abstract:** In development and application of wind energy, for improving the prediction accuracy of wind power output, a prediction model based on improved optimal foraging algorithm for support vector machine (IOFA-SVM) is proposed. Cauchy variation and differential mutation strategy are added into the traditional optimal foraging algorithm to improve the global optimization ability to obtain the optimal parameters of SVM. Using the improved IOFA-SVM model to predict wind power output and comparing the results with BP, GWO-SVM and OFA-SVM models, the three evaluation indexes MAE, NMAE and NRMSE of the model decreased by 0.59%, 0.53% and 0.50% respectively, which shows that the IOFA-SVM model does improve the precision and accuracy of wind power output prediction, and is important to dispatch electric energy and maintain power grid stability.

**Keywords:** wind power output prediction; optimal foraging algorithm; support vector machine; cauchy mutation optimization; differential mutation strategy

## 0 引言

经济发展对能源的需求与日俱增,但资源枯竭、环境污染和气候变化等问题与现实要求矛盾日益突出,所以清洁能源的开发利用得到各国的大力关注<sup>[1]</sup>。风力资源作为一种清洁能源,在我国的蕴含量十分丰富,风能的大规模开发利用将极大缓解环境污染和用电负荷持续增长的问题,但由于风能受气象因素影响严重的特性导致风电输出功率具有间歇性、随机性,大规模风电并网将会影响电网的电压和频率,并将对电网安全运行及电力部门做出合理的调度计划造成巨大影响<sup>[2]</sup>。因此,准确地预测风电输出功率对促

进清洁能源的开发利用和电网的安全经济运行具有重要意义。

短期风电功率预测一般将对未来 72 h 之内的风电输出功率作为主要研究内容,预测方法主要包括物理方法和统计方法<sup>[3]</sup>。物理方法是一种基于数值天气预报的方法,利用大量气象数据做数值计算来预测未来的天气情况,并根据风电场的功率曲线预测输出功率值,但物理方法对天气预报系统的预测精度要求较高,所需要的输入数据较难获得且数据量大,故该方法没有得到广泛应用<sup>[4]</sup>。统计方法主要对风电场的输出功率和气象数据进行训练,构建数据之间的映射关系,采用线性或非线性方法来预测输出功

收稿日期:2021-05-20

<sup>\*</sup> 基金项目:天津市自然科学基金重点项目(19JCZDJC32100)资助

率。但统计方法需要对大量的历史数据进行训练,训练速度较慢,模型中的随机参数对预测结果影响较大。而近些年随着智能算法的研究深入,开始利用智能算法预测风电输出功率,例如人工神经网络(artificial neural network, ANN)、灰色预测(grey prediction)、自回归平均滑动(autoregressive moving average models, ARMA)模型、极限学习机(extreme learning machine, ELM)和支持向量机(support vector machine, SVM)等<sup>[5]</sup>。ANN 学习能力、自适应能力强,但对样本个数比较敏感,且易陷入局部最优解;灰色预测适用范围广,精确度较高,但依赖于历史数据,当输入数据较少,预测结果误差较大;ARMA 对数据依赖性低,但当数据存在残缺时,模型的预测效果变差;ELM 训练速度快,泛化能力强,但鲁棒性较差限制了其应用。

文献[6]和[7]分别利用改进后的 BP 神经网络模型对短期风电功率和电力负荷进行预测,所提模型克服传统神经网络易陷入局部最优的缺点,提高模型预测精度和收敛速度。文献[8]用广义回归神经网络对光伏电站进行短期功率预测,将与输出功率相关系数较高的气象因子作为模型输入,并采用灰色关联度分析来选定与待预测日关联度最高的最佳相似日,利用最佳相似日的输出功率、气象因子和待预测日的气象数据作为神经网络输入进而得到输出功率的预测值,但会受到原始数据的限制,原始数据必须近似指数变化。文献[9]提出一种基于变分模式分解(variational modal decomposition, VMD)和 ELM 的混合预测模型,在预测过程中使用 VMD 技术将风能的时间序列分解为不同分解模式,把这些模式用于训练 ELM,将所有模式预测值相加来得到风电输出功率,预测结果证明该模型的预测精度和收敛速度均有所提高,但模态分解增加了模型的计算成本。文献[10]提出一种径向基函数神经网络模型对风电输出功率预测,提高神经网络的泛化能力,有效提高模型的预测能力,但此模型只对单一影响因素进行研究,导致预测误差依然较高。文献[11]用改进轻型梯度提升机算法和卷积神经网络相结合对长期风电功率进行预测,该方法改善了卷积神经网络对数据敏感的缺点,提高了预测的精度,但是预测速度较慢,实用性较差。文献[12]采用一维卷积和因果卷积运算构建短期风电功率预测模型,加快了训练速度,提高了预测准确度。

SVM 由于自身具有结构简单、泛化能力良好、易于获取到全局最优解等优点而在预测领域得到广泛应用<sup>[13]</sup>。但 SVM 的预测精度与核函数参数和惩罚参数的选取密切相关,可通过智能优化算法获取最优参数来更好地解决预测问题<sup>[14]</sup>。文献[15]和[16]分别提出了一种向后寻优蝙蝠算法、改进的鲸鱼优化算法与 SVM 相结合的风速和光伏输出功率预测模型,通过对真实数据集的分析与计算证明了所提模型相对于传统 SVM 有更优的预测性能,但预测精度仍有进一步提升空间。文献[17]利用改进骨架微分进化算法优化 SVM 预测西藏某地风电场,改善了 SVM 易

受学习参数影响的缺点,提高了预测的精度,但是求解速度较慢。文献[18]利用粒子群算法优化 SVM 来预测光伏电池输出功率,虽使预测精度得到提升,但粒子群算法收敛时间较长。文献[19]先根据风电振幅频率分解时间,再结合最小方块支持向量机结合进行短期风电预测,改进后的预测模型提高了鲁棒性和预测精度,但该算法的收敛速度有待提高。

针对 SVM 预测精度低,收敛速度慢等问题,本文对近年提出的、本身即具有较强寻优能力的最优觅食算法(optimal foraging algorithm, OFA)进行改进,在经典的 OFA 中加入柯西变异,设计了改进型的 OFA(improved OFA, IOFA),通过增强动物在选取最优觅食位置时的随机性,提高算法及早跳出局部最优觅食位置并找到全局最优解的能力;在此基础上建立 IOFA 与 SVM 相结合的新型预测模型,即 IOFA-SVM 模型,利用 IOFA 优化 SVM 的内部参数,有效解决因内部参数设置不当而影响 SVM 预测精度的问题。本文将 IOFA-SVM 模型用于风电功率的短期预测,利用真实的风电场数据检验其有效性,结果表明该模型有较高的预测精度和较快的收敛速度。

## 1 算法介绍

### 1.1 最优觅食算法

最优觅食算法(OFA)是基于最优觅食理论开发的一种随机搜索算法,根据动物觅食理论解决全局优化问题<sup>[20]</sup>。在该算法中将个体视作觅食动物,用觅食位置表征目标解,动物在觅食过程中总是在食物最丰富的区域聚集,所以动物聚集之地就是食物富足的区域,故可在当前位置及附近寻找最优解。

在 OFA 算法中,动物觅食位置用  $d$  维向量  $[x_1, \dots, x_i, \dots, x_d]^T$  表示,其中  $x_i \in [x^L, x^U]$ ,  $x^L$  和  $x^U$  分别为变量  $x_i$  上下边界,根据最优觅食理论,算法将用式(1)在当前觅食位置附近搜索最佳位置:

$$x_i^{t+1} = x_i^t - k \times r_{1i} \times \Delta x_i^t + k \times r_{2i} \times \Delta x_i^t, t = 1, 2, \dots \quad (1)$$

式中:  $x_i^t$  为第  $i$  个个体  $t$  次搜索后的觅食位置;  $x_i^{t+1}$  为个体  $x_i^t$  更新过后新的觅食位置;  $k$  为比例因子;  $r_{1i}$  和  $r_{2i}$  均匀分布于  $[0, 1]$  之间的随机值;  $\Delta x_i^t$  为个体  $x_i^t$  更新觅食位置的位置增量。

为使个体离开局部最优解,继续搜索潜在的最优解, OFA 算法通过招募其他个体来扩大搜索空间,从而避免陷入局部最优。在  $t$  次搜索中第  $j$  个个体的第  $i$  个觅食位置增量  $\Delta x_{ji}^t$  为:

$$\begin{cases} \Delta x_{ji}^t = x_{ji}^t - x_{ji}^t (F_b^t < F_j^t; F_j^t \neq \min(F_1^t, \dots, F_N^t)); \\ b = 1, \dots, N; j = 1, \dots, N; i = 1, \dots, d) \\ \Delta x_{ji}^t = x_{ji}^t - x_{ji}^t (F_j^t = \min(F_1^t, \dots, F_N^t)); \\ (F_N^t = \max(F_1^t, \dots, F_N^t); i = 1, \dots, d) \end{cases} \quad (2)$$

式中:  $x_{bi}^t, x_{ji}^t, x_{Ni}^t$  分别为  $t$  次搜索时,  $b$  个体所处的第  $i$  个觅食位置, 第  $j$  个个体所处的第  $i$  个觅食位置和此次搜索中种群最差的觅食位置;  $F_b^t, F_j^t, F_N^t$  分别为  $x_{bi}^t, x_{ji}^t, x_{Ni}^t$  所对应目标函数值。

当种群中所有个体均更新完觅食位置后, 算法将会根据此时位置的目标函数值也即为动物觅食能量摄入量来判断新位置是否优于原位置以及决定在随后的搜索过程中是否使用该位置, 其原理可用如下公式描述:

$$\frac{\lambda_j^{t+1} F_j^{t+1}}{1 + \lambda_j^{t+1}(t+1)} > \frac{F_j^t}{t} \quad (3)$$

式中:  $\lambda_j^{t+1}$  为  $[0, 1]$  的随机数。

若更新后的位置满足上述公式则将在  $t+1$  次搜索时将获得的位置用于下次搜索, 否则将忽略此位置并保留  $t$  次搜索位置。

### 1.2 改进最优觅食算法

OFA 算法通过对现实中动物觅食理论进行模拟, 使得该算法具有较好的寻优能力, 但在搜索过程中, 觅食位置的范围会随着搜索次数的增加而自适应减少, 逐渐聚集在局部最优解附近, 导致搜索范围多样性减少, 发生早熟收敛, 陷入局部最优, 不能找到全局最优觅食位置。柯西分布是一种连续分布, 其数学期望不存在, 概率密度分布曲线对称分布于峰值左右, 在峰值两端的数值递减趋于 0, 且分布较长, 其分布式为:

$$f(x) = \frac{1}{\pi} \left( \frac{1}{x^2 + 1} \right) \quad (4)$$

在算法中加入柯西变异能在当前的觅食位置附近产生较大的扰动, 在搜索时朝更广的范围变异, 使搜索觅食位置获得有更大的随机性, 提升算法的搜索能力, 及时跳出局部最优, 其原理如下:

$$x_i^{t+1} = \vec{A} \cdot \tan((\gamma - 0.5) \times \pi) \times x_i^t + \gamma(x_j^t - x_k^t) \quad (5)$$

式中:  $\vec{A}$  为从 1~0 线性递减的向量;  $\gamma$  为均匀分布于  $[0, 1]$  之间的随机值。

在柯西变异之后, 计算新的觅食位置的目标函数值并对其进行排序, 将新位置的最优位置与变异前位置进行比较, 确定最优位置并继续搜索。

为避免在搜索过程中出现早熟现象, 本文引入差分变异策略来增加群体的多样性。采用差分变异策略中的 DE/rand/1 策略对种群向量进行变异, 在每一次迭代后期加入差分变异策略, 算式如下:

$$h^{i,t} = x^{p_1,t} + F \times (x^{p_2,t} - x^{p_3,t}) \quad (6)$$

式中:  $p_1 \neq p_2 \neq p_3$ ,  $x^{p_2,t} - x^{p_3,t}$  为差分向量;  $F \in [0.1, 0.9]$  为缩放因子;  $h^{i,t}$  为第  $i$  个位置在第  $t$  次迭代的变异向量。

得到变异向量后, 进行交叉操作:

$$v^{i,t} = \begin{cases} h_j^{i,t}, & j = j_0 \ \& \ \text{rand}(0,1) \leq pCR \\ x_j^{i,t}, & \text{其他} \end{cases} \quad (7)$$

式中:  $v^{i,t}$  为第  $i$  个搜索位置的交叉变量;  $j_0$  为维数中的一个随机值, 每次交叉操作仅涉及个体的一个维度,  $pCR \in [0, 1]$  为交叉概率。

之后进行选择操作, 按照贪婪准则保留目标函数值较优向量作为下一代个体, 选择操作表示为:

$$x^{i,t+1} = \begin{cases} v^{i,t}, & f(v^{i,t}) < f(x^{i,t}) \\ x^{i,t}, & \text{其他} \end{cases} \quad (8)$$

改进后的最优觅食算法具体过程如下:

- 1) 初始化种群觅食位置, 并计算每个个体的目标函数值。
- 2) 对目标函数值进行排序, 记录当前最优觅食位置和最优目标函数值。
- 3) 根据式(3)计算新的觅食位置并计算新的目标函数值。
- 4) 根据式(4)判断新的觅食位置, 选出当前最优觅食位置为最优解。
- 5) 根据式(6)对当前最优觅食位置进行柯西变异, 计算目标函数值。
- 6) 比较变异前后的目标函数值, 若变异后的觅食位置优于之前位置, 保留变异后的位置用于下次搜索, 否则忽略新位置。
- 7) 根据式(6)~(8)对每个个体进行差分进化操作。
- 8) 判断是否达到最大搜索次数, 达到结束搜索并输出最优觅食位置, 否则继续执行步骤 3)。

## 2 支持向量机

支持向量机(SVM)是一种基于统计学习理论的机器学习方法, 主要分为两类, 可用于模式分类和非线性回归。当 SVM 用来做回归预测分析时, 可以通过一个非线性映射  $\varphi(x)$  函数, 将低维样本  $x$  映射到更高维的向量空间  $R^n$  中, 可以更好地解决小样本问题, 其函数关系如下:

$$f(x) = \omega \cdot \varphi(x) + b \quad (9)$$

式中:  $\omega$  为权值系数;  $b$  为偏置项;  $f(x)$  为样本  $x$  对应的预测值。

应用结构风险最小化原则可以将向量回归问题可以转化为一个包含约束的优化问题。将  $f(x)$  与真实值  $y$  之差所满足的实际允许拟合误差  $\epsilon$  考虑到回归问题计算中, 为了估计预测点偏差大小并加入两个松弛因子  $\xi_i$  和  $\xi_i^*$ , 回归问题就变成了目标优化问题, 目标函数以及约束条件分别为:

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (10)$$

$$\begin{cases} y_i - \omega \cdot x_i - b \leq \epsilon + \xi_i \\ \omega \cdot x_i + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i \geq 0 \\ \xi_i^* \geq 0, i = 1, 2, \dots, n \end{cases} \quad (11)$$

式中:  $C$  为惩罚参数, 其值的大小代表对跳出允许拟合误差

$\epsilon$  不敏感点的惩罚力度。

为求解上式,引入拉格朗日函数,可以将寻找带有条件的最优值问题转化为无限制条件的函数。对各个参数求解偏导,利用对偶定理并加入核函数的 SVM 的回归函数式为:

$$f(x) = \sum_{i=1}^n (a_i - \alpha_i^*) K(x_i, x_j) + b \quad (12)$$

径向基函数(radial basis function, RBF)具有高分辨率、计算量少、实用性强的特点,可以有效地将来自输入空间的样本映射到高维特征空间,有利于低维小样本数据表示对原始输入输出空间的非线性关系。在本文中核函数选取 RBF,即:

$$K(x_i, x_j) = \exp\left(-\frac{\|x - x_i\|}{\delta^2}\right) \quad (13)$$

式中: $\delta$  为核函数的带宽。

### 3 案例分析

#### 3.1 数据收集与处理

本文研究的数据来自法国 La Haute Borne 风电场第 1 台发电机组 2017 年的运行数据,该发电机组的额定功率是 2 050 kW,数据集的采样间隔是 1 h,包括同一时刻的风速、风向、温度、湿度和风电输出功率等数据。所选取数据具有较大的波动性,是典型的风电场数据。根据研究发现,同一时刻的风速和风向对此时的输出功率有较大影响,所以在本文中,将风速和风向对应的正弦值与余弦值作为输入数据,将对应时刻的输出功率作为输出数据。为降低风电预测输入数据剧烈的波动性对预测精度的影响,使所提的风电预测模型更好地适应风电输出变化规律,在本文中对数据包括训练数据中的风电功率、风速和风向正余弦值,预测数据中的风速和风向正余弦值均进行归一化处理,文中以风电功率为例进行原理说明。

$$P_{scale,i} = \frac{P_i - P_{min}}{P_{max} - P_{min}} \quad (14)$$

式中: $P_{scale,i}$  为归一化后的风电功率; $P_i$  为风电输出功率真实值; $P_{max}$  和  $P_{min}$  分别为原始风电功率中的最大值和最小值。

#### 3.2 选取目标函数与评价指标

为了更好地评估风电功率预测结果,本文选择均方根误差(RMSE)作为 SVM 的目标函数,并有:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (P_i - Y_i)^2}{N}} \quad (15)$$

式中: $N$  为待预测数据中风电输出功率个数; $P_i$  为风电输出功率真实值; $Y_i$  为输出功率预测值。

为验证所提预测模型的优劣,需要借助评级指标来衡量预测模型结果的误差大小,本文中引入的误差评价指标如下。

1)平均绝对误差(mean absolute error, MAE)

$$MAE = \frac{1}{N} \sum_{i=1}^N \left| \frac{(P_i - Y_i)}{P_N} \right| \quad (16)$$

2)标准绝对值平均误差(normalized mean absolute error, NMAE)

$$NMAE = \frac{\sum_{i=1}^N |P_i - Y_i|}{NP_N} \times 100\% \quad (17)$$

3)标准均方误差(normalized root mean square error, NRMSE)

$$NRMSE = \frac{1}{P_N} \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - Y_i)^2} \quad (18)$$

式中: $P_N$  为发电机组的额定功率。

### 3.3 建立风电预测模型

由于风能的间歇及波动的自身特性导致风电功率输出不稳定,故可将风电系统看成非线性系统回归问题,本文采用支持向量机来预测风电输出功率,算法执行具体步骤如下。

1)选取输入输出数据,进行归一化处理。

2)设置算法和 SVM 模型参数。

3)运行改进后的 OFA 算法,选取最优惩罚因子  $c$  和核函数参数  $g$ 。

4)对输入待预测数据建立 SVM 回归预测模型得到预测结果,并进行反归一化。

5)与实际风电功率数据对比,选取评价指标衡量预测结果。

预测模型具体的流程如图 1 所示。

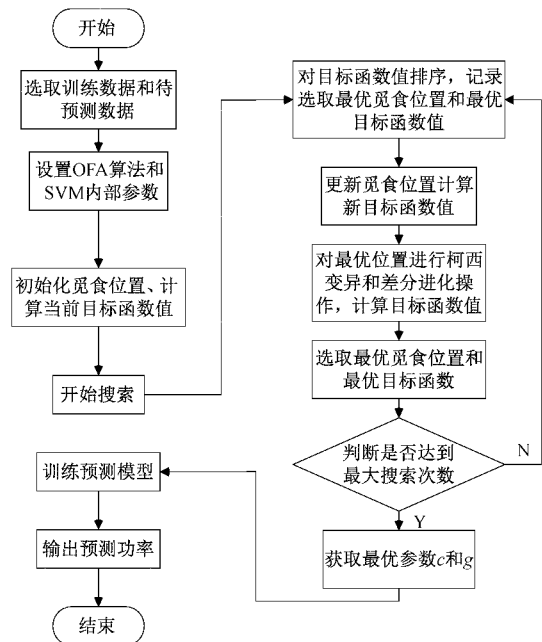


图 1 风电输出功率预测流程

### 3.4 风电输出功率预测分析

为了验证所提出的改进 OFA 算法优化 SVM 预测模型的性能,本文中选取了未改进的 OFA 算法、BP 神经网络和灰狼优化算法进行对比,其中灰狼优化算法是最近几年提出的新的智能优化算法。算法中的相关参数设置如下:种群数量为 30,最大搜索次数为 300,惩罚因子  $c$  的搜索范围为  $[0.1, 1 200]$ ,核函数参数  $g$  为  $[0.01, 100]$ ,算法只对两个参数寻优所以种群维数为 2。各个算法中的其余参数均为默认值。

本文选取秋季某周的风电数据作为实验样本,每天统计 24 个样本,7 天共包含 168 个样本。选取前 5 天的数据共 120 个样本,作为原始训练数据对预测模型进行训练;选取后 2 天的数据共 48 个样本,作为待预测数据对模型进行测试。训练样本及测试样本中的数据包括风速、风向的正、余弦值和风电输出功率,并对所有数据进行归一化处理。本文采用 BP、GWO-SVM、OFA-SVM、IOFA-SVM 4 种不同的预测模型对风电输出功率进行预测,4 种模型的预测结果如图 2 所示。




图 2 不同预测模型预测结果

图 2 显示了 4 种不同预测模型的预测结果和真实值之间的对比,整体上预测模型的预测结果与真实值的走势大致相同,其中 IOFA-SVM 的预测结果在除极个别预测值与真实值的误差较大,曲线整体与真实值拟合效果较好,同真实值最为接近,表明本文所提的 IOFA-SVM 预测模型有较好的预测能力。由图 2 可知,BP 和 OFA-SVM 的预测能力较为接近,但与 IOFA-SVM 相比,预测误差较大的点的个数明显增多,GWO-SVM 预测模型的输出结果与真实值距离相差在几种模型中最大,表明该模型预测效果较差。

为了更加直观地展示不同预测模型的预测能力,分别计算了不同预测模型的各个预测结果的相对误差和平均相对误差(mean related error, MRE),计算结果如表 1 和图 3 所示。

表 1 不同预测模型平均相对误差 %

模型	BP	GWO-SVM	OFA-SVM	IOFA-SVM
MRE	5.52	4.68	4.36	3.83

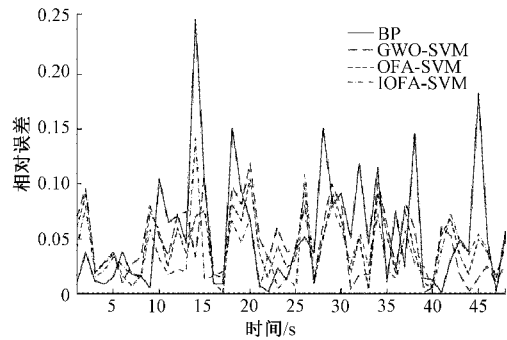


图 3 不同模型相对误差曲线

表 1 和图 3 表明,BP 预测模型的平均相对误差大而且其相对误差曲线最高而且波动最大,表明其预测精度相较于 SVM 预测模型预测精度和稳定性较差。表中 GWO-SVM 和 OFA-SVM 平均相对误差值较为接近,但与 IOFA-SVM 预测模型相比,除极个别预测点之外,IOFA-SVM 模型的相对误差曲线均位于其他 3 种模型之下,且 IOFA-SVM 模型的平均相对误差最小,与 BP 相比平均相对误差下降 1.69%,表明本文所提的改进模型具有更准确的预测能力。

为衡量不同预测模型预测能力,采用 MAE、NMAE 和 NRMSE 3 个误差指标对预测结果进行评价,结果如表 2 所示,各模型预测结果对比柱状图如图 4 所示。

表 2 不同预测模型的评价指标 %

模型	BP	GWO-SVM	OFA-SVM	IOFA-SVM
MAE	3.61	3.45	3.05	2.56
NMAE	5.52	4.68	4.36	3.83
NRMSE	5.15	4.28	3.81	3.31




图 4 不同模型预测结果对比柱状图

从表 2 可以看出,用不同算法优化 SVM 的预测模型 3 种评价指标均要优于 BP,结合图 3,BP 的输出预测相对误差曲线大多数点位于其他 3 种预测模型之上,结合 BP 自身特点,可见 BP 在风电输出功率预测方面能力较差。IOFA-SVM 模型的 MAE 值为 2.56%,相较于其他 3 种模型分别下降了 1.05%、0.89%、0.49%,表明 IOFA-SVM

各个预测点与真实值之间的离散程度较小,即误差值较大的点较少,IOFA-SVM 模型的 NMAE 值为 3.83%,相较于其他 3 种模型分别下降 1.69%、0.85%、0.53%,IOFA-SVM 模型的 NRMSE 值为 3.31%,相较于其他 3 种模型分别下降 1.84%、0.97%、0.50%,表明预测值与真实值之间的偏差更小,预测值与真实值的拟合效果较好。通过上述的评价指标分析,表明本文所提的 IOFA-SVM 风电输出功率预测模型具有更加准确的预测效果。

为更加直观地表现所提模型的预测能力,本文对不同

模型中相对误差区间在 $[-2.5\%, 2.5\%]$ 、 $[-5\%, 5\%]$ 和 $[-7.5\%, 7.5\%]$ 的预测值个数百分比分别进行统计,统计结果如表 3 所示,其中不同预测模型的相对误差在 $[-2.5\%, 2.5\%]$ 区间内点的个数百分比为 39.58%、31.25%、35.42%和 43.75%,只有所提模型的预测点个数多于 40%,从统计结果可以看出本文所提模型预测结果要优于其他预测模型。所提模型的 91.67% 预测点相对误差在 $[-7.5\%, 7.5\%]$ 区间内,说明大部分预测点分布于低误差区间,进而表明所提模型出色的预测能力。

表 3 不同预测模型的误差区间评估

模型	$[-2.5\%, 2.5\%]$		$[-5\%, 5\%]$		$[-7.5\%, 7.5\%]$	
	数量	比例/%	数量	比例/%	数量	比例/%
BP	19	39.58	29	60.42	35	72.92
GWO-SVM	15	31.25	26	54.17	36	75.00
OFA-SVM	17	35.42	27	56.25	39	81.25
IOFA-SVM	21	43.75	33	68.75	44	91.67

## 4 结 论

短期风电功率预测对风力发电机组协调规划和电力系统经济调度具有重大意义,为提高风电输出功率的预测精度,设计出基于改进最优觅食算法优化支持向量机的短期风电功率预测模型,首先在传统最优觅食算法的基础上加入柯西变异和差分进化策略,在最优觅食位置寻优过程中增大随机性,避免算法陷入局部最优觅食位置,增强算法寻找全局最优解的能力,然后用改进后的算法寻找 SVM 的最优参数  $c$  和  $g$  并建立输出功率预测模型,选取历史数据中的风速和风向作为输入,预测未来 48 h 的风电功率输出,与实际值的 MAE、NMAE、NRMSE 分别为 2.56%、3.83%、3.31%;与现有的 BP 神经网络以及灰狼优化算法、经典 OFA 与 SVM 相结合的预测模型相比,IOFA-SVM 模型在上述 3 项误差指标方面至少降低了 0.49%,说明 IOFA-SVM 模型具有更准确的预测能力。

## 参考文献

[1] 涂智福,丁坚勇,周凯. 基于 VMD 和 GP 的短期风电功率置信区间预测[J]. 电测与仪表, 2020, 57(1): 84-88.

[2] ZHAO H R, ZHAO H R, GUO S. Short-term wind electric power forecasting using a novel multi-stage intelligent algorithm[J]. Sustainability, 2018, DOI: 10.3390/su10030881.

[3] 刘武周,刘友波. 基于改进粒子群优化算法风力发电功率预测研究[J]. 可再生能源, 2017, 35(9): 1331-1335.

[4] 王慧莹,吴亮红,梅盼盼,等. 果蝇优化广义神经网络的风电功率短期预测[J]. 电子测量与仪器学报, 2019, 33(6): 177-183.

[5] HU K Y, CAO S H, WANG L D, et al. A new ultra-short-term photovoltaic power prediction model based on ground-based cloud images[J]. Journal of Cleaner Production, 2018, 200: 731-745.

[6] 程逸帆,乔飞,侯珂,等. 区域微电网群两级能量调度策略优化研究[J]. 仪器仪表学报, 2019, 40(5): 68-77.

[7] 王克杰,张瑞. 基于改进 BP 神经网络的短期电力负荷预测方法研究[J]. 电测与仪表, 2019, 56(24): 115-121.

[8] 彭周宁,林培杰,赖云锋,等. 基于混合灰色关联分析-广义回归神经网络的光伏电站短期功率预测[J]. 电气技术, 2019, 20(10): 11-18.

[9] ABDOOS A A. A new intelligent method based on combination of VMD and ELM for short term wind power forecasting [J]. Neurocomputing, 2016, 203: 111-120.

[10] 张靠社,罗钊. 基于 RBF-BP 组合神经网络的短期风电功率预测研究[J]. 可再生能源, 2014, 32(9): 1346-1351.

[11] 张爱枫,段新宇,何泉峰. 基于 CNN 和 LightGBM 的新型风电功率预测模型[J/OL]. 电测与仪表, 2021: 1-7 [2021-06-21].

[12] HUANG S Y. Fast wind power prediction method based on time convolution network[J]. International Core Journal of Engineering, 2021, 7(6), DOI: 10.6919/icje.202106\_7(6).0031.

[13] 朱思萌,杨明,韩学山,等. 多风电场短期输出功率的联合概率密度预测方法[J]. 电力系统自动化, 2014, 38(19): 8-15.

[14] 王永翔,陈国初. 基于改进鱼群优化支持向量机的短期

- 风电功率预测[J]. 电测与仪表, 2016, 53(3): 80-84.
- [15] LI ZH L, XIA J, LIU AN, et al. States prediction for solar power and wind speed using BBA-SVM [J]. Renewable Power Generation, 2019, 13: 1115-1122.
- [16] LIU Y W, FENG H, LI H Y, et al. An improved whale algorithm for support vector machine prediction of photovoltaic power generation [J]. Symmetry-Basel, 2021, 13(2), DOI: 10.3390/sym13020212.
- [17] 龚雪娇, 唐波, 朱瑞金. 基于 IBBDE-SVM 的短期风电功率预测[J]. 水力发电, 2021, 47(6): 109-111.
- [18] 张仕霞, 蒲文莉, 蒋新, 等. 基于聚类边界提取的支持向量机算法[J]. 电子测量技术, 2020, 43(6): 110-115.
- [19] DING M, ZHOU H, XIE H, et al. A time series model based on hybrid-kernel least-squares support vector machine for short-term wind power forecasting [J]. ISA Transactions, 2020, DOI: 10.1016/j.isatra.2020.09.002.
- [20] ZHU G Y, ZHANG W B. Optimal foraging algorithm for global optimization[J]. Applied Soft Computing, 2017, 51: 294-313.

### 作者简介

谢波, 硕士, 主要研究方向为新能源发电。

E-mail: xb565741076@qq.com

高建宇(通信作者), 硕士, 讲师, 主要研究方向为智能仪器与检测系统。

E-mail: aicicn@163.com

张惠娟, 博士, 教授, 主要研究方向为电力系统自动化。

E-mail: zhanghuijuan@hcbut.edu.cn

刘金委, 本科, 助教, 主要研究方向为电气自动化。

E-mail: 615727846@qq.com