

DOI: 10.7652/xjtuxb201706003

# 采用改进果蝇优化算法的最小二乘 支持向量机参数优化方法

司刚全, 李水旺, 石建全, 郭璋  
(西安交通大学电气工程学院, 710049, 西安)

**摘要:** 针对最小二乘支持向量机建模中超参数选择盲目的问题,提出了一种新的改进果蝇优化算法用于超参数寻优。该算法在果蝇优化算法的基础上,通过判断当代寻优所获得的最优值与前代最优值的关系来选择不同的步长计算公式,以实现搜索步长的自适应更新,使其不仅具有果蝇优化算法调整参数少、计算速度快的优越性,而且提高了果蝇优化算法的寻优精度和全局寻优能力。仿真结果和磨机负荷应用表明,与基于网格搜索法、粒子群优化算法以及未改进的果蝇优化算法所建立的预测模型相比,基于改进的果蝇优化算法所建立的预测模型可以显著提高磨机负荷的预测精度,能更准确地描述出磨机负荷的变化规律。

**关键词:** 改进果蝇优化算法(IFOA);最小二乘支持向量机(LSSVM);磨机负荷

**中图分类号:** TP274 **文献标志码:** A **文章编号:** 0253-987X(2017)06-0014-06

## Least Squares Support Vector Machine Parameters Optimization Based on Improved Fruit Fly Optimization Algorithm with Applications

SI Gangquan, LI Shuiwang, SHI Jianquan, GUO Zhang  
(School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** Considering the blind hyper parameters selection in least squares support vector machine (LSSVM) modeling, a new improved fruit fly optimization algorithm(IFOA) for hyper parameter optimization is proposed based on the conventional FOA. This algorithm selects the different step size formula to realize the adaptive update of the search step by judging the relation between the optimal value obtained by contemporary optimization and the previous generation optimal value, which improves the optimization precision and global optimization ability of the IFOA with fewer parameters and quick calculation rate. The simulation and mill load softsensing application show that the prediction model based on IFOA, compared with those based on grid search method, particle swarm optimization algorithm and FOA, significantly improves the mill load forecast precision and more accurately reveals the change rule of mill load.

**Keywords:** improved fruit fly optimization algorithm; least squares support vector machine; mill load

最小二乘支持向量机(LSSVM)是利用核函数 使原始空间的非线性问题转化为特征空间的线性问

收稿日期: 2017-01-10。 作者简介: 司刚全(1980—),男,副教授。 基金项目: 国家自然科学基金资助项目(61304118);教育部新世纪人才计划资助项目(NCET-13-0456);中央高校基本科研业务费专项资金资助项目;教育部高等学校博士学科点专项科研基金资助项目(20130201120011)。

网络出版时间: 2017-02-24

网络出版地址: <http://www.cnki.net/kcms/detail/61.1069.T.20170224.1838.004.html>

题,并在高维特征空间中提出最大间隔的优化目标,实现按结构风险最小化准则进行学习,具有收敛快、精度高等一系列优点。在利用 LSSVM 建模过程中,惩罚系数  $\gamma$  和核参数  $\sigma$  统称为超参数,它们的取值直接影响着模型的复杂程度以及预测精度。然而,在当前实际应用中,对超参数取值的调整主要依靠网格搜索法,但是这种方法消耗时间长、预测精度低。因此,国内外许多学者对参数寻优方法进行了深入研究,文献[1]采用梯度下降法来实现对惩罚系数和核参数的寻优,主要通过计算误差梯度来改变寻优步长;文献[2]通过留一法导出梯度最优化算法,以选取最优超参数,从而构建 G-LSSVM 模型;文献[3]是从 K-折交叉验证中推出一种新的验证函数,通过拟牛顿优化法最小化经验函数从而实现参数寻优;文献[4]采用混合统计实验方法来实现支持向量机模型的自动选择;文献[5]采用快速交叉验证法对最小二乘支持向量机模型的超参数进行选择;文献[6]首先根据实际情况将超参数进行区间划分,然后在确定的范围内,采用自适应混沌算法来进行参数寻优;文献[7]利用预测误差作为遗传算法(GA)的评价函数来优化模型超参数,最终建立预测模型;文献[8]采用布谷鸟搜索算法对最小二乘支持向量机进行参数优化,并结合 LSSVM 建立文本分类器;文献[9]通过蚁群算法(ACO)对 LSSVM 参数进行自动搜索和确定,然后建立改进的预测模型;文献[10]采用粒子群优化算法(PSO)对 LSSVM 的惩罚系数  $\gamma$  和核参数  $\sigma$  进行优化,建立了速度更快的识别模型;文献[11]应用果蝇优化算法对支持向量机的参数进行优化,建立预报模型。

上述所提到的方法,相比于网格搜索法都有着自己的优势,但也有相应的缺陷。梯度下降法对初始点要求特别高,快速交叉验证法计算量过大,遗传算法优化过程过于复杂,粒子群算法消耗时间过长。果蝇优化算法相比于其他优化算法,简单易于实现,调整参数少,并且优化速度快,但果蝇优化算法由于搜索步长固定,靠近最优点时调整速度慢,无法保证收敛到最优点,并且容易陷入局部最优,导致预测精度下降。为此,本文提出了一种改进的自适应变步长果蝇优化算法(IFOA),该算法能够快速高效地寻找出最优超参数,结合最小二乘支持向量机建立 IFOA-LSSVM 预测模型,并将其应用于火电厂磨机负荷预测,有效提高了磨机负荷的预测精度。

## 1 最小二乘支持向量机

由于标准 SVM 模型需要求解二次规划问题,

在大样本数据的情况下,其运算量大,所需支持向量的个数较多,因此模型比较复杂,从而导致模型的推广能力较差。Suykens 等在标准 SVM 基础上提出了最小二乘支持向量机模型。相对于支持向量机模型,LSSVM 模型中的约束是等式约束,在优化目标函数中选取了误差平方和的形式,将原来 SVM 中需要求解的二次规划问题通过最优条件转化为线性方程组求解问题,从而降低了计算复杂度,在非线性系统建模方面更具有优势<sup>[12]</sup>。LSSVM 的基本思想简述如下。

给定一个含有  $N$  个样本的训练样本数据集  $\{\mathbf{x}_n, y_n\}_{n=1}^N$ , 其中输入为  $P$  维向量  $\mathbf{x}_n \in \mathbf{R}^P$ , 输出为一维  $y_n \in \mathbf{R}$ , 则 LSSVM 定义如下优化问题

$$\min_{\mathbf{w}, b, e} J(\mathbf{w}, e) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \gamma \frac{1}{2} \sum_{n=1}^N e_n^2 \quad (1)$$

$$y_n = \mathbf{w}^T \varphi(\mathbf{x}_n) + b + e_n, \quad n = 1, \dots, N \quad (2)$$

式中:  $\mathbf{w}$  是权系数向量;  $\varphi(\cdot)$  是输入空间到高维空间的映射;  $\gamma$  是惩罚系数;  $e_n$  是拟合误差;  $b$  是阈值。为求解该优化问题,构造如下拉格朗日函数

$$L(\mathbf{w}, b, e, \alpha) = J(\mathbf{w}, e) -$$

$$\sum_{n=1}^N \alpha_n \{ \mathbf{w}^T \varphi(\mathbf{x}_n) + b + e_n - y_n \} \quad (3)$$

式中:  $\alpha_n \in \mathbf{R}$  为 Lagrange 乘子。通过 KKT (Karush-Kuhn-Tucker) 条件, 分别求出  $L(\mathbf{w}, b, e, \alpha)$  对  $\mathbf{w}, b, e, \alpha$  的偏微分, 可得

$$\left. \begin{aligned} \frac{\partial L}{\partial \mathbf{w}} = 0 &\rightarrow \mathbf{w} = \sum_{n=1}^N \alpha_n \varphi(\mathbf{x}_n) \\ \frac{\partial L}{\partial b} = 0 \\ \frac{\partial L}{\partial e_n} = 0 &\rightarrow \alpha_n = \gamma e_n \\ \frac{\partial L}{\partial \alpha_n} = 0 &\rightarrow \mathbf{w}^T \varphi(\mathbf{x}_n) + b + e_n - y_n = 0, \\ &n = 1, \dots, N \end{aligned} \right\} \quad (4)$$

消去变量  $\mathbf{w}$  和  $e_n$ , 并引入核函数

$$K(\mathbf{x}_m, \mathbf{x}_n) = \varphi(\mathbf{x}_m)^T \varphi(\mathbf{x}_n), \quad m, n = 1, \dots, N \quad (5)$$

可得矩阵方程

$$\begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & \mathbf{\Omega} + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (6)$$

式中:  $\mathbf{y}^T = [y_1; \dots; y_N]$ ,  $\mathbf{1}^T = [1; \dots; 1]$ ,  $\boldsymbol{\alpha}^T = [\alpha_1; \dots; \alpha_N]$ ;  $\mathbf{\Omega}$  是一个方阵, 其第  $m$  行  $n$  列的元素为  $\Omega_{mn} = K(\mathbf{x}_m, \mathbf{x}_n)$ ,  $m, n = 1, \dots, N$ 。本文中核函数选择径向基核函数(RBF)  $K(\mathbf{x}, \mathbf{x}_n) = \exp(-\|\mathbf{x} - \mathbf{x}_n\|^2 / \sigma^2)$ 。最后得到的用于函数估计的 LSSVM 模型为

$$y(x) = \sum_{n=1}^N \alpha_n K(x, x_n) + b \quad (7)$$

通过以上分析,惩罚系数 $\gamma$ 和核参数 $\sigma$ 的选择对LSSVM预测模型十分重要,能否选取合适的超参数直接影响着最终模型的复杂程度以及预测精度。

## 2 基于改进果蝇优化算法(IFOA)的LSSVM超参数寻优

### 2.1 果蝇优化算法(FOA)原理及改进

果蝇优化算法是通过学习具有超强视觉和嗅觉的果蝇群体觅食行为而提出的一种新的群智能优化算法。果蝇群体在觅食过程中,先通过嗅觉搜索漂浮在空气中的气味,然后向该区域飞去,再利用视觉寻找食物和同伴聚集的位置,不断搜寻味道浓度更大的位置,以获取味道浓度最大的位置和食物。

果蝇优化算法虽然相比其他一些优化算法在优化速度、参数数量方面存在优势,但由于搜索步长固定,导致果蝇群体无法快速收敛到最优点,并且容易陷入局部最优,导致算法早熟。针对以上缺陷,本文在果蝇优化算法的基础上引入了自适应步长,步长的取值随着当代获得的最优味道浓度值与上一代最优味道浓度值的比值的变化而变化,对果蝇优化算法改进如下(以最优味道浓度最小为例)。

记 $i$ 为迭代次数, $R(i)$ 为第 $i$ 次的搜索步长, $S'(i)$ 为第 $i$ 次迭代所获得的最优味道浓度值, $\Delta = |S'(i) - S'(i-1)|$ 为味道误差绝对值。

当 $i=1$ 时, $R(1)=3$ 为初始步长, $S'(1)$ 为第一代寻优所获得的最优味道浓度值。

当 $i \geq 2$ 时,有

$$\text{if } S'(i) < S'(i-1)$$

$$R(i+1) = R(i) \left( 1 - \frac{S'(i)}{S'(i-1)} \right) \quad (8)$$

$S'(i) < S'(i-1)$ 表示当代最优味道浓度值优于上一代最优味道浓度值,此时应缩减步长以提高寻优精度。从 $S'(i-1)$ 到 $S'(i)$ 所需步长为 $R(i)$ ,当 $\Delta$ 较小时,说明此时已经靠近最优值,应该让步长减小较快,以快速收敛到最优值;当 $\Delta$ 较大时,说明此时离最优值相对较远,应该让步长减小较慢,以减少搜索次数,表达式为

$$\text{if } S'(i) \geq S'(i-1)$$

$$R(i+1) = R(i) \left( 1 + \frac{S'(i-1)}{S'(i)} \right) \quad (9)$$

$S'(i) \geq S'(i-1)$ 表示上一代最优味道浓度优于或等于当代最优味道浓度,此时应增加步长以扩

大搜索范围,提高全局搜索能力。从 $S'(i-1)$ 到 $S'(i)$ 所需步长为 $R(i)$ ,当 $\Delta$ 为0时,保持原步长不变;当 $\Delta$ 较小时,说明当前区域寻优效果一般,应让步长增加较快,以更换搜索区域;当 $\Delta$ 较大时,说明已到新的搜索区域,应让步长增加较慢,以继续扩大搜索范围。

### 2.2 基于 IFOA 的 LSSVM 超参数寻优

采用LSSVM进行预测模型的过程中,预测精度与惩罚系数 $\gamma$ 和核参数 $\sigma$ 的选择有关,如果 $\gamma$ 和 $\sigma$ 的选择不合理,则导致预测结果可靠性不高。果蝇优化算法虽然相比其他一些优化算法在优化速度、参数数量方面存在优势,但无法保证快速收敛到最优点,并且容易陷入局部最优。为此,采用改进的果蝇优化算法(IFOA)对LSSVM的两个参数 $\gamma$ 和 $\sigma$ 进行优化。

算法:基于 IFOA 的 LSSVM 超参数优化;

输入:果蝇群体初始位置 $(X_0, Y_0)$ ,群体规模 $m$ ,最大迭代次数 $n$ ,第一代搜索步长 $R(1)$ ;

输出:最优味道浓度 $S'$ ,最优惩罚系数 $\gamma'$ ,最优核参数 $\sigma'$ 。

具体步骤如下。

步骤1:在设定空间内,随机初始化果蝇群体位置 $(X_0, Y_0)$ 以及给定群体规模 $m$ 、最大迭代次数 $n$ 。

步骤2:根据初始位置,赋予每个果蝇个体搜寻食物的随机方向与距离。由于对惩罚系数 $\gamma$ 和核参数 $\sigma$ 两个参数进行寻优,因此 $X$ 与 $Y$ 各有两列数值

$$\left. \begin{aligned} X(i, 1) &= X_0 + R(i) \\ X(i, 2) &= X_0 + R(i) \\ Y(i, 1) &= Y_0 + R(i) \\ Y(i, 2) &= Y_0 + R(i) \end{aligned} \right\} \quad (10)$$

式中: $R$ 为搜索步长; $i$ 为迭代次数。

步骤3:由于无法得知食物位置,因此先估计与原点之间距离 $D$ ,再计算味道浓度判定值 $P$ ,此值为距离之倒数

$$\left. \begin{aligned} D(i, 1) &= (X(i, 1)^2 + Y(i, 1)^2)^{1/2} \\ P(i, 1) &= 1/D(i, 1) \\ D(i, 2) &= (X(i, 2)^2 + Y(i, 2)^2)^{1/2} \\ P(i, 2) &= 1/D(i, 2) \end{aligned} \right\} \quad (11)$$

步骤4:对惩罚系数 $\gamma$ 和核参数 $\sigma$ 进行赋值

$$\left. \begin{aligned} \gamma &= 10P(i, 1) \\ \sigma &= P(i, 2) \end{aligned} \right\} \quad (12)$$

步骤5:将均方误差作为味道浓度判定函数 $f(\cdot)$ ,每次迭代寻优获得一组味道浓度 $S(i)$ 并保留

$$S(i) = f(P(i))$$

(13)

步骤 6: 求出此果蝇群体中味道浓度最高果蝇

$$[S' \ I'] = \min S(i)$$

(14)

步骤 7: 判断  $i$  是否小于 2, 若是, 则直接执行步骤 8; 否则, 继续判断  $S'(i)$  是否小于  $S'(i-1)$ , 若是, 令  $R(i+1) = R(i) \left(1 - \frac{S'(i)}{S'(i-1)}\right)$ , 否则令  $R(i+1) = R(i) \left(1 + \frac{S'(i-1)}{S'(i)}\right)$ 。

步骤 8: 判断  $S'(i)$  是否小于  $S''$ , 若是, 则保留最优味道浓度值与相应位置, 并记录此时的  $\gamma$  和  $\sigma$ , 同时果蝇群体利用视觉往该位置飞去

$$\left. \begin{aligned} X_0 &= X(I', :) \\ Y_0 &= Y(I', :) \\ S'' &= S' \\ \gamma' &= 10P(I', 1) \\ \sigma' &= P(I', 2) \end{aligned} \right\}$$

(15)

否则, 只记录  $S'(i)$  所对应的位置

$$\left. \begin{aligned} X_0 &= X(I', :) \\ Y_0 &= Y(I', :) \end{aligned} \right\}$$

(16)

步骤 9: 进入迭代寻优, 执行步骤 2~步骤 8, 并判断当前迭代次数是否达到最大迭代次数  $n$ , 若是, 则执行步骤 10; 若不是, 则继续执行步骤 2~步骤 8。

步骤 10: 算法结束, 获得最优味道浓度  $S''$ , 最优惩罚系数  $\gamma'$  以及最优核参数  $\sigma'$ 。

3 仿真研究

3.1 评价指标与数据集

目前, 网格搜索法是应用最为广泛的一种超参数寻优算法, 粒子群优化算法是当下研究较多且效果较好的参数寻优方法。因此, 为了更好地评价所提出的改进果蝇优化算法的性能, 本文同时采用网格搜索法、粒子群优化算法、标准果蝇优化算法进行 LSSVM 的超参数寻优, 建立的模型分别记为 GS-LSSVM、PSO-LSSVM、FOA-LSSVM。

本文采用如表 1 所示的数据集进行仿真, 所选用的数据集覆盖了一维、多维、异方差等多种情况。

3.2 仿真结果

采用选取的 4 种优化算法对以上数据集进行 LSSVM 超参数优化, 结果如表 2 所示。从表中可以看出, 本文所提出的基于 IFOA 的 LSSVM 模型在 5 个基本数据集的两个评价指标上均表现出更好的性能。其中, 传统的网格搜索法(GS)不但训练时

表 1 不同优化算法所用数据集

| 样本集        | 样本数量<br>× 维数 | 定义及说明                                                                                  |
|------------|--------------|----------------------------------------------------------------------------------------|
| Sinc       | 200×2        | $Y = \frac{10\sin(X)}{X} + \epsilon, X \in [-10, 10]$<br>$\epsilon$ 是均值为 0、方差为 0.5 的噪声 |
| Motorcycle | 133×2        | 摩托车加速度试验数据集, 具有典型的异方差特性                                                                |
| Nelson     | 128×3        | 尼尔森数据集, 主要应用于社会科学                                                                      |
| bodyfat    | 251×15       | 体脂数据集, 是一组标准回归数据集                                                                      |
| pyrim      | 74×28        | Pyrim 数据集, 来源于定量活性结构关系                                                                 |

间长, 均方根误差也很大; 粒子群优化算法(PSO)相比网格搜索法在训练时间和均方根误差上有了较大的提升, 但是需要设置的参数个数过多, 达到 11 个; 未改进的果蝇优化算法(FOA)相比于粒子群优化算法速度更快, 精度更高, 需要设置的参数仅有 4 个; 改进的果蝇优化算法相比于之前的 3 种方法在训练时间、均方根误差上都表现得更为出色。

4 基于 IFOA-LSSVM 的磨机负荷预测

磨机负荷的准确检测一直是对火电厂磨机实施自动控制的关键和难点, 严重影响其能效水平的提高<sup>[13]</sup>。磨机负荷无法直接测量, 常规方法通过单源信息间接估计负荷情况, 结果通常不理想, 而采用软测量技术对磨机负荷进行准确检测, 可以综合多源信息得到相对可靠的估计结果<sup>[14]</sup>。

磨机负荷在噪声、振动、磨机电流、磨机出入口差压以及磨机出口温度等多个量上均有表征, 但都存在非线性、局部有效、相关二义性以及工况适应性差等问题。本文基于 IFOA-LSSVM 构建磨机负荷软测量模型, 可表示为

$$y_{ml} = f(E_{n1}, E_{n2}, E_{v1}, E_{v2}, P_{in}, P_{dio}, T_{out}, I_m)$$

(17)

式中:  $E_{n1}$ 、 $E_{n2}$  和  $E_{v1}$ 、 $E_{v2}$  分别是磨机前段噪音、后段噪音和前段振动、后段振动的特征频段能量;  $P_{in}$  为磨机入口负压;  $P_{dio}$  为磨机的出入口差压;  $T_{out}$  为磨机出口温度;  $I_m$  为磨机电流。为了验证建立的 IFOA-LSSVM 模型的预测性能, 本文采用某 200 MW 火力发电机组球磨机运行过程中收集的 800 组覆盖低负荷、正常负荷以及高负荷等工况的数据

表 2 不同优化算法的 LSSVM 模型寻优参数和性能对比

| 数据集               | 优化算法       | $\gamma$  | $\sigma$ | 均方根误差    | 训练时间/s    |
|-------------------|------------|-----------|----------|----------|-----------|
| Sinc<br>函数        | GS-LSSVM   | 20.534 5  | 8.947 5  | 0.653 3  | 0.096 330 |
|                   | PSO-LSSVM  | 3.852 4   | 0.258 8  | 0.554 2  | 0.006 484 |
|                   | FOA-LSSVM  | 3.374 0   | 0.011 5  | 0.471 4  | 0.005 025 |
|                   | IFOA-LSSVM | 19.889 9  | 0.010 0  | 0.174 2  | 0.004 302 |
| Motorcycle<br>数据集 | GS-LSSVM   | 51.628 6  | 58.125 0 | 21.669 5 | 0.089 317 |
|                   | PSO-LSSVM  | 19.974 5  | 0.010 0  | 19.783 2 | 0.004 489 |
|                   | FOA-LSSVM  | 1.661 2   | 0.146 2  | 18.634 3 | 0.004 676 |
|                   | IFOA-LSSVM | 4.361 3   | 0.315 9  | 13.370 8 | 0.002 556 |
| Nelson<br>数据集     | GS-LSSVM   | 9.130 6   | 6.021 4  | 15.360 9 | 0.095 650 |
|                   | PSO-LSSVM  | 41.188 0  | 0.010 0  | 12.001 4 | 0.003 914 |
|                   | FOA-LSSVM  | 9.326 7   | 0.619 9  | 12.785 7 | 0.003 400 |
|                   | IFOA-LSSVM | 11.708 3  | 0.393 0  | 10.004 3 | 0.002 438 |
| bodyfat<br>数据集    | GS-LSSVM   | 18.670 7  | 89.841 0 | 0.475 5  | 0.063 887 |
|                   | PSO-LSSVM  | 100.000 0 | 21.039 0 | 0.041 7  | 0.008 770 |
|                   | FOA-LSSVM  | 36.140 4  | 0.654 8  | 0.025 0  | 0.015 117 |
|                   | IFOA-LSSVM | 49.808 8  | 0.975 8  | 0.018 3  | 0.002 593 |
| pyrim<br>数据集      | GS-LSSVM   | 860.828 0 | 37.733 0 | 0.026 9  | 0.055 190 |
|                   | PSO-LSSVM  | 501.651 0 | 0.187 9  | 0.028 5  | 0.001 975 |
|                   | FOA-LSSVM  | 5.779 9   | 0.322 2  | 0.021 0  | 0.002 066 |
|                   | IFOA-LSSVM | 44.482 7  | 1.026 0  | 0.009 4  | 0.001 392 |

作为训练样本进行建模,对之后的 50 组数据进行预测及仿真。根据 IFOA 算法的寻优过程,本文设置种群规模为 20、迭代次数为 100、步长为 10,将均方根误差作为浓度判定函数。通过 IFOA 算法寻优所获得的  $\gamma$  和  $\sigma$  分别为 39.333 3 和 0.874 5,代入

LSSVM 模型后进行预测,其预测值与真实值对比如图 1 所示,预测值与真实值的误差如图 2 所示。GS-LSSVM、PSO-LSSVM、FOA-LSSVM、IFOA-LSSVM 模型评价指标对比如表 3 所示。由上得出本文模型的预测值与真实值吻合度更好。




图 1 基于 IFOA-LSSVM 的磨机负荷模型预测结果




图 2 基于 IFOA-LSSVM 的磨机负荷模型预测误差

表 3 不同优化算法在磨机负荷检测中的寻优参数和性能对比

| 优化算法       | $\gamma$ | $\sigma$ | 均方根误差    | 训练时间/s    |
|------------|----------|----------|----------|-----------|
| GS-LSSVM   | 20.465 1 | 2.937 2  | 0.386 21 | 0.027 568 |
| PSO-LSSVM  | 21.251 3 | 0.593 2  | 0.017 52 | 0.003 750 |
| FOA-LSSVM  | 29.324 4 | 1.974 2  | 0.012 91 | 0.002 830 |
| IFOA-LSSVM | 39.333 3 | 0.874 5  | 0.005 61 | 0.001 140 |

## 5 结 论

在利用最小二乘支持向量机建模过程中,超参数的取值直接影响着模型复杂度以及预测精度。然而,在当前实际应用中,对超参数取值的选取主要依靠网格搜索法,但是这种方法消耗时间长、预测精度低。本文采用基于交叉训练的果蝇优化算法对最小二乘支持向量机进行超参数寻优,可以显著提高超参数寻优效率以及模型的预测精度。仿真结果表明,该方法比网格搜索法、粒子群算法以及果蝇优化算法寻优效率更高,同时模型预测精度相对较好,对火电厂磨机负荷的准确预测具有较高的实用价值。

## 参考文献:

- [1] DUAN K, KEERTHI S S, POO A N. Evaluation of simple performance measures for tuning SVM hyperparameters [J]. *Neurocomputing*, 2003, 51(4): 41-49.
- [2] KERRTHI S S. Efficient tuning of SVM hyperparameters using radius/margin bound and iterative algorithms [J]. *IEEE Trans on Neural Networks*, 2002, 13(5): 1225-1229.
- [3] 陶少辉,陈德钊,胡望明. LSSVM 过程中超参数选取的梯度优化算法 [J]. *化工学报*, 2007, 58(6): 1514-1517.  
TAO Shaohui, CHEN Dezhaoh, HU Wangming. Gradient algorithm for selecting hyper parameters of LSSVM in process modeling [J]. *Journal of Chemical Industry and Engineering*, 2007, 58(6): 1514-1517.
- [4] GOLD C, SOLLICH P. Model selection for support vector machine classification [J]. *Neurocomputing*, 2003, 55(1/2): 221-249.
- [5] AN S, LIU W, VENKATESH S. Fast cross-validation algorithms for least squares support vector machine and kernel ridge regression [J]. *Pattern Recognition*, 2007, 40: 2154-2162.
- [6] 郭一楠,程建,杨梅. 支持向量回归超参数的混沌文化优化选择方法 [J]. *控制与决策*, 2010, 25(4): 525-530.  
GUO Yinan, CHENG Jian, YANG Mei. Selection method for hyper-parameters of support vector regression by chaotic cultural algorithm [J]. *Control and Decision*, 2010, 25(4): 525-530.
- [7] 裴瑞平,邱杰. 基于 GA-LSSVM 的短期风功率预测 [J]. *自动化与仪器仪表*, 2015, 183(1): 164-167.  
PEI Ruiping, QIU Jie. Based on GA-LSSVM of short-term wind power prediction [J]. *Automation and Instrumentation*, 2015, 183(1): 164-167.

- [8] 赵专政,李云翔. 聚类加权和 CS-LSSVM 的文本分类 [J]. *计算机工程与应用*, 2013, 49(16): 124-128.  
ZHAO Zhuangzheng, LI Yunxiang. Text categorization model based on CS-LSSVM optimized by cuckoo search algorithm [J]. *Computer Engineering and Applications*, 2013, 49(16): 124-128.
- [9] 田海梅,黄楠. 基于 ACO-LSSVM 的网络流量预测 [J]. *计算机工程与应用*, 2014, 50(1): 91-95.  
TIAN Haimei, HUANG Nan. Network traffic prediction based on ACO-LSSVM [J]. *Computer Engineering and Applications*, 2014, 50(1): 91-95.
- [10] 董建达,孙志能,周开河,等. 粒子群优化算法和最小二乘支持向量机的雷电过电压识别 [J]. *电网与清洁能源*, 2016, 32(6): 35-41.  
DONG Jianda, SUN Zhineng, ZHOU Kaihe, et al. Identification of lightning over-voltage based on particle swarm optimizing algorithm and least square support vector machine [J]. *Power System and Clean Energy*, 2016, 32(6): 35-41.
- [11] 王慧中,周佳,王岳峰,等. 基于果蝇参数优化的 LSSVM 短期负荷预测 [J]. *电力系统及其自动化*, 2015, 37(6): 60-63.  
WANG Huizhong, ZHOU Jia, WANG Yuefeng, et al. LSSVM in short-term load forecasting based on fruit fly optimization algorithm [J]. *Power System and Automation*, 2015, 37(6): 60-63.
- [12] 司刚全,曹晖,张彦斌,等. 一种基于密度加权的最小二乘支持向量机稀疏化算法 [J]. *西安交通大学学报*, 2009, 43(10): 11-15.  
SI Gangquan, CAO Hui, ZHANG Yanbin, et al. Density weighted pruning method for sparse least squares support vector machines [J]. *Journal of Xi'an Jiaotong University*, 2009, 43(10): 11-15.
- [13] 汤健,赵立杰,岳恒,等. 磨机负荷检测方法研究综述 [J]. *控制工程*, 2010, 17(5): 565-574.  
TANG Jian, ZHAO Lijie, YUE Heng, et al. Present status and future developments of detection method for mill load [J]. *Control Engineering of China*, 2010, 17(5): 565-574.
- [14] 汤健,赵立杰,岳恒,等. 基于多源数据特征融合的球磨机负荷软测量 [J]. *浙江大学学报(工学版)*, 2010, 44(7): 1406-1413.  
TANG Jian, ZHAO Lijie, YUE Heng, et al. Soft sensor for ball mill load based on multi-source data feature fusion [J]. *Journal of Zhejiang University (Engineering Science)*, 2010, 44(7): 1406-1413.

(编辑 杜秀杰)