

# 基于 IGSA 优化的 LSSVM 制冷系统故障诊断研究

谢伟, 丁强, 江爱朋, 姜周曙

(杭州电子科技大学 自动化学院, 杭州 310018)

**摘要:** 为提高制冷系统故障诊断的准确率, 提出一种基于改进引力搜索算法 (IGSA) 优化的最小二乘支持向量机 (LSSVM) 的制冷系统故障诊断方法; 首先, 引入粒子群算法的速度更新机制对引力搜索算法进行改进, 增加粒子的记忆性和信息共享能力, 提高了算法的收敛速度和搜索精度; 其次, 利用 IGSA 对 LSSVM 的核参数与正则化参数进行优化, 得到最优的 IGSA-LSSVM 故障诊断模型; 最后, 利用故障模拟实验台模拟制冷系统的 4 种典型故障, 将优化好的 LSSVM 模型对其进行分类识别, 并与标准 LSSVM、GSA-LSSVM 和 PSO-LSSVM 模型进行比较; 仿真结果表明, 基于 IGSA 优化的 LSSVM 方法具有良好的辨识能力和泛化能力, 能够更好地对制冷系统故障进行诊断。

**关键词:** 最小二乘支持向量机; 故障诊断; 引力搜索算法; 分类模型; 参数优化

## Fault Diagnosis of LSSVM Refrigeration System Based on IGSA Optimization

Xie Wei, Ding Qiang, Jiang Aipeng, Jiang Zhoushu

(College of Automation, Hangzhou Dianzi University, Hangzhou 310018, China)

**Abstract:** To improve the diagnosis accuracy of refrigeration system faults, an optimized Least Squares Support Vector Machine (LSSVM) based fault diagnosis method using the improved gravity search algorithm (IGSA) was proposed. Firstly, to increase the memory and information sharing ability of the particles, the gravitational search algorithm was further developed using the speed updating mechanism in particle swarm optimization algorithm, so that its calculation convergence and the search accuracy were improved. Through optimizing the kernel parameters and regularization parameters of LSSVM using IGSA, the proposed IGSA-LSSVM fault diagnosis model was then developed. Finally, using the experimental data obtained from a real refrigeration system, four typical faults of the refrigeration system were successfully identified by the optimized IGSA-LSSVM model. The fault diagnosis results, in comparison with that using the standard LSSVM, GSA-LSSVM and PSO-LSSVM models, showed that the proposed IGSA-LSSVM method was better as expressed in terms of its identification ability and generalization ability.

**Keywords:** LSSVM; fault diagnosis; GSA; classification model; parameter optimization

## 0 引言

空调制冷设备已经逐渐成为人们追求舒适环境的必需品。然而制冷系统结构复杂, 工作环境特殊, 加上缺少定期维护与检修, 使得制冷设备常常“带障”运行。制冷系统一旦发生故障, 将会导致系统运行效率低下, 能源成本增加, 用户舒适度下降, 部件磨损加剧等问题<sup>[1]</sup>。因此, 对制冷系统的故障进行早期的检测与诊断显得尤为重要。

近些年来, 研究人员针对制冷系统结构复杂、非线性程度高等特点, 提出了许多基于数据驱动的方法来对其进

行故障诊断<sup>[2]</sup>。常见的有主元分析、神经网络等<sup>[3-4]</sup>。其中神经网络方法应用较为广泛, 但传统神经网络存在训练模型需要的数据量大, 收敛速度慢, 精度不高等缺点。

支持向量机 (Support vector machine, SVM) 是一种基于结构风险最小化原则的机器学习方法<sup>[5]</sup>, 能够很好地平衡模型的性能影响很大, 使用较多的网格法与梯度下降法<sup>[7]</sup>寻优时间长, 收敛精度不高, 难以获得最优的分类模型。目前, 利用粒子群 (PSO)、遗传 (GA)、引力搜索 (GSA) 等启发式算法对 LSSVM 的参数进行寻优是研究的热点。胡天琪等<sup>[8]</sup>用改进的粒子群算法优化 LSSVM, 在模

收稿日期: 2018-09-04; 修回日期: 2018-10-22。

**作者简介:** 谢伟 (1993-), 男, 江西吉安, 硕士研究生, 主要从事故障检测与诊断技术方向的研究。

江爱朋 (1976-), 男, 山东济宁, 博士, 教授, 主要从事大规模复杂过程系统建模、优化与控制方向的研究。

姜周曙 (1964-), 男, 浙江温州, 博士, 教授, 主要从事检测技术与自动化装置方向的研究。

拟电路的故障诊断中验证了方法的有效性。周竹等<sup>[9]</sup>用遗传算法对LSSVM的参数寻优,提高了霉变板栗的识别率。Yuan等<sup>[10]</sup>建立基于LSSVM的短期风力预测模型,并用引力搜索算法对模型参数进行寻优,提高了预测精度。

研究表明,相较于GA和PSO算法,GSA在收敛性能上有一定的优势<sup>[11]</sup>。然而基本GSA仍然存在早熟收敛,易陷入局部最优等问题<sup>[12]</sup>,依然需要对其加以改进,提高搜索性能。本文在标准GSA的基础上,引入PSO的局部搜索能力和粒子的速度更新机制,改进算法的速度公式,并将改进的引力搜索算法用于LSSVM的参数优化中,建立一种IGSA-LSSVM的制冷系统故障诊断模型。将建立好的模型用于风冷热泵机组故障模拟实验中,结果验证了算法的有效性和优越性。

## 1 基本原理

### 1.1 最小二乘支持向量机(LSSVM)

设训练集 $\{(x_i, y_i)\}, i=1, 2, \dots, N, x_i \in \mathbf{R}^d$ , 其中 $x_i$ 是第 $i$ 个输入变量, $y_i$ 是相应的类别, $d$ 为样本个数。原空间的函数优化问题为:

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

$$s. t: y_i [w^T \varphi(x_i) + b] = 1 - e_i, i = 1, \dots, N$$

式中, $\gamma$ 为惩罚因子,用来平衡模型的复杂性和训练误差,选取合适的 $\gamma$ 可以使模型具有良好的泛化能力; $e_i$ 为误差量; $b$ 为截距; $w$ 为法向量; $\varphi(i)$ 为映射函数,将输入空间的内积 $x_i \cdot x_j$ 转换为特征空间的内积 $\varphi(x_i) \cdot \varphi(x_j)$ <sup>[13]</sup>。

引入Lagrange函数:

$$L(w, b, e; \alpha) = J(w, e) - \sum_{i=1}^N \alpha_i \{y_i [w^T \varphi(x_i) + b] - 1 + e_i\} \quad (2)$$

式中, $\alpha_i$ 为Lagrange乘子,分别对 $w, b, e, \alpha_i$ 求偏导,计算得到关于 $\alpha$ 和 $b$ 的线性方程组:

$$\begin{bmatrix} 0 & E^T \\ E & \Omega + E\gamma^{-1} \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (3)$$

式中, $E = [1, 1, \dots, 1]^T; \alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]^T; y = [y_1, y_2, \dots, y_n]^T; \Omega_{N \times N}$ 为核矩阵。 $\Omega_{ij}$ 可由下式计算:

$$\Omega_{ij} = \langle \varphi(x_i) \cdot \varphi(x_j) \rangle = \varphi(x_i)^T \varphi(x_j) = K(x_i, x_j), i, j = 1, \dots, N \quad (4)$$

目前核函数 $K(x_i, x_j)$ 主要根据经验选取,常用的有Poly核函数, Sigmoid核函数以及RBF核函数等<sup>[14]</sup>。本文选用RBF核函数: $K(x_i, x_j) = \exp(-\frac{\|x_i - x_j\|^2}{2\sigma^2})$ , 其中

核宽 $\sigma$ 决定函数的作用范围。解方程组(3)可以得到一组 $\alpha$ 和 $b$ , 最后得到LSSVM的分类表达式:

$$y(x) = \text{sign} \left[ \sum_{i=1}^N \alpha_i y_i K(x, x_i) + b \right] \quad (5)$$

由上述可知, 选取RBF核的LSSVM分类模型有两个

参数需要确定, 即约束条件中的系数 $\gamma$ 以及核宽 $\sigma$ , 它们的选取对LSSVM的性能有很大影响。

### 1.2 引力搜索算法(GSA)

GSA是一种新颖的启发式算法, 由Rashedi等人于2009年根据万有引力现象而提出<sup>[11]</sup>。在GSA中, 每个粒子对应着一种解决方案, 所求问题的解则由粒子的位置表示。粒子之间通过万有引力作用而移动, 其中质量越大的粒子拥有的吸引力更大, 而且移动速度也要更慢。最终所有粒子聚集在质量最大的粒子周围, 其位置对应着最优解。

设系统有 $N$ 个粒子, 定义粒子 $i$ 的位置 $X_i = (x_i^1, \dots, x_i^d, \dots, x_i^n), i = 1, 2, \dots, N$ , 其中, $x_i^d$ 表示粒子 $i$ 在 $d$ 维空间的位置。在特定时刻 $t$ , 定义粒子 $j$ 作用于粒子 $i$ 上的引力为:

$$F_{ij}^d(t) = G(t) \frac{M_p(t) \cdot M_w(t)}{R_{ij}(t) + \epsilon} (x_j^d(t) - x_i^d(t)) \quad (6)$$

其中: $M_w(t)$ 表示 $j$ 的主动引力质量, $M_p(t)$ 表示 $i$ 的被动引力质量, $G(t)$ 是引力系数, $\epsilon$ 是一个小的常量, $R_{ij}(t)$ 是粒子 $i$ 和粒子 $j$ 之间的欧几里得距离。

适应度函数一旦确定, 相应的引力和惯性质量就可以通过计算得出。用下列方程更新引力和惯性质量:

$$M_w = M_p = M_i = M_i, i = 1, 2, \dots, N$$

$$m_i(t) = \frac{fit_i(t) - \omegaorst(t)}{best(t) - \omegaorst(t)}$$

$$M_i(t) = \frac{m_i(t)}{\sum_{j=1}^N M_j(t)} \quad (7)$$

$fit_i(t)$ 为粒子 $i$ 在 $t$ 时刻的适应度值, 求解最小适应度值时, $\omegaorst(t)$ 和 $best(t)$ 的定义如下:

$$best(t) = \max_{j \in \{1, \dots, N\}} fit_j(t)$$

$$\omegaorst(t) = \min_{j \in \{1, \dots, N\}} fit_j(t) \quad (8)$$

为了让算法具有随机特征, 设 $d$ 维上施加于 $i$ 的合力为由其他粒子施加的引力分量的随机加权和:

$$F_i^d(t) = \sum_{j=1, j \neq i}^N rand_j F_{ij}^d(t) \quad (9)$$

$rand_j$ 是 $[0, 1]$ 之间均匀分布的随机数。

根据运动定律, 粒子 $i$ 的加速度 $a_i^d(t)$ 为:

$$a_i^d(t) = \frac{F_i^d(t)}{M_i(t)} \quad (10)$$

$M_i(t)$ 是第 $i$ 个粒子的惯性速度。

在 $t+1$ 时刻, 粒子 $i$ 的位置和速度可以表示如下:

$$v_i^d(t+1) = rand_i \cdot v_i^d(t) + a_i^d(t) \quad (11)$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \quad (12)$$

### 1.3 改进的引力搜索算法(IGSA)

尽管GSA具有良好的优化性能, 但是从式(11)和(12)可以看出, GSA的位置和速度更新只考虑了粒子当前的状态, 即没有记忆性<sup>[15]</sup>。而当算法迭代运行到后期时, 靠近近视最优解的粒子质量都基本相同, 此时粒子的运动

将十分缓慢，算法发生了停滞现象。本文提出的 IGSA 是在标准 GSA 的基础上，引入 PSO 的局部搜索能力和粒子的速度更新机制，使得算法在维持搜索群体多样性的同时，还能改善搜索效果。

改进后的粒子运动方程为：

$$v_i^d(t+1) = \omega v_i^d(t) + c_1 \cdot rand \cdot a_i^d(t) + c_2 \cdot rand \cdot (g_{best}^d - x_i^d(t)) \quad (13)$$

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \quad (14)$$

其中  $d$  为空间维数； $v_i^d(t)$  表示粒子  $i$  在  $t$  时刻的速度； $\omega$  为权重系数； $rand$  为  $[0, 1]$  之间的随机数； $c_1, c_2$  为学习因子，均为正数，表示引导每个粒子分别朝向个体最佳和群体最佳位置的加速项的权重，选取适当的值可使系统不易于陷入局部最优； $g_{best}$  为历史全局最优解。

为了验证改进算法的有效性，选取 3 个经典的基准函数来进行测试<sup>[16]</sup>。

$$f_1(x) = \sum_{i=1}^n x_i^2, x_i \in [-100, 100] \quad (15)$$

$$f_2(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos \frac{x_i}{\sqrt{i}} + 1, x_i \in [-600, 600] \quad (16)$$

$$f_3(x) = \sum_{i=1}^{11} [a_i - \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4}]^2, x_i \in [-5, 5] \quad (17)$$

为了公平起见，GSA 和 IGSA 的参数均设为：搜索空间的粒子数  $N = 30, c_1 = 0.5, c_2 = 1.5, \omega$  为区间  $[0, 1]$  内的随机数，最大迭代次数均为 1 000 次。GSA 和 IGSA 分别单独运行 30 次，获得 3 个测试函数的最优值和平均值，并计算出标准差，详细结果见表 1， $f_1(x), f_2(x)$  和  $f_3(x)$  的迭代曲线图如图 1 所示。

从图 1 可以看出 IGSA 在优化三个测试函数的表现上均优于 GSA，有更快的收敛速度和更高的收敛精度。这是因为 IGSA 引入了历史全局最佳适应值  $g_{best}$ ，惯性质量大的粒子受到  $g_{best}$  的引导，朝着全局最优解的方向移动，较好地解决了 GSA 后期算法停滞的问题。这为 IGSA 用于 LSSVM 的参数进行优化提供了依据。

表 1 GSA 和 IGSA 优化结果对比

测试函数	算法	最优值	平均值	标准差
$f_1(x)$	GSA	5.9385e-17	1.0618e-16	3.8366e-17
	IGSA	1.8491e-19	2.644e-19	6.485e-20
$f_1(x)$	GSA	4.9301	7.3955	1.5246
	IGSA	0.0122	0.0471	0.023598
$f_1(x)$	GSA	1.5e-3	1.83e-3	8.7331e-4
	IGSA	4.9365e-4	6.2396e-4	4.8063e-4

### 1.4 基于 IGSA 的 LSSVM 参数优化

LSSVM 模型构建的过程中将分类的错误率（误分率）作为适应度函数，以误分率最小化为优化目标，最优值对应的参数组合  $\gamma$  即为 LSSVM 模型的最优参数，具体步骤

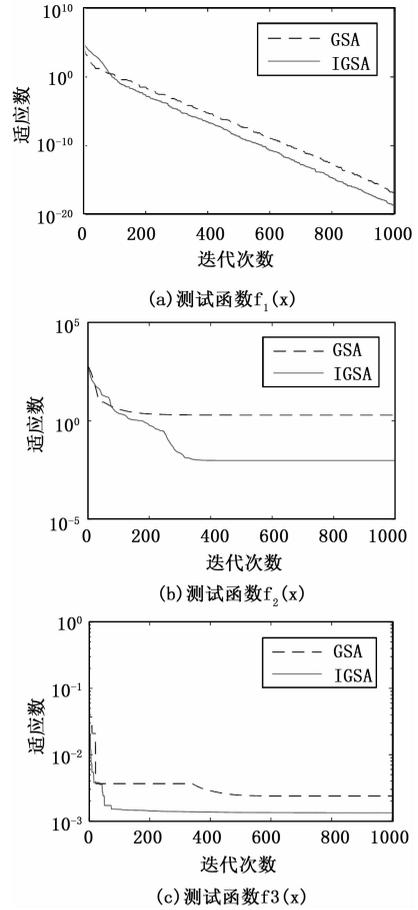


图 1 GSA 与 IGSA 优化迭代曲线对比

如下。

Step1: 随机生成初始种群并初始化 LSSVM 的参数  $\gamma$ ，初始化粒子数  $\gamma$ ，最大迭代次数  $\gamma$ ，学习因子  $\gamma$ ， $\gamma$ ，确定搜索空间；

Step2: 输入训练样本，对数据进行预处理及归一化，将初始化得到的  $\gamma$  对训练集进行 LSSVM 学习，并将分类的错误率作为 IGSA 的适应度函数，计算每个粒子的适应值；

Step3: 根据公式 (7)，(8) 计算  $\gamma, \gamma$ ，和  $\gamma$ ；

Step4: 根据公式 (10) 计算  $\gamma$ ；

Step5: 根据公式 (13)，(14) 更新粒子的速度与位置即得到的 LSSVM 参数；

Step6: 判断程序是否迭代完成，若否，回到 Step3；若是，则返回最优参数，程序结束。

## 2 实例分析

### 2.1 实验数据采集

本文的研究对象为一台分体式热泵型落地空调器，型号是：KFR-72LW，机组的额定制冷量 7.2 kW，制热量是 8 kW，蒸发器与冷凝器都采用了 R22-空气翅片换热器，节流装置采用热力膨胀阀。在该机组的基础上，依托焓差实验台，搭建故障模拟实验系统。分析除机组正常运行

(类别编号 F0) 的情况外,引入压缩机吸排气串气,四通阀泄漏等 4 种典型单一故障,如表 2 所示。

表 2 故障类别及模拟方法

编号	类别	故障模拟方法
F1	压缩机吸排气串气	在压缩机吸排气端之间安装电子膨胀阀,用 PLC 调节其开度
F2	四通阀泄漏	在四通阀的 D 管和 S 管之间安装电子膨胀阀,用 PLC 调节其开度
F3	室外侧换热器表面积堵塞	用剪好的纸张将换热器表面覆盖住,覆盖面积的大小代表堵塞的程度
F4	制冷剂过少	机组额定运行时,缓慢抽取一定量的制冷剂

在搭建好的故障模拟实验台上,对需要采集的参数进行传感器布点。在实验设计中,一共设置了 22 个采集点位置,分别代表了机组运行的温度、压力等参数。通过数据采集系统,获取机组在制冷工况下运行的原始数据,原始样本数据由 22 个特征参数组成,代表了不同状态下的特征参数的变化,由  $\gamma \sim \gamma$  表示。部分原始样本数据见表 3。

### 2.2 IGSA-LSSVM 诊断模型

基于 IGSA 和 LSSVM 的制冷系统故障诊断模型的构建主要分为两大部分,即 LSSVM 模型的训练,以及将训练好的模型用于故障模式的分类。LSSVM 的两个结构参数  $\gamma$  和  $\sigma$  的选取对诊断模型的性能非常重要,常用的网格法和交叉验证法收敛速度太慢,并且可能达不到全局最优。因此,本文采用 IGSA 算法对参数进行优化。由于标准的 LSSVM 只能解决二类分类问题,而本文需要将制冷系统正常运行及 4 中典型故障进行区分,属于多分类问题。因此,需要将多个 LSSVM 进行组合,常用的组合方法有“一对一”,“一对多”,“有向无环图”等<sup>[17]</sup>,本文采用实际应用广泛的“一对一”分类方法。由于有 5 种类别:正常、压缩机吸排气串气、四通阀泄漏、室外侧换热器表面积堵塞以及制冷

剂过少,需要构建  $5 \times (5-1) / 2 = 10$  个二分类 LSSVM 分类器,最后采用投票的方法来确定故障的类别。

IGSA 优化 LSSVM 的故障诊断过程如图 2 所示,首先,对样本数据进行预处理,并将其分为训练集和测试集;然后,对 IGSA 算法的参数进行初始化,选择核函数构建 LSSVM 模型;接着,按照前文 1.4 节所述,利用 IGSA 对 LSSVM 的参数进行优化获取最优参数;最后,将最优参数和训练集对 LSSVM 模型进行训练,构建最终的故障分类模型,并用测试集对该模型进行验证,分析故障分类结果。

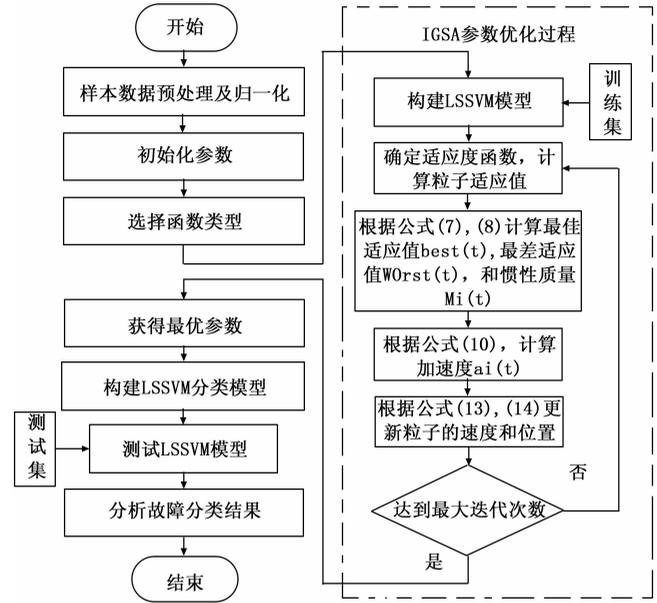


图 2 基于 IGSA 与 LSSVM 的故障诊断过程

### 2.3 诊断结果及分析

在本研究中,利用搭建好的故障模拟实验台采集机组正常运行和模拟故障的数据。原始数据可能存在噪声和异常数据,首先要将其剔除,由于故障特征参数的量纲和数量级可能不同,还需要对数据进行归一化处理。然后在正常运行及 4 种故障的样本数据中随机选取 400 组,其中 300 组作为训练集,用于模型的训练;100 组作为测试集,用于

表 3 部分原始样本数据

GN	故障特征参数										FT
	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>	...	C <sub>19</sub>	C <sub>20</sub>	C <sub>21</sub>	C <sub>22</sub>		
1	8.088	8.875	40.508	37.487	...	1.544	0.411	0.568	0.454	F0	
2	8.096	8.880	40.642	37.503	...	1.545	0.410	0.575	0.453	F0	
3	8.831	9.195	41.186	37.861	...	1.565	0.428	0.586	0.470	F1	
4	8.817	9.192	41.225	37.910	...	1.565	0.428	0.586	0.469	F1	
5	8.878	9.234	40.964	37.697	...	1.556	0.432	0.588	0.474	F2	
6	8.875	9.223	40.576	37.670	...	1.553	0.429	0.585	0.471	F2	
7	8.772	8.871	42.047	40.314	...	1.701	0.435	0.627	0.489	F3	
8	8.785	8.926	42.922	40.246	...	1.718	0.437	0.626	0.487	F3	
9	9.852	9.352	40.934	38.312	...	1.551	0.408	0.567	0.451	F4	
10	9.808	9.312	40.987	38.399	...	1.552	0.408	0.567	0.451	F4	

模型的验证。IGSA 的参数设置为：最大迭代次数  $it_{max} = 200$ ，粒子数  $N = 30$ ， $c_1 = 0.5$ ， $c_2 = 1.5$ ， $\gamma$  和  $\sigma$  的取值范围分别为  $[0, 1000]$  和  $[0, 100]$ 。经过 IGSA 迭代寻优后，得到最优的参数组合： $\gamma = 297.42$ ， $\sigma = 18.25$ 。利用优化好的 IGSA-LSSVM 模型对正常运行及 4 种故障进行区分，故障分类结果如图 3 所示。

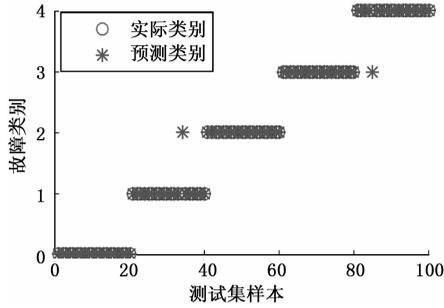


图 3 故障分类结果

从图 3 可以看出，IGSA-LSSVM 模型能够准确地将制冷系统正常运行及 4 种故障进行区分，准确率达到了 98%。为了对比验证本文所提方法的有效性，将其与标准 LSSVM，PSO-LSSVM 以及 GSA-LSSVM 模型进行比较，其中各模型的训练数据及测试数据均与 IGSA-LSSVM 模型一致，PSO 和 GSA 的参数设置均与 IGSA 优化算法相同。具体的诊断性能如表 4 所示。

表 4 故障诊断结果对比

诊断方法	$\gamma$	$\sigma$	准确率/%
LSSVM	60.5	5.0	83.0
PSO-LSSVM	175.46	15.26	90.0
GSA-LSSVM	218.22	20.01	92.0
IGSA-LSSVM	297.42	18.25	98.0

从表 4 可以看出，IGSA-LSSVM 诊断模型性能最好，准确率达到了 98%。表明改进的引力搜索算法对于 LSSVM 的参数寻优能力更强，所得的诊断结果也更为准确。而标准的 LSSVM 模型由于人为选取参数的盲目性，诊断性能最差，准确率只有 83%。同时 GSA-LSSVM 的准确率为 92%，高于 PSO-LSSVM 的 90%，说明 GSA 的寻优能力要强于 PSO。由于标准的引力搜索算法缺少记忆性，容易陷入局部最优，本文提出的 IGSA 算法借鉴粒子群算法中的记忆性思想，改进速度更新机制，能有效地减少振荡，跳出局部最优，获得更优的参数组合，取得更好的故障诊断结果。

### 3 结束语

LSSVM 用于制冷系统故障诊断时，对故障模式的分类性能很大程度上取决于核函数参数和惩罚因子的选取。由于人工设置参数可能导致故障识别不准确，本文提出了一种改进的 GSA 算法来优化参数，建立了 IGSA-LSSVM 的制冷系统故障诊断模型。仿真结果表明，改进的 GSA 能够快

速收敛到全局最优。故障模拟实验表明，IGSA-LSSVM 模型能够对风冷热泵机组的正常运行及 4 种故障进行准确区分，提高了故障诊断的准确率。同时，与标准的 LSSVM，PSO-LSSVM 以及 GSA-LSSVM 模型进行对比，表明了所提方法的优越性，在制冷系统故障诊断方面具有良好的应用前景。

### 参考文献:

- [1] Beghi A, Brignoli R, Cecchinato L, et al. Data-driven Fault Detection and Diagnosis for HVAC water chillers [J]. Control Engineering Practice, 2016, 53: 79-91.
- [2] 文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述 [J]. 自动化学报, 2016 (9): 1285-1299.
- [3] 梁晴晴, 韩华, 崔晓钰, 等. 基于主元分析-概率神经网络的制冷系统故障诊断 [J]. 化工学报, 2016, (3): 1022-1031.
- [4] 肖赋, 王盛卫, 徐新华, 等. 基于主成分分析法的空调系统传感器自动故障诊断 [J]. 建筑科学, 2008 (6): 34-34-39.
- [5] 汪海燕, 黎建辉, 杨风雷. 支持向量机理论及算法研究综述 [J]. 计算机应用研究, 2014, 31 (5): 1281-1286.
- [6] J. A. K. Suykens, J. Vandewalle. Least Squares Support Vector Machine Classifiers [M]. Kluwer Academic Publishers, 1999, 293-300.
- [7] Olivier Chapelle, Vladimir Vapnik, Olivier Bousquet, et al. Choosing Multiple Parameters for Support Vector Machines [J]. Machine Learning, 2002, 46 (1-3): 131-159.
- [8] 胡天骥, 单剑锋, 宋晓涛. 基于改进 PSO-LSSVM 的模拟电路诊断方法 [J]. 计算机技术与发展, 2015 (6): 193-196.
- [9] 周竹, 李小昱, 李培武, 等. 基于 GA-LSSVM 和近红外傅里叶变换的霉变板栗识别 [J]. 农业工程学报, 2011 (3): 331-335.
- [10] Xiaohui Yuan, Chen Chen, Yanbin Yuan, et al. Short-term wind power prediction based on LSSVM-GSA model [J]. Energy Conversion & Management, 2015, 101: 393-401.
- [11] Esmat Rashedi, Hossein Nezamabadi-pour, Saeid Saryazdi. GSA: A Gravitational Search Algorithm [J]. Information Sciences, 2009, 179 (13): 2232-2248.
- [12] 谷文祥, 李向涛, 朱磊, 等. 求解流水线调度问题的万有引力搜索算法 [J]. 智能系统学报, 2010 (5): 411-418.
- [13] 李航. 统计学习方法 [M]. 北京: 清华大学出版社, 2012.
- [14] 张树团, 张晓斌, 雷涛, 等. 基于粒子群算法和支持向量机的故障诊断研究 [J]. 计算机测量与控制, 2008, 16 (11): 1573-1574.
- [15] Mohammad-Ali Ahmadi, Alireza Bahadori. A LSSVM approach for determining well placement and conning phenomena in horizontal wells [J]. Fuel, 2015, 153: 276-283.
- [16] Amarjeet Singh, Kusum Deep, Atulya Nagar. A New Improved Gravitational Search Algorithm for Function Optimization Using a Novel "Best-So-Far" Update Mechanism [J]. 2015: 35-39.
- [17] 李晓宇, 张新峰, 沈兰荪. 支持向量机 (SVM) 的研究进展 [J]. 测控技术, 2006, 25 (5): 7-12.