

基于反学习飞蛾火焰算法优化的 LSSVM 模型及其软测量应用

夏祥礼¹ 陈国彬¹ 刘超^{2*}

¹(重庆工商大学融智学院 重庆 401320)

²(贵州航天电器股份有限公司 贵州 贵阳 550009)

摘要 针对最小二乘支持向量机 LSSVM(least squares support vector machine)软测量模型参数难以估计问题,提出将参数估计转化为约束优化问题,基于反学习飞蛾火焰算法 OMFO(opposition-based MFO)优化的 LSSVM 建模技术,并构建 OMFO-LSSVM 软测量模型。在 MFO(moth-flame optimization)基础上增加新型反学习策略以提升算法性能。针对越界飞蛾,采用一种镜像越界策略保证飞蛾均在维度范围内,改善种群多样性。利用 OMFO 算法调整模型参数,并建立 OMFO-LSSVM 软测量模型。将 OMFO-LSSVM 模型用于机组热耗率预测,预测精度达到 0.11%,验证了该模型的可行性与优越性。

关键词 软测量 最小二乘支持向量机 飞蛾火焰算法 反学习 越界

中图分类号 TP18 **文献标识码** A **DOI**:10.3969/j.issn.1000-386x.2019.05.054

OPTIMIZED LSSVM AND ITS SOFT SENSING APPLICATION BASED ON OPPOSITION-BASED LEARNING MOTH FLAME ALGORITHM

Xia Xiangli¹ Chen Guobin¹ Liu Chao^{2*}

¹(Rongzhi College of Chongqing Technology and Business University, Chongqing 401320, China)

²(Guizhou Aerospace Electronics Co., Ltd., Guiyang 550009, Guizhou, China)

Abstract In order to solve the problem of parameter estimation in the LSSVM soft sensing model, we transformed the parameter estimation into a constrained optimization problem. We proposed an optimization LSSVM modeling technique based on opposition-based learning moth flame algorithm(OMFO) and constructed an OMFO-LSSVM soft sensing model. A new opposition-based learning strategy was added to improve the performance of the algorithm. For cross-border moths, a mirror cross-border strategy was adopted to ensure that moths were within the dimension range and improved population diversity. Then we the used OMFO algorithm to adjust the model parameters, and the OMFO-LSSVM soft sensing model was established. The OMFO-LSSVM model is used to predict the heat rate of the unit, and the prediction accuracy reaches 0.11%, which verifies the feasibility and superiority of the model.

Keywords Soft sensing LSSVM Moth-flame optimization algorithm Opposition-based learning Out of bound

0 引言

近年来,越来越多的研究人员开始关注数据驱动方法。许多过程数据可以通过使用测量技术来收集、存储和分析。数据驱动的软传感器模型有望解决现场实际问题中难以采用机理建模的通用技术^[1,2]。建立

准确的数学模型是软测量技术研究的主要内容之一,常见的非线性预测模型包括人工神经网络、支持向量机^[3-5]等。

最小二乘支持向量机 LSSVM 是支持向量机的一种变体,良好的非线性处理能力使得 LSSVM 得到广泛应用。然而,LSSVM 正则化参数和核参数严重影响模型的预测精度和泛化能力,其模型参数的选择问题也

是 LSSVM 模型重要研究内容之一。文献[6]采用差分进化算法优化最小二乘支持向量机模型,将其用于开关磁阻电机模型建立,仿真实验验证了 DE-LSSVM 模型的有效性。为改善 LSSVM 模型对非高斯脉动风速预测性能,李春祥等^[7]采用蚁群算法和遗传算法分别与粒子群算法相融合的混合算法优化模型参数,结果验证了优化后的模型精度更高。文献[8]采用三维果蝇优化算法选择 LSSVM 模型参数并建立库存调节误差预测模型,仿真结果验证了优化算法对模型泛化能力提升的有效性。

飞蛾火焰优化算法 MFO 是 Mirjalili 等模仿飞蛾捕焰机制提出的群智能优化技术^[9-10]。为增强 MFO 算法的性能,提出一种反学习 MFO 算法 OMFO。进一步,采用 OMFO 算法优化选择 LSSVM 模型参数,并构建 OMFO-LSSVM 软测量模型,仿真实验验证了 OMFO-LSSVM 模型的实用性。

1 最小二乘支持向量机

基于结构风险最小化准则的 LSSVM 因具有良好的非线性回归特性,常用作软测量建模的主要工具之一。LSSVM 的目标函数定义如下:

$$\min J(\boldsymbol{\omega}, \boldsymbol{e}) = \frac{1}{2} \boldsymbol{\omega}^T \boldsymbol{\omega} + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2 \quad \gamma > 0 \quad (1)$$

$$\text{Subject to } y_i = \langle \boldsymbol{\omega}, \boldsymbol{x}_i \rangle + b + e_i \quad i=1, 2, \dots, n \quad (2)$$

式中: (x_i, y_i) , $i=1, 2, \dots, l$, $x_i \in R^n$, $y_i \in R$, 为训练样本集; $\varphi(\cdot)$ 为非线性映射; γ 为正则化参数; e_i 为第 i 个样本的拟合误差。利用拉格朗日法构造目标函数:

$$L(\boldsymbol{\omega}, b, \boldsymbol{e}, \boldsymbol{\alpha}) = J(\boldsymbol{\omega}, \boldsymbol{e}) - \sum_{i=1}^N \alpha_i [\boldsymbol{\omega}^T \boldsymbol{\varphi}(\boldsymbol{x}_i) + b + e_i - y_i] \quad (3)$$

式中: α_i 是拉格朗日乘子。

根据式(3),通过 L 对 $\boldsymbol{\omega}$ 、 b 、 e_i 和 α_i 的偏导数等于零对式(3)进行优化,可得到 LSSVM 的数学模型:

$$y(x) = \boldsymbol{\omega}^T \boldsymbol{\varphi}(x) + b = \sum_{i=1}^N \alpha_i K(x, x_i) + b \quad (4)$$

待求参数 $\boldsymbol{\alpha} = [a_1, a_2, \dots, a_i, \dots, a_n]$, b 可由下式求得:

$$\begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 & \boldsymbol{e}^T \\ \boldsymbol{e} & \boldsymbol{\Omega} + 2\gamma^{-1} \boldsymbol{e} \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ \boldsymbol{y} \end{bmatrix} \quad (5)$$

式中: $\boldsymbol{e} = [1 \ 1 \ \dots \ 1]^T$; $\boldsymbol{y} = [y_1 \ y_2 \ \dots \ y_n]^T$; 支持向量值 $\boldsymbol{\alpha}$ 和偏置量 b 是 LSSVM 的模型参数; $\boldsymbol{\Omega}$ 是一个 $n \times n$ 的

对称矩阵。

$$\boldsymbol{\Omega}_{ij} = \boldsymbol{\varphi}(\boldsymbol{x}_i)^T \boldsymbol{\varphi}(\boldsymbol{x}_j) = K(\boldsymbol{x}_i, \boldsymbol{x}_j) \quad i, j=1, 2, \dots, n \quad (6)$$

式中: $K(\boldsymbol{x}_i, \boldsymbol{x}_j)$ 为核函数。常用核函数多项式核函数、Sigmoid 核函数、径向基等核(RBF)函数。RBF 函数比其余两种核函数待优化参数少、且性能优良,因此选择 RBF 函数为 LSSVM 模型的核函数:

$$K(x_i, x) = \exp\left(\frac{-(x_i - x)^2}{2\delta^2}\right) \quad (7)$$

2 新型反学习飞蛾火焰算法

2.1 飞蛾火焰算法

Mirjalili 等在 2015 年提出飞蛾火焰优化算法 MFO,旨在通过模仿飞蛾夜间使用的导航方法来解决优化问题。在 MFO 算法中,飞蛾个体为优化问题的候选解。 n 个飞蛾在 d 维空间中构成的种群由矩阵 \boldsymbol{M} 描述:

$$\boldsymbol{M} = \begin{bmatrix} m_{1,1} & m_{1,2} & \dots & m_{1,d} \\ m_{2,1} & m_{2,2} & \dots & m_{2,d} \\ \vdots & \vdots & & \vdots \\ m_{n,1} & m_{n,2} & \dots & m_{n,d} \end{bmatrix} \quad (8)$$

飞蛾个体适应度值存储在 \boldsymbol{OM} 矩阵中:

$$\boldsymbol{OM} = [OM_1 \quad OM_2 \quad \dots \quad OM_n]^T \quad (9)$$

火焰为当前迭代所获得的最佳位置,种群 \boldsymbol{F} 和适应度矩阵 \boldsymbol{OF} 描述如下:

$$\boldsymbol{F} = \begin{bmatrix} f_{1,1} & f_{1,2} & \dots & f_{1,d} \\ f_{2,1} & f_{2,2} & \dots & f_{2,d} \\ \vdots & \vdots & & \vdots \\ f_{n,1} & f_{n,2} & \dots & f_{n,d} \end{bmatrix} \quad (10)$$

$$\boldsymbol{OF} = [OF_1 \quad OF_2 \quad \dots \quad OF_n]^T \quad (11)$$

MFO 算法包括捕焰行为和弃焰操作。飞蛾以对数螺旋运动轨迹移动到火焰位置,并实现全局最优,其捕焰行为描述如下:

$$S(M_i, F_j) = D_i \cdot e^{bt} \cdot \cos(2\pi t) + F_j \quad (12)$$

式中: M_i, F_j 分别为第 i 个飞蛾和第 j 个火焰; $S(M_i, F_j)$ 为飞蛾更新位置; b 为螺旋常量; t 为 $[-1, 1]$ 之间的随机数; $D_i = |F_j - M_i|$ 。

在 MFO 算法中,定义最大迭代次数和当前迭代次数分别为 T 和 t 。MFO 算法通过式(13)弃焰操作将火焰数量由 N 逐渐减少,并最终将保持一个最优火焰:

$$no_{\text{name}} = \text{round}\left(N - t \times \frac{N-1}{T}\right) \quad (13)$$

2.2 OMFO 算法

MFO 算法是一种自然启发的搜索算法,在解决各种优化问题时具有良好的性能和效率。横向定向过程中的“火焰”变量是 MFO 用来更新种群新位置的一个重要参数。然而,火焰的减少会导致收敛速度变慢,从而影响最终解决方案的质量。为了克服这个缺点,提出新的反学习 OBL (opposition-based learning) 飞蛾火焰算法;此外,针对越界飞蛾,采用一种镜像越界策略保证飞蛾均在维度范围内,改善种群多样性。

2.2.1 反学习算法

OBL 最初由 Tizhoosh 于 2005 年提出^[11],描述如下:假设 d 维空间的点 $X = (x_1, x_2, \dots, x_i, \dots, x_d)$,其中: $x_1, x_2, \dots, x_i, \dots, x_d \in R$,且 $x_i \in [a_i, b_i] \quad \forall i \in \{1, 2, \dots, d\}$ 。其反向点 $\tilde{X} = (\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_i, \dots, \tilde{x}_d)$ 定义如下:

$$\tilde{x}_i = a_i + b_i - x_i \quad (14)$$

在 MFO 基础上增加基于反学习策略的补充函数 H 以加快 MFO 收敛速度,并获得了高精度的解。 H 函数描述如下:

$$H = (A + B) - C \times rand() \quad (15)$$

$$M_i = H \quad (16)$$

$$A = \begin{cases} \Gamma & s > rand() \\ U & \text{otherwise} \end{cases} \quad (17)$$

$$B = \begin{cases} \Theta & s > rand() \\ L & \text{otherwise} \end{cases} \quad (18)$$

式中: s = 当前迭代次数/最大迭代次数; Γ 和 Θ 分别为飞蛾的最大和最小位置; U 和 L 为搜索空间的上、下限; C 为任意迭代过程中最佳火焰位置; $rand()$ 为 $(0, 1)$ 之间的随机数。式(15)是反学习的一种新形式, H 函数根据飞蛾的反向位置生成新的反向解。

2.2.2 飞蛾越界镜像策略

MFO 优化过程中,飞蛾按式(12)更新位置,其位置坐标会发生越界情况而不断被置于边界上,不仅降低飞蛾种群的多样性,还容易使算法陷入局部最优,进而影响算法的优化性能。针对这种情况,利用下式更新越界飞蛾:

$$m_{i,j} = \begin{cases} 2L_j - rand() \times m_{i,j} & m_{i,j} \leq L_j \\ 2U_j - rand() \times m_{i,j} & m_{i,j} > U_j \end{cases} \quad (19)$$

式中: $m_{i,j}$ 为第 i 个飞蛾中第 j 维越界位置; L_j, U_j 为第 j 维的取值范围。多次重复操作式(19)可以将 $m_{i,j}$ 映射到维度的范围之内,保证了种群多样性,有效提升 MFO 算法优化性能。

2.3 OMFO 算法描述

OMFO 算法步骤描述如下:

参数初始化:种群规模 ($sizepop$)、维数 (d)、最大迭代次数 ($Max_iterations$)、当前迭代次数 ($Iteration$) 等

```

初始化飞蛾和火焰
While(Iteration <= Max_iterations)
OM = FitnessFunction(M);
按式(13)更新 MFO's 算法火焰数量;
if Iteration == 1
    F = sort(M);
    OF = sort(OM);
else
    F = sort(M_{t-1}, M_t); //t 是当前迭代次数
    OF = sort(OM_{t-1}, OM_t);
end
for i = 1 : sizepop
    for j = 1 : d
        计算 D_i = |F_j - M_i|;
        按式(12)更新 M(i, j);
    end
end
按式(17) - 式(18)计算 A, B;
按式(15)计算 H 函数;
更新 M_i = H;
按式(19)处理越界飞蛾;
End
终止并输出全局最优解飞蛾。

```

3 OMFO-LSSVM 软测量模型

LSSVM 软测量模型关心系统的输入与输出而不必掌握对象的具体内部物理结构。LSSVM 模型参数包括正则化参数 γ 和核宽度 δ , 通过优化技术解决模型参数确定的问题能够有效提升模型预测精度和泛化能力。MFO 算法全局优化性能优异, 基于反学习与飞蛾越界镜像策略改进的 OMFO 算法在高维、多模函数优化中性能更优, 因此采用 OMFO 解决 LSSVM 模型的数对 (γ, δ^2) 的优化选择问题。以每个飞蛾对应的模型参数在训练集上产生的均方误差 (MSE) 作为算法调整 LSSVM 模型的适应度函数, 定义如下:

$$f_{MSE} = \frac{1}{1 + \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (20)$$

式中: y_i 为实际值; \bar{y}_i 为模型的预测值。

基于 OMFO-LSSVM 软测量模型流程主要包括数据准备、模型建立与模型验证三个过程。首先对控制系统进行分析, 确定与被测变量相关的易测变量; 然后采集模型所需实验数据、并对数据进行清洗、选择等预

处理,按一定比例随机确定训练集和测试集;在上述步骤完成后,将采用 OMFO 算法训练 LSSVM 模型。将每个飞蛾的位置映射到 LSSVM 模型,输入样本训练模型,按式(20)计算种群中飞蛾的适应度值,一旦搜索完成,适应度值最大对应的飞蛾位置就是最优模型参数值,以求得的最优参数对构建最优 OMFO-LSSVM 软测量器;最后,将采用测试集进行模型验证,将测试样本输入最优 OMFO-LSSVM 软测量器并获得预测结果,根据结果对模型泛化能力进行分析、评估。

4 仿真实验

汽轮机是火电机组中重要设备之一,包括高、低压缸系统、再热系统、除氧器、凝结水、负荷自动控制等系统,其结构复杂、热工过程常常难以采用机理模型进行准确描述。热耗率是指每产生 1 kWh 的电能所消耗的热量。作为机组最重要指标之一,热耗率指标常用来衡量电厂热经济性。本文采用 OMFO-LSSVM 软测量模型对热耗率值进行仿真预测实验。

以某 600 MW 汽机为研究对象,确定机组负荷、主蒸汽压力与温度、过热蒸汽压力等 12 个易测参数作为软测量模型输入,热耗率作为模型预测值^[12]。从该机组的集散控制系统中采集正常运行的 598 组数据,并离线分析出热耗率值。为研究模型的预测性能,假设离线分析的热耗率是准确的。随机选择 550 组数据作为训练样本,余下的 48 组数据作为测试样本。采用 550 组数据训练模型,得到最优 OMFO-LSSVM 模型,并利用 48 组测试样本进行模型预测,预测结果如图 1 所示。此外,为了验证该模型性能,将其结果与 MFO-LSSVM 和 LSSVM 进行对比。图 2 为 MFO-LSSVM 预测结果。图 3 为 3 个模型的预测误差曲线。




图 1 OMFO-LSSVM 预测曲线

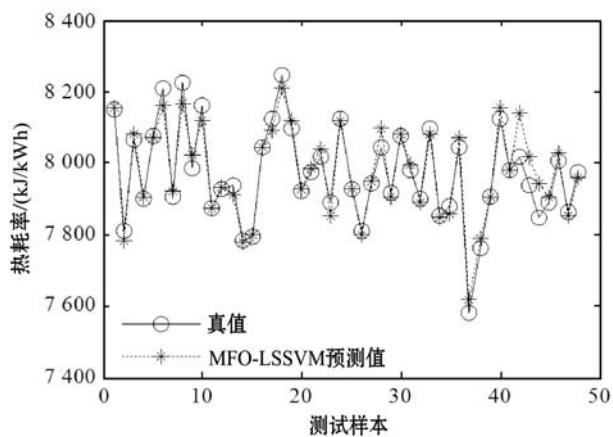


图 2 MFO-LSSVM 预测曲线




图 3 预测误差对比曲线

从图 1 可以看出,OMFO-LSSVM 热耗率预测曲线与真值曲线几乎完全重合,预测误差较小,反映出 OMFO-LSSVM 模型泛化性能优良。从图 2 可以发现,MFO-LSSVM 预测趋势与真值曲线一致,对于样本 6、8、23、42、43、44,MFO-LSSVM 预测误差较大。从图 3 可以看出,LSSVM 模型预测误差曲线波动范围最大,其预测结果最差;经过 MFO 算法优化的 LSSVM 模型误差明显变小,验证了模型参数是模型泛化能力的关键影响因素;OMFO-LSSVM 模型预测曲线波动范围最小,表明 OMFO 搜索优化的模型参数最理想,也进一步验证了 OMFO 算法改进策略的有效性。

表 1 给出了 3 种模型的预测误差指标。可以看出,LSSVM 模型预测精度最差,其最大绝对误差 MAE 达到 149.85 kJ/(kWh),平均绝对百分误差 MAPE 达到 4.52%;均方根误差 RMSE 为 56.72 kJ/(kWh);而 OMFO-LSSVM 模型 3 个指标分别为 33.21、0.11、11.49,均是最小的,表明模型精度最高。综上所述,OMFO-LSSVM 模型在热耗率预测中取得了最佳效果,验证了 OMFO-LSSVM 模型的优越性。

表 1 模型预测性能比较

模型	MAE/(kJ/kWh)	MAPE/%	RMSE/(kJ/kWh)
OMFO-LSSVM	33.21	0.11	11.49
MFO-LSSVM	123.21	0.28	32.88
LSSVM	149.85	4.52	56.72

5 结 语

针对工业过程变量无法或难以直接测量的问题,本文提出一种新的 LSSVM 软测量模型。所提出的模型与反学习 OMFO 算法相结合,采用 OMFO 算法优化选择模型参数,并构建 OMFO-LSSVM 软测量模型。以某 600 MW 汽轮机热耗率预测为案例进行研究,OMFO-LSSVM 模型预测 MAPE 指标达到 0.11%,与 MFO-LSSVM、LSSVM 模型相比,OMFO-LSSVM 模型具有更高的精度。

参 考 文 献

- [1] He Y L, Xu Y, Zhu Q X. Soft-sensing model development using PLSR based dynamic extreme learning machine with an enhanced hidden layer [J]. *Chemometrics and Intelligent Laboratory Systems*, 2016, 154:101 - 111.
- [2] 彭道刚, 陈跃伟, 钱玉良. 基于粒子群优化-支持向量回归的变压器绕组温度软测量模型[J]. *电工技术学报*, 2018, 33(8): 1742 - 1749.
- [3] 周馨, 王国胤, 于洪. 基于改进极限学习机的软测量建模[J]. *计算机应用*, 2017, 37(3): 668 - 672.
- [4] Yin Z Y, Hou J. Recent advances on SVM based fault diagnosis and process monitoring in complicated industrial processes [J]. *Neurocomputing*, 2016, 174: 643 - 650.
- [5] Xiong W, Xu J J, Xiong Z J, et al. Degraded historical document image binarization using local features and support vector machine(SVM) [J]. *Optik*, 2018, 164: 218 - 223.
- [6] Jebarani E S, Suresh Kumar S, Jayakumar J. Torque modeling of Switched Reluctance Motor using LSSVM-DE [J]. *Neurocomputing*, 2016, 211: 117 - 128.
- [7] 李春祥, 丁晓达, 郑晓芬. 基于混合智能优化 LSSVM 的非高斯脉动风速预测[J]. *振动与冲击*, 2017, 36(20): 52 - 58.
- [8] Shui A S, Fang H M, Zong F X. The error prediction of inventory reconciliation during storage and transportation process based on PLS and MFOA-LSSVM [J]. *Journal of Petroleum Exploration and Production Technology*, 2017, 7(3): 895 - 904.
- [9] Mirjalili S. Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm[J]. *Knowledge-Based Systems*, 2015, 89:228 - 249.
- [10] Rebecca N, Mohd H S, Zuriani M. Optimal reactive power dispatch solution by loss minimization using moth-flame optimization technique [J]. *Applied Soft Computing*, 2017, 59: 210 - 222.
- [11] 李龙澍, 翁晴晴. 基于反向学习的自适应差分进化算法[J]. *计算机应用*, 2018, 38(2): 399 - 404.
- [12] 牛培峰, 陈科, 马云鹏. 基于磷虾群算法的汽轮机热耗率建模应用[J]. *动力工程学报*, 2016, 36(10): 781 - 787.

(上接第 224 页)

- [3] Dong C, Loy C C, He K, et al. Learning a Deep Convolutional Network for Image Super-Resolution [C]// *European Conference on Computer Vision*. Springer, Cham, 2014:184 - 199.
- [4] Dong C, Loy C C, He K, et al. Image Super-Resolution Using Deep Convolutional Networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295 - 307.
- [5] Shi W, Caballero J, Huszar F, et al. Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network [C]// *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE Computer Society, 2016:1874 - 1883.
- [6] 徐冉, 张俊格, 黄凯奇. 利用双通道卷积神经网络的图像超分辨率算法 [J]. *中国图象图形学报*, 2016, 21(5): 556 - 564.
- [7] Kim J, Kwon Lee J, Mu Lee K. Accurate image super-resolution using very deep convolutional networks [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 1646 - 1654.
- [8] Ledig C, Theis L, Huszar F, et al. Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network [C]// *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2017: 4681 - 4690.
- [9] Lim B, Son S, Kim H, et al. Enhanced Deep Residual Networks for Single Image Super-Resolution [C]// *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. IEEE Computer Society, 2017:136 - 144.
- [10] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions [C]// *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2015.
- [11] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition [C]// *IEEE Conference on Computer Vision and Pattern Recognition*. IEEE Computer Society, 2016:770 - 778.
- [12] Yang C Y, Ma C, Yang M H. Single-image super-resolution: a benchmark [M]// *Lecture Notes in Computer Science*. Heidelberg: Springer, 2014, 8692: 372 - 386.