

文章编号: 2095-2163(2022)01-0119-05

中图分类号: TP301.6

文献标志码: A

# 基于麻雀搜索优化支持向量机的短期风机发电功率预测

王维高, 魏云冰, 滕旭东, 黄 圆

(上海工程技术大学 电子电气工程学院, 上海 201620)

**摘要:** 风电大规模并入电网, 风电所占比例越来越大。然而, 由于风的不确定性和随机性, 风机发电并不稳定, 给风电并网带来巨大困难, 因此需要引入准确的风电预测。为了提高风电预测精度, 本文提出麻雀搜索算法优化支持向量机预测模型, 该模型在支持向量机学习参数(惩罚系数  $C$  和核参数  $g$ ) 选择困难的问题上, 基于麻雀搜索算法优化选择学习参数, 建立 SSA-SVM 短期风电预测模型。经实验仿真并对比 SSA-SVM、GA-SVM 和 SVM 模型预测结果, 发现经过优化后 SSA-SVM 模型的平均绝对误差较 GA-SVM、SVM 模型减少 3.796 MW 和 4.153 MW, 相对改善百分比为 68.25% 和 70.16%; 均方根误差减少 4.886 MW 和 4.945 MW, 相对改善百分比为 67.59% 和 67.87%, 说明 SSA-SVM 模型能有效提高学习参数选择效率和预测精确度。

**关键词:** 风电预测; 麻雀搜索算法; 支持向量机; 平均绝对误差; 均方根误差

## Short-term wind turbine generation power prediction based on sparrow search optimization support vector machine

WANG Weigao, WEI Yunbing, TENG Xudong, HUANG Yuan

(School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

**【Abstract】** With the large-scale integration of wind power into the grid, the proportion of wind power is increasing. However, due to the uncertainty and randomness of wind, wind turbine power generation is not stable, which brings great difficulties to wind power grid connection, and accurate wind power prediction needs to be introduced for this problem. In order to improve the accuracy of wind power prediction, this paper proposes a sparrow search algorithm to optimize the support vector machine prediction model. The model is based on the problem of difficult selection of learning parameters (penalty coefficient  $C$  and kernel parameter  $g$ ) of support vector machines, and the SSA-SVM short-term wind power prediction model is established based on the optimized selection of learning parameters by the sparrow search algorithm. The experimental simulation compares the prediction results of SSA-SVM, GA-SVM and SVM models. After optimization, the mean absolute error of SSA-SVM model is reduced by 3.796 MW and 4.153 MW compared with GA-SVM, SVM model, and the relative improvement percentage is 68.25% and 70.16%. The root mean square error is reduced by 4.886 MW and 4.945 MW, and the relative improvement percentages are 67.59% and 67.87%. The experimental results show that the SSA-SVM model is more effective in improving the learning parameter selection efficiency and prediction accuracy.

**【Key words】** wind power forecast; sparrow search algorithm; support vector regression; mean absolute error; root mean square

## 0 引言

风力发电已成为全世界应用最为广泛和最为成熟的技术<sup>[1]</sup>。风电装机规模也愈发庞大, 据国家统计局数据显示, 2020 年 12 月中国风力发电量达到  $409 \times 10^8 \text{ kW} \cdot \text{h}$ , 同比增长 7.1%; 2020 年 1~12 月中国风力发电量累计产量  $4.146 \times 10^8 \text{ kW} \cdot \text{h}$ , 累计增长 10.5%; 2015~2020 年中国发电量逐年递增, 2020 年达到最高。然而, 由于风的随机性和间歇性问题, 风力发电并不稳定, 给风电并网带来极大的困难, 风

电功率预测问题日益突出<sup>[2]</sup>。

短期风电预测模型主要包括物理模型、时间序列模型和人工智能模型 3 种。其中, 物理模型需要风速、风向、温湿度等气象信息数据, 并以此为依据建立复杂的数学模型, 该模型在针对短期风电预测时误差较大; 时间序列模型需要和历史风电功率数据结合进行建模, 在低阶模型中预测精度低, 在高阶模型中参数不易确定<sup>[3]</sup>; 人工智能模型是目前最为常用的模型, 通过对大量样本学习和训练, 建立风电功率与特征量之间的关系, 其中支持向量机是目前

**基金项目:** 国家自然科学基金(51507157)。

**作者简介:** 王维高(1995-), 男, 硕士研究生, 主要研究方向: 电力系统分析; 魏云冰(1970-), 男, 博士, 教授, 硕士生导师, 主要研究方向: 电力系统自动化、智能运检; 滕旭东(1971-), 男, 博士, 副教授, 主要研究方向: 大功率高频声学仪器设计。

**通信作者:** 魏云冰 Email: wei.yunbing@sues.edu.cn

**收稿日期:** 2021-07-30

较为常用的模型,因为支持向量机基于结构风险最小化设计,能够很好的解决过拟合问题,在线性回归方面表现良好,能够防止过度学习,泛化能力好<sup>[4]</sup>。因此,本文采用支持向量机搭建组合模型。支持向量机在选择学习参数上一般采用交叉验证法,此方法可能会在选择学习参数过程中陷入局部最优,因此一些优化算法也被应用到 SVM (Support Vector Machines) 预测模型当中<sup>[5]</sup>,如:文献[6]~[8]采用遗传算法、灰狼算法和粒子群算法对 SVM 中的学习参数进行优化选择,以提高精度。但遗传算法、灰狼算法和粒子群算法都面临过早收敛的问题。文献[9]采用 BP 神经网络算法预测风电功率;文献[10]采用人工蚁群算法优化神经网络,构建 ABC-BP (Artificial Bee Colony-BP) 神经网络风电功率预测模型,但 BP 神经网络算法和蚁群算法收敛速度慢,且有局部极小化问题。

针对上述问题,本文引入麻雀算法优化支持向量机学习参数的选择,提出 SSA-SVM (Sparrow Search Algorithm-Support Vector Machines) 预测模型。通过与 GA-SVM (Genetic Algorithm-Support Vector Machines) 和 SVR (Support Vector Machines) 模型的预测结果对比,验证本文提出的模型在预测精确度上的提升。

## 1 麻雀搜索优化算法

麻雀搜索算法是受麻雀觅食行为和逃避捕食行为启发而提出的,具有寻优能力强,收敛速度快等优点<sup>[11]</sup>。

每一只麻雀代表一个位置属性,即其找到食物的位置。在全局中每一只麻雀扮演3个不同角色,发现者,在一定范围内搜索食物;加入者,跟随发现者发现最好的食物;警戒者,警惕周围危险,察觉危险时发出警告。

在  $D$  维解空间内每只麻雀位置  $X = (x_1, x_2, \dots, x_d)$ , 适应度值  $f_i = f(x_1, x_2, \dots, x_d)$ , 选用均方误差 MSE (Mean Square Error) 作为适应度函数,公式(1):

$$MSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2} \quad (1)$$

其中,  $y_i$  表示实际风电发电功率,  $\hat{y}_i$  表示预测风电发电功率。

在整个麻雀群体中发现者和加入者数量是不变的,每当增加一个加入者就会减少一个发现者。算

法原理:

(1)更新发现者位置,每代发现者位置更新公式(2):

$$x_{i,d}^{t+1} = \begin{cases} x_{i,d}^t \times \exp\left(-\frac{i}{\alpha \times \text{iter}_{\max}}\right), R_2 < ST \\ x_{i,d}^t + Q, R_2 > ST \end{cases} \quad (2)$$

其中,  $x_{i,d}^{t+1}$  表示第  $i$  只麻雀在  $d$  维当中的位置;  $\alpha$  表示在  $[0,1]$  之间的随机数;  $R_2$  表示在  $[0,1]$  之间的预警值;  $ST$  表示在  $[0.5,1]$  之间的安全值;  $Q$  表示正态分布的随机数;  $L$  是一个矩阵,结构为  $1 \times d$ ,并且其中元素都是1。当  $R_2 < ST$  时,表明当前环境安全,发现者可以在此觅食;当  $R_2 > ST$  时,表明当前环境有危险,种群中一些麻雀就向其他同伴发出警报,示意其到安全地方觅食。

(2)更新加入者位置,加入者位置更新公式(3):

$$x_{i,d}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{x_{\text{worst}} - x_{i,d}^t}{l^2}\right), i > n/2 \\ x_p^{t+1} + |x_{i,d} - x_p^{t+1}| \cdot A^+ \cdot L, i \leq n/2 \end{cases} \quad (3)$$

其中,  $x_p, x_{\text{worst}}$  分别表示当前最优位置和最差位置。  $A$  是  $1 \times d$  且每一个元素都被赋值为1或者-1的矩阵,而且  $A^+ = A^T(AA^T)^{-1}$ 。当  $i > (0.5 \cdot n)$  时,表明适应度值较低,第  $i$  个加入者需要飞往别处觅食。

(3)警戒者:在种群中有一部分麻雀在各自觅食过程中会时刻警惕附近危险,一旦发觉附近有危险就放弃食物或者觅食,然后飞往安全区域继续觅食。

每代种群当中都会有  $SD$  个麻雀负责警示。其位置更新公式(4)如下:

$$x_{i,d}^{t+1} = \begin{cases} x_{\text{best}}^t + \beta \cdot |x_{i,d}^t - x_{\text{best}}^t|, f_i > f_g \\ x_{i,d}^t + K \cdot \left(\frac{|x_{i,d}^t - x_{\text{worst}}^t|}{f_i - f_w + \varepsilon}\right), f_i = f_g \end{cases} \quad (4)$$

其中,  $\beta$  是一个符合标准正态分布的随机数;  $x_{\text{best}}$  表示目前全局最优位置;  $f_i$  表示当前麻雀适应度值并且  $f_g, f_w$  分别表示当前最好和最差适应度值;  $k$  表示  $[-1,1]$  的均匀随机数;  $\varepsilon$  表示一个较小数,防止分母为0。从公式(4)中可以看出,当  $f_i = f_g$  时,表明有麻雀发现危险,就会转移觅食地点,以避免被捕食;当  $f_i > f_g$  时,表明麻雀在整个种群边缘地区捕食,容易受到其他捕食者攻击。

麻雀算法的流程图如图1所示:



图 1 麻雀算法流程图

Fig. 1 Sparrow Search Algorithm flow chart

## 2 支持向量机(SVM)原理

支持向量机是一种常用于分类和回归预测的模型,其特点在于能够克服局部最小值,很好的解决过拟合问题,在线性回归方面表现良好,同时能防止过度学习并且泛化能力好<sup>[12]</sup>。

算法步骤:

(1) 选择一个惩罚系数  $C > 0$ , 构造约束优化问题, 式(5);

$$\min_{\alpha^V, \alpha^A} \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\hat{\alpha}_i - \check{\alpha}_j)(\hat{\alpha}_j - \check{\alpha}_i) k(x_i, x_j) + \sum_{i=1}^N [(\varepsilon - y_i) \hat{\alpha}_i + (\varepsilon - y_i) \check{\alpha}_i] \quad (5)$$

$$\sum_{i=1}^N (\hat{\alpha}_i - \check{\alpha}_i) = 0$$

$$s.t. \quad 0 \leq \hat{\alpha}_i \leq C, \quad i = 1, 2, \dots, N$$

$$0 \leq \check{\alpha}_i \leq C, \quad i = 1, 2, \dots, N$$

(2) 用 SMO 算法求出最优  $\check{\alpha}$  和  $\hat{\alpha}$ ;

(3) 计算  $W \sum_{i=1}^N = (\check{\alpha}_i^* - \hat{\alpha}_i^*)$ ;

(4) 寻找一个满足  $0 < \check{\alpha}_i^* < C$  的样本点  $(x_k, y_k)$ , 计算  $b^* = y_k + \varepsilon - w^{*T}$ ;

(5) 构建最终回归超平面  $w^{*T}x + b^* = 0$  和预测函数  $f(x) = \text{sgn}(w^{*T}x) + b^*$ 。

为能够将数据映射到高维空间当中,需要用到核函数,本文运用到的核函数是 RBF 高斯核函数,公式(6),这样就能将非线性回归问题转化为线性回归问题。

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) =$$

$$\exp(-g \|x_i - x_j\|^2), \quad g > 0 \quad (6)$$

在支持向量机中惩罚系数  $C$  和核函数参数  $g$  对整个回归预测精确度产生很重要的影响,所以选择选择合适的参数  $C, g$  就显得尤为重要。本文基于麻雀搜索算法优化参数  $C$  和  $g$ , 以此优化预测结果。

## 3 SSA-SVM 预测模型的构建

SVM 基于结构风险最小化设计,能够很好的解决过拟合问题,在线性回归方面表现良好,能够防止过度学习并且泛化能力好。SVM 预测结果受学习参数影响较大,本文基于麻雀搜索算法优化支持向量机的学习参数。

本文采用内蒙古某风电场所测的风速、风向、温度出力作为输入变量,为减少数据的奇异性影响,用公式(7)对数据归一化处理,处理后的数据用于 SVM 模型的新数据。

$$p = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (7)$$

其中:  $p$  表示归一化后的数据;  $x_i$  原始风速数据;  $x_{\min}$  和  $x_{\max}$  分别是原始数据中的最小值和最大值。

SSA 参数设置: 种群规模  $N_p = 20$ , 迭代次数  $T = 100$ , 参数  $C, g$  范围  $C \in [0.001, 100], g \in [0, 001, 1000]$ 。交叉验证折数  $V = 5$ ; 安全值  $ST = 0.6$ ; 发现者比例  $PD = 0.7$ ; 意识到有危险麻雀的比重  $SD = 0.2$ 。

麻雀搜索算法会初始一个种群,种群中发现者、加入者和警戒者个体数依照设置参数比例进行分配,根据公式(1)计算麻雀适应度值,并将其作为麻雀搜索到食物的多少;根据公式(2)~(4)更新麻雀的个体位置;根据最佳个体位置确定学习参数,循环 100 代结束循环;输出最优参数。

SSA-SVM 模型构建具体流程如图 2 所示。

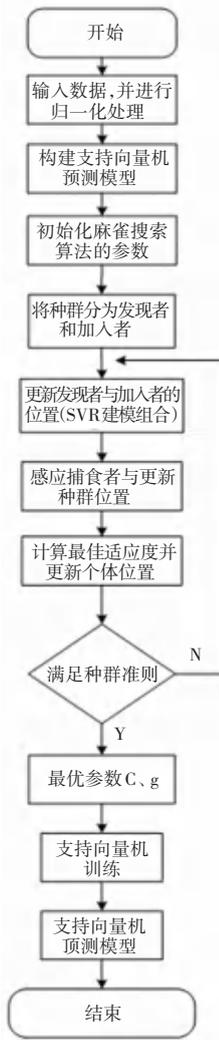


图2 SSA-SVM 模型流程图

Fig. 2 Flow chart of SSA-SVM model

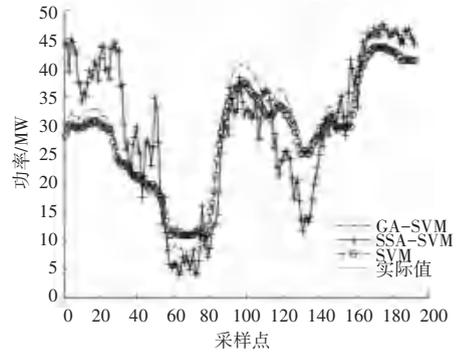


图3 不同算法的预测值对比

Fig. 3 Comparison of predicted values of different algorithms

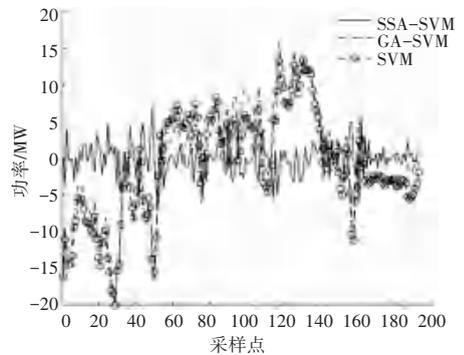


图4 不同优化算法误差对比

Fig. 4 Comparison of errors of different optimization algorithms

表1 不同模型预测效果对比

Tab. 1 Comparison of prediction effects of different models

模型	RMSE /MW	MAE /MW
SSA-SVM	2.343	1.766
GA-SVM	7.229	5.562
SVM	7.288	5.919

### 4 仿真分析

以内蒙古某风电场 2019~2020 年风场出力数据为例。选取 2019/10/01~2020/01/31 数据作为训练集,每隔 15 min 一个采样点,共计 11 809 组数据;测试集选择 2019-11-30~2019-11-31 每15 min 一个采样点,共计 192 个采样点的数据。

为验证 SSA-SVM 模型精确度的提升,本文搭建 SVM、GA-SVM 两种模型进行对比。GA-SVM 参数设置:种群规模  $N_p = 20$ ,最大迭代次数  $T = 20$ ,参数  $C、g$  范围设置  $C \in [0,001,100], g \in [0.001, 1\ 000]$ ,交叉验证折数  $V = 5$ ;个体选择概率  $ggap = 0.9$ 。各模型预测结果如图 3 所示,预测误差如图 4 所示,预测指标见表 1。

为评价本文所建预测模型性能,引入平均绝对误差 MAE (Mean Absolute Error) 和均方根误差 RMSE (Root Mean Square Error) 作为评价指标。两种评价指标公式(8)和公式(9):

$$MAE = \frac{1}{N_p} \sum_{i=1}^n |y_i - \hat{y}_i| \tag{8}$$

$$RMSE = \sqrt{\frac{1}{N_p} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{9}$$

其中,  $y_i$  表示实际风电发电功率;  $\hat{y}_i$  表示预测风电发电功率;  $N_p$  表示预测样本数量。

由表 1 并结合图 3,图 4 可以看出:SSA-SVM 模型相较 GA-SVM 和 SVM 模型,在预测精度上有大幅度提升;较之 GA-SVM 模型和 SVM 模型, MAE

指标分别减少 3.796 MW 和 4.153 MW, 相对改善百分比分别为 68.25% 和 70.16%。对比 GA-SVM 模型和 SVM 模型 RMSE 指标, SSA-SVM 模型分别减少 4.886 MW 和 4.945 MW, 相对改善百分比分别为 67.59% 和 67.85%。

综上所述, 本文所提出的 SSA-SVM 算法在预测精度上改善最佳, GA-SVM 算法次之, SVM 算法最差。验证 SSA 算法能有效解决 SVM 学习参数选择困难问题, 并提高风电预测精确度。

## 5 结束语

针对提升短期风电功率预测精确度问题, 本文提出基于麻雀搜索算法优化支持向量机学习参数, 建立 SSA-SVM 模型, 该模型能有效提高支持向量机选择学习参数的效率和预测准确度。在内蒙古某风电场风电预测仿真中, 分别与 GA-SVM 和 SVM 模型预测结果做对比。

仿真结果表明: 在 MAE 和 RMSE 指标中, SSA-SVM 预测模型都明显优于 GA-SVM 和 SVM 模型, 表明 SSA-SVM 模型适用于短期风电预测。

风电功率序列的随机波动特性导致原始序列中的数据难以被完全挖掘, 故需要借助数据分解技术解决此问题, 这也是未来重点研究和探索的方向。

(上接第 118 页)

制的角度输出。从图中可以看出, 系统的位置输出能够时刻保持对给定信号的跟随, 相对于给定信号滞后程度微小。系统跟随性能和快速性能较为良好, 可以满足实际应用的需求。

## 5 结束语

本文基于 simulink 搭建了永磁同步电机三闭环矢量控制模型, 并通过系统输入阶跃信号和正弦信号来模拟驾驶过程中驾驶员对电机转向的需求, 具有很好的跟随效果。通过对比传统 PI 控制, 得出在速度环增添模糊控制器可以获得更高的响应速度和稳定性, 为后续对线控转向系统的研究提供了理论依据和基础。

## 参考文献

[1] 张扬. PMSM 伺服系统控制器参数自整定及优化[D]. 哈尔滨: 哈尔滨工业大学, 2009.  
[2] 郭岩. 线控转向系统转向电机控制算法与软件建模研究[D]. 吉林: 吉林大学, 2018.

## 参考文献

[1] 吴小珊, 张步涵, 袁小明, 等. 求解含风电场的电力系统机组组合问题的改进量子离散粒子群优化方法[J]. 中国电机工程学报, 2013, 33(4): 45-52, 7.  
[2] 杨子民, 彭小圣, 郎建勋, 等. 基于集群动态划分与 BLSTM 深度学习的风电集群短期功率预测[J]. 高电压技术, 2021, 47(4): 1195-1203.  
[3] 岳晓宇, 彭志刚, 林俐. 鲸鱼优化支持向量机的短期风电功率预测[J]. 电力系统及其自动化学报, 2020, 32(2): 146-150.  
[4] 耿鸿冲, 张越师. 基于 GA-SVM 的风机发电功率预测[J]. 电子测试, 2019, 4(12): 38-40.  
[5] 徐炜君. 基于灰狼优化 SVR 的风电场功率超短期预测[J]. 杭州师范大学学报(自然科学版), 2021, 20(2): 177-182.  
[6] 陈道君, 龚庆武, 金朝意, 等. 基于自适应扰动量子粒子群算法参数优化的支持向量回归机短期风电功率预测[J]. 电网技术, 2013, 37(4): 974-980.  
[7] 何廷一, 田鑫萃, 李胜男, 等. 基于蜂群算法改进的 BP 神经网络风电功率预测[J]. 电力科学与技术学报, 2018, 33(4): 22-28.  
[8] 薛建凯. 一种新型的群智能优化技术的研究与应用[D]. 上海: 东华大学, 2020.  
[9] 杨锡运, 孙宝君, 张新房, 等. 基于相似数据的支持向量机短期风速预测仿真研究[J]. 中国电机工程学报, 2012, 32(4): 35-41, 21.  
[10] 张晓鹏, 张兴忠. 基于高斯核函数的支持向量机光伏故障诊断研究[J]. 可再生能源, 2021, 39(6): 760-765.  
[11] 孙斌, 姚海涛, 刘婷. 基于高斯过程回归的短期风速预测[J]. 中国电机工程学报, 2012, 32(29): 104-109, 5.  
[12] 曹俊波, 周任军, 邓学华, 等. 考虑优化 ARIMA 模型差分次数的风功率预测[J]. 电力系统及其自动化学报, 2019, 31(1): 105-111.  
[3] 杨国梁, 李建雄. 永磁同步电机控制技术[M]. 北京: 知识产权出版社, 2015: 6.  
[4] 解小刚, 陈进. 采用  $i_d = 0$  的永磁同步电机矢量控制系统 MATLAB/Simulink 仿真[J]. 新型工业化, 2016, 6(5): 47-54.  
[5] 王晓明. 电动机的 DSP 控制(第 2 版)[M]. 北京: 北京航空航天大学出版社, 2009: 37.  
[6] 张军凯, 韩峻峰. SVPWM 原理及逆变技术的仿真研究[J]. 计算技术与自动化, 2016, 35(1): 41-46.  
[7] B AKIN, M SARUL. Soft switched SVPWM controlled PRDCL inverter[J]. International Journal of Hydrogen Energy, 2017, 42(28): 132-135.  
[8] 钟立群, 王辉, 谭维胜. 基于五电平逆变器的异步电机矢量控制研究[J]. 控制工程, 2015, 22(5): 933-938.  
[9] 刘可述. PMSM 伺服系统速度环和位置环控制器参数自整定技术[D]. 哈尔滨: 哈尔滨工业大学, 2012.  
[10] 林远. 基于模糊和滑模变结构控制的异步电机调速系统研究[D]. 广西: 广西大学, 2017.  
[11] 时维国, 金鑫. 基于模糊 PI 双环 PMSM 转矩脉动抑制研究[J]. 微电机, 2018, 51(1): 69-73.  
[12] 孙玉坤, 袁野, 黄永红, 等. 磁悬浮开关磁阻电机及其关键技术发展综述[J]. 电工技术学报, 2015, 30(22): 1-8.