

doi: 10.12052/gdutxb.190099

基于鲸鱼优化参数的最小二乘支持向量机 短期负荷预测方法

陈友鹏, 陈璟华

(广东工业大学 自动化学院, 广东 广州 510006)

摘要: 大量分布式能源站的出现以及电动汽车的普及, 给电力系统的安全、经济运行带来影响的同时, 传统的负荷预测方法也面临挑战。针对这个问题, 提出了利用鲸鱼算法优化最小二乘支持向量机(Whale Optimization Algorithm-Least Squares Support Vector Machine, WOA-LSSVM)进行短期电力系统负荷预测。利用鲸鱼算法全局寻优能力强、收敛速度快的优点, 弥补最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)选参的盲目性, 提高 LSSVM 的负荷预测精度。采用 WOA-LSSVM 对 2013 年浙江某地区历史负荷数据预测未来 1 d 的负荷, 并与粒子群优化最小二乘支持向量机模型和标准 LSSVM 模型预测结果对比。结果表明, 基于鲸鱼优化 LSSVM 的短期负荷预测具有较高的预测精度, 相对误差较小。

关键词: 短期电力负荷预测; 最小二乘支持向量机; 鲸鱼优化算法

中图分类号: TM734

文献标志码: A

文章编号: 1007-7162(2020)03-0075-07

A Short-term Load Forecasting Method Based on Support Vector Machine with Whale Optimization Parameters

Chen You-peng, Chen Jing-hua

(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: With the emergence of a large number of distributed energy stations and the popularity of electric vehicles, the security and economic operation of the power system are affected. At the same time, the traditional load forecasting methods are also facing challenges. To solve this problem, a Whale Optimization Algorithm-Least Squares Support Vector Machine (WOA-LSSVM) is proposed for short-term power system load forecasting. Using the advantages of whale algorithm such as strong global optimization ability and fast convergence speed, the blindness of parameter selection of LS-SVM is overcome, and the load forecasting accuracy of LS-SVM is improved. WOA-LSSVM is used to forecast the load of a certain area in Zhejiang province in the next day based on the historical load data in 2013. The results are compared with those of the particle swarm optimization least squares support vector machine model and the standard LSSVM model. The results show that the short-term load forecasting based on the whale optimization LSSVM has a higher forecasting accuracy and a smaller relative error.

Key words: short-term load forecasting; least squares support vector machine; whale optimization algorithm

随着工业4.0的提出, 以信息化、数字化、自动化和互动化为主要特征的智能电网成为全球电网的发展趋势^[1-2]。智能配电网建设作为一项国家战略关乎国家的经济发展, 但在未来几年, 随着大量分布式能源站的接入、新能源汽车的推广和配套充电设施的建设, 智能配电网将会变得更加复杂。而且这些变化也会改变以往负荷的结构, 对电力系统的运行维护、

电源架构和周期规划产生较大的影响。在进行配电网建设时, 首先要掌握相关地区的负荷预测、电源规划和网络规划, 其中负荷预测是电网规划的首要任务。高精度的负荷预测对电力系统的建设和运维有着举足轻重的作用, 同时也影响着电力市场的社会效益和经济效益^[3]。但是目前传统负荷预测方法的精度并不高, 如何改进负荷预测方法、提高负荷预测精度,

收稿日期: 2019-07-26

基金项目: 中央财政支持地方高校发展专项资金项目(粤财教[2016]202号)

作者简介: 陈友鹏(1995-), 男, 硕士研究生, 主要研究方向为电力系统安全运行与控制

对于制定合理的发电计划、分析电力市场需求等具有十分重要的意义。

近年来,智能算法发展迅速,粒子群优化算法^[4](Particle Swarm Optimization Algorithm, PSO)、遗传算法和支持向量机(Support Vector Machine, SVM)等自学能力强的预测方法在电力负荷预测上广泛应用^[5]。文献[6]提出使用SVM对电力负荷进行短期预测,在解决非线性、小样本问题方面具有较好的精度和泛化能力,提高了预测精度,但存在计算速度慢等问题。文献[7]利用改进差分算法和最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)进行负荷预测,该算法保持了SVM的优点,同时降低了计算的复杂度,提高了运算速度,但存在LSSVM选参盲目性问题。文献[8]利用PSO对LSSVM进行参数寻优,克服以往LSSVM选参的盲目性。但是在实际应用中发现PSO在寻优过程中易出现早熟现象,导致所选参数不是最优。LSSVM采用结构最小化原则,把复杂的优化问题转为易于求解的线性规划问题,具有较好的鲁棒性,能有效避免维数灾难,求解速度快。但LSSVM的求解精度受参数选取的影响,传统做法是根据经验来选取参数,求解准确率一般,所以参数的优化选取是提高模型效果的关键。为了解决上述文献中存在的问题,本文利用鲸鱼优化算法(Whale Optimization Algorithm, WOA)精度高、收敛过程迅速和脱离局部最优能力强等特点^[9-10],提出基于鲸鱼优化最小二乘支持向量机的负荷预测模型(Whale Optimization Algorithm-Least Squares Support Vector Machine, WOA-LSSVM),用于解决LSSVM盲目选参的问题,从而提高负荷预测的精度。

1 最小二乘支持向量机的原理

LSSVM预测模型基于结构风险最小化原则^[11-12],通过采用核函数映射到高维的特征空间中,再分析求解凸二次规划问题,得到支持向量和稀疏解,从而在非线性和回归问题上得到应用。LSSVM是将SVM的不等式约束转为等式约束^[11],最终可求解线性KKT。

给定样本集合 $S = \{(\mathbf{x}_i, \mathbf{y}_i) | i = 1, 2, \dots, N\}$,其中 $\mathbf{x}_i$ 为输入量, $\mathbf{y}_i$ 为输出量, N 为样本总数。 $\varphi(\cdot)$ 是将低维的样本映射到高维特征空间的非线性映射,LSSVM回归模型可表示为

$$f(\mathbf{x}) = \omega^T \varphi(\mathbf{x}) + b \quad (1)$$

式(1)中, ω 为特征空间中的权系数向量, b 为常数。

LSSVM的原问题是使训练集与超平面之间的最小距离最大,可以转换为如下的二次规划问题:

$$\min \frac{1}{2} \|\omega\|^2 + \frac{1}{2} c \sum_{i=1}^N \varepsilon_i^2 \quad (2)$$

$$\text{s.t. } \mathbf{y}_i [\omega^T \varphi(\mathbf{x}_i) + b] = 1 - \varepsilon_i, i = 1, 2, \dots, N \quad (3)$$

式(2)中, c 为惩罚系数, ε_i 为误差向量。

然后利用拉格朗日函数求解:

$$L(\omega, b, \varepsilon, \lambda) = \frac{1}{2} \omega^T \omega + \frac{1}{2} c \sum_{i=1}^N \varepsilon_i^2 + \sum_{i=1}^N \lambda_i \mathbf{y}_i [\omega^T \varphi(\mathbf{x}_i) + b] - 1 + \varepsilon_i \quad (4)$$

式(4)中, λ_i 为拉格朗日乘子。根据KKT条件求解:

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 \rightarrow \sum_{i=1}^N \lambda_i \mathbf{y}_i \varphi(\mathbf{x}_i) = 0 \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^N \lambda_i \mathbf{y}_i = 0 \\ \frac{\partial L}{\partial \varepsilon_i} = 0 \rightarrow \lambda_i = c \varepsilon_i \\ \frac{\partial L}{\partial \lambda_i} = 0 \rightarrow \mathbf{y}_i [\omega^T \varphi(\mathbf{x}_i) + b] - 1 + \varepsilon_i = 0 \end{cases} \quad (5)$$

通过消去 ω 和 ε_i 可将最优问题转化为一个线性系统矩阵方程:

$$\begin{bmatrix} 0 & 1 & \cdots & 1 \\ 1 & k(\mathbf{x}_1, \mathbf{x}_1) + \frac{1}{r} & \cdots & k(\mathbf{x}_N, \mathbf{x}_1) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & k(\mathbf{x}_N, \mathbf{x}_1) & \cdots & k(\mathbf{x}_N, \mathbf{x}_N) + \frac{1}{r} \end{bmatrix} \begin{bmatrix} b \\ \lambda_1 \\ \vdots \\ \lambda_N \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y}_1 \\ \vdots \\ \mathbf{y}_N \end{bmatrix} \quad (6)$$

因此,求解可得LSSVM模型为

$$\mathbf{y}_i = \sum_{i=1}^N \lambda_i k(\mathbf{x}, \mathbf{x}_i) + b \quad (7)$$

式(7)中, $k(\mathbf{x}, \mathbf{x}_i)$ 为核函数。

核函数常有以下几种形式:(1) 多项式核函数, $k(\mathbf{x}, \mathbf{x}_i) = (\mathbf{x}_i^T \mathbf{x} + 1)^d$;(2) 线性核函数, $k(\mathbf{x}, \mathbf{x}_i) = \mathbf{x}_i^T \mathbf{x}$;(3) Sigmoid核函数, $k(\mathbf{x}, \mathbf{x}_i) = \tanh(C_1 \mathbf{x}_i^T \mathbf{x} + C_2)$;(4) 径向基核函数(Radial Basis Function, RBF), $k(\mathbf{x}, \mathbf{x}_i) = \exp(-\|\mathbf{x} - \mathbf{x}_i\|^2 / (2\sigma^2))$ 。由于径向基核函数具有较好的分类效果^[11],本文选其作为模型的核函数。

2 鲸鱼优化算法

Mirjalili和Lewis在2016年从座头鲸的猎食行为中得到启示,提出一种新的元启发式优化算法——鲸鱼优化算法。该算法仿照座头鲸的泡泡网觅食方法,通过收缩包围、螺旋位置更新以及随机捕食行为捕猎,如图1所示。通过模仿其觅食建立数学模型,具

体的寻优过程如下:首先通过判断系数向量 $\mathbf{A}$ 是否在区间 $[-1,1]$ 内,若不在就采用搜索捕食的方式跳出当前包围圈;若就在通过判断阈值 p 选择包围猎物还是狩猎行为。为了减少控制变量,该算法只有位置向量,去掉了速度向量,所以使得算法的寻优能力得到增强^[13]。




图1 座头鲸的泡网觅食行为

Fig.1 Bubble-net feeding behavior of humpback whales

2.1 包围猎物

座头鲸在捕猎时,通过离猎物最近的鲸鱼群位置更新自己的位置,迅速包围猎物,位置更新公式为

$$\begin{cases} \mathbf{X}(t+1) = \mathbf{X}^*(t) - \mathbf{AD} \\ D = |\mathbf{CX}^*(t) - \mathbf{X}(t)| \end{cases} \quad (8)$$

式(8)中, t 为当前迭代次数, $\mathbf{X}^*(t)$ 为当前最佳的鲸鱼位置向量, $\mathbf{X}(t)$ 为鲸鱼当前位置向量, $\mathbf{A}$ 和 $\mathbf{C}$ 为系数向量。

系数向量 $\mathbf{A}$ 和 $\mathbf{C}$ 的定义为

$$\begin{cases} \mathbf{A} = 2a \times r - a \\ \mathbf{C} = 2r \end{cases} \quad (9)$$

式(9)中, r 为 $(0,1)$ 区间内的随机数, a 为常数, $a = 2 - \frac{2t}{T_{\max}}$, $T_{\max}$ 为最大迭代次数。

2.2 狩猎行为

座头鲸通过螺旋式运动进行捕猎,可以建立一个螺旋位置更新的数学模型。首先计算鲸鱼群到猎物的距离,模仿座头鲸的螺旋游动行为,建立一个螺旋运动的数学模型。表达式为

$$\begin{cases} \mathbf{X}(t+1) = \mathbf{X}^*(t) + DPe^{bl} \cos(2\pi l) \\ D_P = |\mathbf{X}^*(t) - \mathbf{X}(t)| \end{cases} \quad (10)$$

式(10)中, D_P 为猎物与鲸鱼之间的距离, b 为对数螺旋系数, l 为 $(-1,1)$ 区间内的随机数。

座头鲸捕猎时,会在收缩圈内以螺旋的方式来来回游动,以选择以上2种捕猎方式的其中的1种。因此,设鲸群个体更新位置时以50%概率选择捕猎方式,此时可能会出现包围猎物的行为,其数学模型为

$$\mathbf{X}(t+1) = \begin{cases} \mathbf{X}^*(t) - \mathbf{AD}, & p < 0.5 \\ \mathbf{X}^*(t) + DPe^{bl} \cos(2\pi l), & p > 0.5 \end{cases} \quad (11)$$

式(11)中, p 为 $(0,1)$ 区间上的随机数。

2.3 搜索捕食

座头鲸在搜索猎物时,可以根据鲸群个体位置随机捕猎,该方式也是根据向量 $\mathbf{A}$ 的变化进行选择的,但此时 $\mathbf{A}$ 在 $(-1,1)$ 的范围之外随机取值,使得鲸鱼远离目标,搜索收缩圈外更优的目标,从而提高算法的全局寻优能力,脱离局部最优^[14]。搜索捕食的数学模型为

$$\begin{cases} \mathbf{X}(t+1) = \mathbf{X}_{\text{rand}} - \mathbf{AD} \\ D = |\mathbf{CX}_{\text{rand}} - \mathbf{X}(t)| \end{cases} \quad (12)$$

式(12)中, $\mathbf{X}_{\text{rand}}$ 为随机的鲸群位置向量。

3 鲸鱼优化LSSVM的预测模型

负荷预测的精度直接影响电力系统运行的经济性和安全性。为确保电力系统安全可靠运行,需要考虑影响负荷的因素,准确建立数学模型,提高模型的预测精度。

3.1 短期负荷的影响因素

关于影响短期电力负荷预测的因素,本文主要考虑以下几个方面。

(1) 天气因素。天气的变化会对负荷产生影响,改变用户的用电情况,天气因素对负荷预测精度起着关键作用,如温度、湿度和日照强度都会对用户的用电情况产生影响。例如夏季气温较高时,空调负荷将会增加;冬季气温较低时,供暖系统的负荷也会增加。

(2) 日期类型。由于负荷具有周期性,不同日期类型也会对负荷产生一定的影响,该因素对负荷预测产生重要影响。如相同时间段工作日的用电量与周末的用电量不一样。

(3) 典型负荷。典型负荷是由于不同地区负荷组成不一样造成的,主要体现在负荷的组成比例和负荷类型两方面。考虑典型负荷可使预测模型建立更精确,提高预测精度。

(4) 特殊事故。特殊事故的发生对负荷会产生很大的影响,如自然灾害、系统故障和政治事件等。考虑到特殊事故属于随机事件,具有不可预测性,本文忽略该因素。

因此电力系统的总负荷公式可以表示为

$$\mathbf{X}(t) = f(s, w, h, t) \quad (13)$$

式(13)中, $\mathbf{X}(t)$ 为总负荷, s 为天气因素, w 为日期类型, h 为典型负荷, t 为时间。

本文进行负荷预测时考虑天气因素、日期类型和典型负荷, 这3个因素都是影响模型预测精度的重要因素。

3.2 输入变量的确定

(1) 负荷数据。考虑不同日期同一时间段负荷的相似性以及相邻时间点负荷的影响, 从历史数据中选取预测时刻的前4个时刻、前一天相同时刻及前一天相同时刻的前后两个时刻的负荷值作为输入变量的一部分。

(2) 天气因素。主要考虑一天当中的最高温度 $T_i^{\max}$ 、最低温度 $T_i^{\min}$ 、平均温度 T_i^{mean} 和相对湿度 S_i , 经过归一化处理后的第 i 日天气因素为

$$s_i = [T_i^{\max}, T_i^{\text{mean}}, T_i^{\min}, S_i] \quad (14)$$

(3) 日期类型。由于负荷具有周期性, 可用星期类型值表示星期特点, 将星期类型值 W_i 作为输入变量, 其中周一将 W_i 设为0.7, 周二到周五设为0.8, 周六设为0.4, 周日设为0.3, 节假日设为0.1。

把这些因素作为输入变量进行建模, 为预测第 i 天第 t 时刻的负荷 $\mathbf{Y}_i(t)$, 输入变量为

$$\begin{aligned} \mathbf{X}_i(t) = [s_i, W_i, L_{(i-1, t-4)} : L_{(i-1, t-1)}, L_{(i-2, t-4)} : \\ L_{(i-2, t-1)}, W_{i-1}], i = 3, 4, \dots \end{aligned} \quad (15)$$

3.3 模型构建

给定优化参数的范围, 输出数据为预测点的负荷 $\mathbf{Y}(t)$, 随机给定训练数据 $(\mathbf{X}(t), \mathbf{Y}(t))$ 对最小二乘支持向量机进行训练, 根据上述的适应度函数优化参数, 不断进行迭代, 找出最优参数, 获得理想的训练模型^[15-17], 其流程如图2所示。基于WOA的LSSVM模型超参数寻优步骤为:

(1) 对数据 $(\mathbf{X}(t), \mathbf{Y}(t))$ 进行归一化预处理, 形成训练集和测试集样本;

(2) 初始化鲸群, 设定参数: 进化次数 M , 鲸群规模 N 及其位置范围;

(3) 计算各鲸群的初始适应度, 公式为

$$f = \frac{1}{N} \sum_i^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (16)$$

比较鲸群大小, 确定当前最优种群位置;

(4) 利用WOA算法对鲸群位置进行优化, 更新鲸群的位置;

(5) 计算优化后鲸群的适应度, 并更新当前最优种群位置;

(6) 当迭代次数达到 $T_{\max}$, 结束优化, 输出优化的参数, 否则迭代次数 $t=t+1$, 转到步骤(3);

(7) 将优化后的参数输入到LSSVM中, 得到预测模型并进行预测;

(8) 比较预测负荷与实际负荷, 计算预测日的平均相对误差。




图2 基于鲸鱼优化LSSVM的预测模型流程图

Fig.2 Flow chart of prediction model based on WOA-LSSVM

4 算例分析

现选取浙江台州某地区2013年3月1日到4月8日的936个数据作为训练样本, 用本文所提出的WOA-LSSVM模型来预测4月9日至11日的每天24 h的负荷。利用MATLAB2016编程对所提出的短期负荷预测方法进行验证。在算例中, 设置WOA进化次数为30, 种群规模 $N=25$, 对数螺旋形状常数取为1, 惩罚系数 c 的搜索区间为 $[0.1, 150]$, 参数 δ^2 的搜索区间为 $[0.01, 10]$ 。经过鲸鱼算法的优化, 得出2013年4月11日的LSSVM超参数 $(c, \delta^2) = (0.215, 0.6548)$ 。表1给出了该地区2013年4月11日1 d的负荷预测结果。为了体现WOA的优越性, 与PSO-LSSVM和标准LSSVM的负荷预测模型进行了对比, 标准LSSVM参数组根据经

验选取 $(c, \delta^2)=(30,2.27)^{[18-19]}$ 。以相对误差(Relative Error, RE)和平均绝对百分误差^[20](Mean Absolute Percentage Error, MAPE)作为评价标准。

从表1可以看出:WOL-LSSVM预测的RE为 $[-1.97\%, 3.31\%]$, PSO-LSSVM预测的RE为 $[-2.33\%, 3.78\%]$, 2种方法的预测结果基本都在短期负荷预测允许的误差范围 $[-3\%, 3\%]$ 内。但是未经优化的LSSVM预测的RE为 $[-4.87\%, 4.86\%]$, 而且有7个点的预测误差超出了规定范围。由此可见, 未经优化的LSSVM的预测值的波动性较大, 缺乏负荷预测所需的稳定性。PSO-LSSVM和WOA-LSSVM的波动性相对较好, 而且WOA-LSSVM的最大预测误差比LSSVM降低了1.56%, 比PSO-LSSVM降低了0.47%, 提高了负荷预测的精度。

图3为预测结果比较图, 与PSO-LSSVM及未优化的LSSVM比较, WOA-LSSVM模型的预测曲线与目标曲线重合度更高, 除个别点误差稍大以外, 大部分时间点的预测误差都较小, 预测效果良好。图4为

WOA迭代过程的在线性能曲线, 假设在环境 e 下策略 s 的在线性能为 $Q_e(s)$, $f_e(t)$ 为第 t 代的平均适应度函数, 则

$$Q_e(s) = \frac{1}{T} \sum_{t=1}^T f_e(t)$$

(17)

由图4可以说明算法收敛稳定, 能够很好避免早熟现象, 逐步搜索到全局最优值。与粒子群优化算法相比, 鲸鱼优化算法具有较强的全局寻优能力, 没有出现早熟现象。

表2给出了3种预测方法3 d负荷预测的MAPE, WOA-LSSVM 3 d的MAPE都比PSO-LSSVM模型和LSSVM模型的低, 说明WOA-LSSVM模型的泛化能力更好, 具有较高的预测精度。

5 结论

随着智能电网的快速发展, 为了提高短期负荷预测的精度, 本文采用鲸鱼优化算法寻找LSSVM的最优参数, 克服了以往最小二乘支持向量机选参盲

表 1 WOA-LSSVM与PSO-LSSVM, LSSVM的预测结果对比

Table 1 Comparison of prediction results between WOA-LSSVM, PSO-LSSVM and LSSVM

时间	实际负荷/MW	WOA-LSSVM		PSO-LSSVM		LSSVM	
		预测值/MW	相对误差/%	预测值/MW	相对误差/%	预测值/MW	相对误差/%
00:00	179.10	179.66	0.31	180.22	0.63	173.82	-2.95
01:00	170.40	169.85	-0.32	170.33	-0.04	166.20	-2.46
02:00	163.80	163.99	0.12	164.52	0.44	159.28	-2.76
03:00	164.20	160.96	-1.97	160.38	-2.33	156.20	-4.87
04:00	159.30	159.64	0.21	160.26	0.60	155.48	-2.40
05:00	162.00	161.01	-0.61	161.41	-0.36	159.84	-1.33
06:00	170.20	170.43	0.14	170.69	0.29	168.91	-0.76
07:00	206.40	207.64	0.60	207.71	0.63	209.87	1.68
08:00	286.80	288.85	0.71	288.90	0.73	291.68	1.70
09:00	303.50	303.65	0.05	303.52	0.01	307.76	1.40
10:00	307.00	308.09	0.36	307.93	0.30	311.64	1.51
11:00	314.00	309.26	-1.51	309.49	-1.44	307.76	-1.99
12:00	221.70	217.65	-1.83	217.98	-1.68	218.45	-1.47
13:00	284.90	283.82	-0.38	283.63	-0.45	290.11	1.83
14:00	294.90	298.09	1.08	297.80	0.98	304.56	3.28
15:00	298.40	296.75	-0.55	296.59	-0.61	303.99	1.87
16:00	295.80	298.12	0.78	297.98	0.74	305.01	3.11
17:00	295.60	294.89	-0.24	294.74	-0.29	302.01	2.17
18:00	256.40	256.23	-0.07	255.98	-0.16	261.00	1.79
19:00	261.30	265.61	1.65	265.39	1.57	270.84	3.65
20:00	248.50	254.65	2.47	257.59	3.66	260.19	4.70
21:00	234.90	241.38	2.76	243.43	3.63	245.22	4.39
22:00	215.90	220.58	2.17	220.51	2.14	222.36	2.99
23:00	193.70	200.11	3.31	201.03	3.78	203.12	4.86




图 3 WOA-LSSVM、PSO-LSSVM与LSSVM的预测结果对比曲线图

Fig.3 Comparison Curve of Prediction Results of WOA-LSSVM, PSO-LSSVM and LSSVM




图 4 WOA的在线性能曲线

Fig.4 Online Performance of WOA

表 2 负荷预测平均相对误差的比较

日期	WOA-LSSVM			PSO-LSSVM			LSSVM		
	<i>c</i>	δ^2	MAPE/ %	<i>c</i>	δ^2	MAPE/ %	<i>c</i>	δ^2	MAPE/ %
4月9日	17.86	0.100 0	1.77	148.46	3.134 5	1.96	30	2	3.20
4月10日	63.90	3.004 6	0.87	140.32	4.821 1	0.88	30	2	0.99
4月11日	0.215	0.654 8	1.03	0.395 6	2.759 4	1.14	30	2	2.59

目性的缺点。该算法不仅实现了自动选取关键参数，同时结合了最小二乘法优良的非线性回归问题的处理能力，具有较高的负荷预测精度。实验结果表明，与LSSVM和PSO-LSSVM相比，WOA-LSSVM在短期电力负荷预测中泛化能力强，预测精度高，在线性能良好，具有很好的实际应用价值。

参考文献:

[1] 李勋, 龚庆武, 胡元潮, 等. 智能配电网体系探讨[J]. 电力

自动化设备, 2011, 31(8): 108-126.

LI X, GONG Q W, HU Y C, *et al.* Discussion of smart distribution grid system [J]. *Electric Power Automation Equipment*, 2011, 31(8): 108-126.

[2] BESSA R, TRINDADE A, MIRANDA V. Spatial-temporal solar power forecasting for smart grids [J]. *IEEE Transactions on Industrial Informatics*, 2015, 11(1): 232-241.

[3] 金光太. 基于人工免疫算法的神经网络电力系统短期负荷预测[J]. 成都大学学报(自然科学版), 2013, 32(2): 159-161.

JIN G D. Short-term load forecasting of power system based on artificial immune algorithm [J]. *Journal of Chengdu University (Natural Science)*, 2013, 32(2): 159-161.

[4] 郭经韬, 陈璟华, 周俊, 等. 基于组合混沌序列动态粒子群算法的电力系统无功优化[J]. 广东工业大学学报, 2014, 31(2): 85-89.

GUO J T, CHEN J H, ZHOU J, *et al.* Reactive power optimization based on combined chaotic dynamic particle swarm optimization algorithm [J]. *Guangdong University of Technology*, 2014, 31(2): 85-89.

[5] 孙薇, 刘默涵. 基于改进最小二乘支持向量机的短期负荷预测[J]. 电力科学与工程, 2015, 31(12): 16-21.

SUN W, LIU M H. Short-term load forecasting based on improved least squares support vector machine [J]. *Electric Power Science and Engineering*, 2015, 31(12): 16-21.

[6] SUN W, HE Y J. Optimal support vector machine based short-term load forecasting model with input variables and samples selection[C]//HUANG D S, HEUTTEL, LOOG M. ICIC 2007, Berlin Heidelberg: Springer-Verlag, 2007: 39-47.

[7] WANG S, WANG Q. Prediction and dispatching of workshop material demand based on least squares support vector regression with genetic algorithm [J]. *Information-an International Interdisciplinary Journal*, 2012, 15(1): 213-222.

[8] 柴远斌. 改进粒子群算法和最小二乘支持向量机的电力负荷预测[J]. 电气应用, 2015, 6(12): 46-49.

[9] SEYEDALI M, ANDREW L. The whale optimization algorithm [J]. *Engineering Software*, 2016, 95(5): 51-67.

[10] 唐俊杰, 陈璟华, 邱明晋. 基于动态模糊混沌粒子群算法的含电动汽车微电网多目标优化调度研究[J]. 广东工业大学学报, 2018, 35(3): 100-106.

TANG J J, CHEN J H, QIU M J. Multi-objective dispatch of microgrid based on dynamic fuzzy chaotic particle swarm algorithm [J]. *Journal of Guangdong University of Technology*, 2018, 35(3): 100-106.

[11] 李元诚, 方延健, 于尔铿. 短期负荷预测的支持向量机方法研究[J]. 中国电机工程学报, 2003, 23(6): 55-59.

LI Y C, FANG Y J, YU E K. Study of support vector machines for short-term load forecasting [J]. *Proceedings of the CSEE*, 2003, 23(6): 55-59.

[12] 张育凡. 基于蚱蜢优化和最小二乘支持向量机的电力负

- 荷预测研究[D]. 甘肃: 兰州大学, 2018.
- [13] 谭风霜, 陈梦涛, 汪龙龙. 基于积温效应和优化支持向量机的短期电力负荷预测[J]. *电力需求侧管理*, 2018, 20(5): 33-36.
- TAN F S, CHEN M T, WANG L L. Short-term load forecasting based on accumulated temperature effect and optimized support vector machine [J]. *DSM*, 2018, 20(5): 33-36.
- [14] 崔东文. 鲸鱼优化算法在水库优化调度中的应用[J]. *水利水电科技进展*, 2017, 37(3): 72-76.
- CUI D W. Application of whale optimization algorithm in reservoir optimal operation [J]. *Science and Technology of Water Resources*, 2017, 37(3): 72-76.
- [15] ZHI B S, YANG L, TAO Y. Short-term load forecasting based on LS-SVM optimized by bacterial colony chemotaxis algorithm[C]//International Conference on Information and Multimedia Technology. South Korea: Jeju Island, 2009: 306-309.
- [16] 陈璟华, 邱明晋, 唐俊杰, 等. 基于改进差分进化和粒子群混合算法的电力系统最优潮流计算[J]. *广东工业大学学报*, 2017, 34(5): 22-28.
- CHEN J H, QIU M J, TANG J J, *et al.* A hybrid algorithm based on improved differential evolution and particle swarm optimization for power system optimal power flow calculation [J]. *Journal of Guangdong University of Technology*, 2017, 34(5): 22-28.
- [17] 熊军华, 牛珂, 张春歌, 等. 基于小波变异果蝇优化支持向量机短期负荷预测方法研究[J]. *电力系统保护与控制*, 2017, 45(13): 71-77.
- XIONG J H, NIU K, ZHANG C G, *et al.* LSSVM in short-term load forecasting based on wavelet transform and mutant fruit fly optimization algorithm [J]. *Power System Protection and Control*, 2017, 45(13): 71-77.
- [18] 谢宏, 魏江平, 刘鹤立. 短期负荷预测中支持向量机模型的参数选取和优化方法[J]. *中国电机工程学报*, 2006, 26(22): 17-22.
- XIE H, WEI J P, LIU H L. Parameter selection and optimization method of SVM model for short-term load forecasting [J]. *Proceedings of the CSEE*, 2006, 26(22): 17-22.
- [19] 杨国健, 杨镜非, 童开蒙, 等. 短期负荷预测的支持向量机参数选择方法[J]. *电力系统及其自动化学报*, 2012, 24(6): 148-151.
- YANG G J, YANG J F, TONG K M, *et al.* Parameter selection of support vector machine for short-term load forecasting [J]. *Proceedings of the CSU-EPSCA*, 2012, 24(6): 148-151.
- [20] 郝晓弘, 刘鹏娟, 汪宁渤. 混沌优化PSO-LSSVM算法的短期负荷预测[J]. *兰州理工大学学报*, 2019, 45(1): 85-90.
- HAO X H, LIU P J, WANG N B. Short-term load forecasting using chaotic optimization PSO-LSSVM algorithm [J]. *Journal of Lanzhou University of Technology*, 2019, 45(1): 85-90.

(责任编辑: 杨耀辉)