

基于改进麻雀搜索算法与支持向量机的 光纤陀螺故障诊断

陈 鑫^{1,2}, 肖明清¹, 孙 曜¹, 文斌成¹, 刘双喜², 仇晨阳²

(1. 空军工程大学航空工程学院, 西安, 710038; 2. 94701 部队, 安徽安庆, 246003)

摘要 针对光纤陀螺输出信号噪声成分复杂、故障特征难以提取的问题, 提出一种基于改进麻雀搜索算法与支持向量机的光纤陀螺故障诊断方法。首先, 对光纤陀螺正常信号和故障信号进行 3 层小波包分解以提取特征向量; 其次, 通过引入改进 Logistic 混沌映射和自适应 t 分布策略, 加入边界探索和警戒解除机制, 改进麻雀搜索算法并用于支持向量机参数寻优; 最后, 建立支持向量机模型进行光纤陀螺故障的识别和诊断。经实例分析, 提出的方法可有效用于光纤陀螺故障诊断, 与麻雀搜索算法、灰狼优化算法、粒子群算法、遗传算法和天牛须算法对比, 可有效提高光纤陀螺故障诊断准确率。

关键词 故障诊断; 光纤陀螺; 小波包分解; 麻雀搜索算法; 混沌; 支持向量机; t 分布

DOI 10.3969/j.issn.1009-3516.2021.03.006

中图分类号 V249.32 **文献标志码** A **文章编号** 1009-3516(2021)03-0033-08

A Fault Diagnosis of Fiber Optic Gyro Based on ISSA-SVM

CHEN Xin^{1,2}, XIAO Mingqing¹, SUN Yao¹, WEN Bincheng¹, LIU Shuangxi², QIU Chenyang²

(1. Aeronautics Engineering College, Air Force Engineering University, Xi'an 710038, China;
2. Unit 94701, Anqing 246003, Anhui, China)

Abstract Aimed at the problems that the noise components are complex and the fault features in fiber optic gyro output signals are hard to extract, a fault diagnosis method based on improved sparrow search algorithm and support vector machine (SVM) is proposed. Firstly, the normal and the fault signals of fiber optic gyro are decomposed by three-layer wavelet packet to extract feature vectors. Secondly, by introducing the improved Logistic chaotic map and adaptive t distribution strategy, and adding the boundary exploration and alarm cancellation mechanism, the ISSA is proposed and applied to the parameter optimization of SVM. Finally, a SVM model is established for fault identification and diagnosis of fiber optic gyro. The results show that the method proposed in this paper can be effectively used in fiber optic gyro fault diagnosis, and simultaneously effectively improve the accuracy of fiber optic gyro fault diagnosis compared with the sparrow search algorithm, the gray wolf optimization, the particle swarm optimization, the genetic algorithm and the Beetle Antennae Search.

Key words fault diagnosis; fiber optic gyro; wavelet packet decomposition; sparrow search algorithm; chaos; support vector machine; t distribution

收稿日期: 2020-01-22

作者简介: 陈 鑫(1995—), 男, 江西萍乡人, 硕士生, 研究方向: 航空武器装备故障诊断。E-mail: 451379925@qq.com

引用格式: 陈鑫, 肖明清, 孙曜, 等. 基于改进麻雀搜索算法与支持向量机的光纤陀螺故障诊断[J]. 空军工程大学学报(自然科学版), 2021, 22(3): 33-40. CHEN Xin, XIAO Mingqing, SUN Yao, et al. Fault Diagnosis of Fiber Optic Gyro Based on ISSA-SVM[J]. Journal of Air Force Engineering University (Natural Science Edition), 2021, 22(3): 33-40.

光纤陀螺因其可靠性高、寿命长、精度覆盖面宽和结构设计灵活等优点而被广泛运用于航空航天和军事装备领域^[1]。作为导航系统的核心部件,其工作状态直接影响着整个导航系统的性能。在复杂的环境下,光纤陀螺不可能完全避免故障的产生,一旦发生故障,就可能导致巨大的损失。因此,研究光纤陀螺的故障状态监测诊断技术,对提高惯性导航设备的性能有着重要的意义^[2]。

目前,针对光纤陀螺的故障诊断已有大量研究。文献[3]基于小波信息熵和反向神经网络提出一种光纤陀螺故障诊断方法,通过实验证明了该方法能够减少光纤陀螺信号噪声,有效识别故障状态;文献[4]运用粒子群算法优化径向基神经网络进行光纤陀螺故障诊断,有效提高了径向神经网络的故障识别能力,实现了对光纤陀螺故障的准确诊断;文献[5]利用卷积神经网络和深度前馈神经网络进行光纤陀螺故障诊断,同单纯的基于深度前馈神经网络的光纤陀螺故障诊断算法相比,具有更高的准确率和更强的泛化能力。但是神经网络存在样本需求量大、训练结果不稳定、易陷入局部最优等问题。

支持向量机(SVM)因其在解决非线性和高维数问题上的优势而被广泛应用于故障诊断领域,与神经网络相比,支持向量机的鲁棒性和泛化能力更强,需求样本更小,且更易趋于全局最优^[6]。然而,利用交叉验证寻优的支持向量机对光纤陀螺进行故障诊断,分类准确率较低,容易造成故障误判。为提高支持向量机的分类性能,已有多种智能算法用于优化支持向量机故障诊断模型,如遗传算法(GA)^[7]、粒子群算法(PSO)^[8]、天牛须算法(BAS)^[9]、灰狼优化算法(GWO)^[10]等。麻雀搜索算法(SSA)是XUE J K 2020年提出的新型群智能算法,与灰狼优化算法、粒子群算法等算法相比,麻雀搜索算法在收敛速度、稳定性和求解精度上有更大的优势和竞争力^[11]。但在接近全局最优解时,麻雀种群多样性减少,易出现“早熟”现象,而使算法陷入局部最优。

针对光纤陀螺信号故障特征难提取及支持向量机在光纤陀螺故障诊断中精度不足的问题,本文提出一种基于改进麻雀搜索算法(ISSA)优化支持向量机的光纤陀螺故障诊断方法。首先,对光纤陀螺正常信号和故障信号进行3层小波包分解以提取特征;其次,通过引入改进 Logistic 映射和自适应t分布策略,并加入边界探索和警戒解除机制改进麻雀搜索算法;最后,运用改进麻雀搜索算法进行支持向量参数寻优,建立优化的支持向量机模型进行光纤陀螺不同故障的识别和诊断。

1 理论基础

1.1 小波包分析

小波包分析能够为信号提供一种精细的分析方法,它将频带进行多层次划分,对多分辨分析没有细分的高频部分进一步分解,并能够根据被分析信号的特征,自适应的选择相应频带,使之与信号频谱相匹配,从而提高了时频分辨率^[12]。

具体的小波包分解过程如图1所示(A表示低频,D表示高频)。

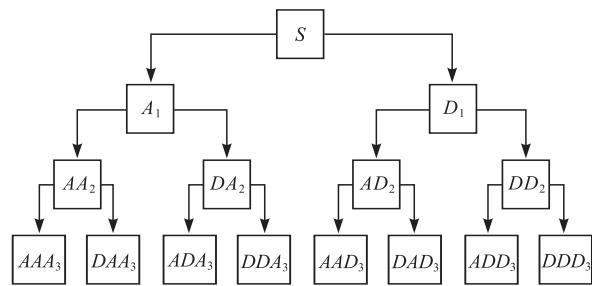


图1 3层小波包变换树

1.2 麻雀搜索算法

麻雀搜索算法是根据麻雀觅食并逃避捕食者的行为而提出的群智能优化算法。搜索过程可抽象为发现者-加入者-警戒者模型。发现者拥有更广阔的搜索范围,负责引导种群觅食,加入者跟随发现者觅食,警戒者负责侦查预警,一旦发现威胁,便放弃当前食物而移动到新的位置。

SSA中发现者、加入者和警戒者更新位置的数学模型依次如下:

$$X_i^{t+1} = \begin{cases} X_i^t \cdot \exp(-\frac{i}{\alpha i_{\max}}), & R_2 < S \\ X_i^t + Q \cdot L, & R_2 \geq S \end{cases} \quad (1)$$

式中: t 表示当前迭代次数; i_{\max} 表示最大迭代次数; X_i 表示麻雀当前的位置信息; $\alpha \in (0, 1]$ 是一个随机数; $R_2 \in [0, 1]$ 表示预警值; $S \in [0.5, 1]$ 表示安全值; Q 是服从正态分布的随机数; L 表示一个一行多维的全一矩阵。

$$X_i^{t+1} = \begin{cases} Q \cdot \exp(\frac{X_w^t - X_i^t}{i^2}), & i > \frac{n}{2} \\ X_b^{t+1} + |X_i^t - X_b^{t+1}| \mathbf{A}^+ \mathbf{L}, & i \leq \frac{n}{2} \end{cases} \quad (2)$$

式中: X_b 是目前发现者的最优位置; X_w 则表示全局最差位置; \mathbf{A} 表示一个一行多维矩阵,其中每个元素随机赋值为1或-1,并且 $\mathbf{A}^+ = \mathbf{A}^\top (\mathbf{A}\mathbf{A}^\top)^{-1}$ 。

$$X_i^{t+1} = \begin{cases} X_b^t + \beta \cdot |X_i^t - X_b^t|, & f_i > f_B \\ X_i^t + u \cdot (\frac{|X_i^t - X_w^t|}{(f_i - f_w) + \sigma}), & f_i = f_B \end{cases} \quad (3)$$

式中: X_B 是当前全局最优位置; β 为步长参数,是服从均值为0,方差为1的正态分布随机数; $u \in [-1, 1]$ 是一个随机数; f_i 代表当前麻雀的适应度值; f_B 和 f_w 分别是当前全局最佳和最差适应度值; σ 是一个避免分母为0的极小常数。

算法流程见图2。

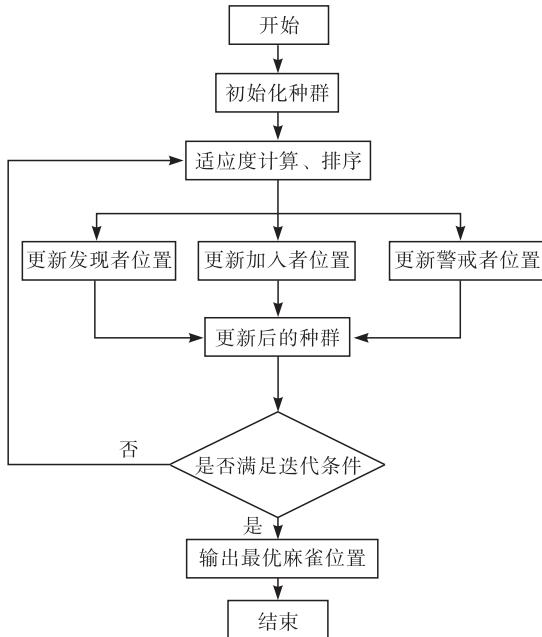


图2 麻雀搜索算法流程图

1.3 改进麻雀搜索算法

针对SSA在求解工程优化问题时,容易陷入“早熟”而导致收敛精度低,且易陷入局部收敛的特点,提出一种改进麻雀搜索算法。针对算法初值对算法影响大的问题,利用改进Logistic映射进行种群初始化,增加初始种群的均匀性;引入边界探索机制和警戒解除机制,增强算法的边界寻优能力,减少算法的运算时间;针对算法末期易陷入停滞问题,使用自适应 t 分布增强麻雀种群的多样性,提高算法的寻优能力。

1.3.1 改进 Logistic 映射

混沌现象具有非周期、有界但不收敛以及对初始条件极为敏感等特征^[13],被很多学者应用于优化搜索问题,不仅能有效保持种群的多样性,而且有利于避免算法陷入局部最优,改善全局搜索能力^[14]。

Logistic映射是目前应用最广泛的一类混沌映射系统,具有随机性、遍历性的特点,能够有效保持种群的多样性,改善算法的搜索能力,其定义为:

$$x_{i+1} = ax_i(1-x_i) \quad (4)$$

式中:初始值 $x_0 \in (0,1)$, $a \in (0,4]$,当 $a \in (3.569, 4]$ 时,系统处于混沌状态,当 $a=4$ 时,Logistic映射处于满映射状态。Logistic映射分岔图如图3。

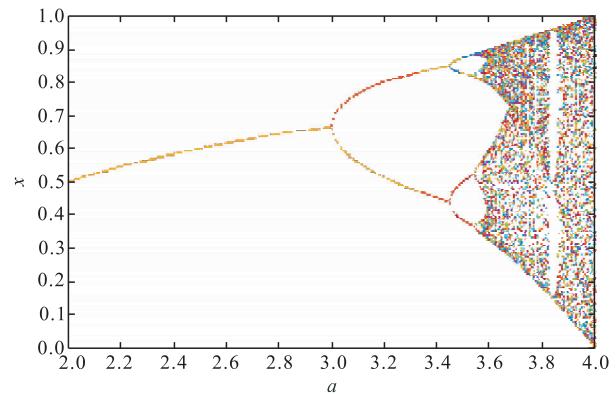


图3 Logistic映射分岔图

满映射状态混沌映射的定义域与值域相同,映射生成的序列具有更强的遍历性,因此,扩大满映射的参数范围能够产生性能更好的初始值。Logistic只有当 $a=4$ 才能达到满映射状态,这就导致了在很大的参数范围内,数据可能相对集中,不利于算法初值随机性的要求。针对这一问题,引入一种二次多项式混沌映射,具体定义如下:

$$x_{i+1} = \frac{a^2 x_i^2}{2} + (a^2 - 2a)x_i + \frac{a^2}{2} - 2a + 1 \quad (5)$$

改进后的映射分岔图见图4。由图4可以看出,改进后的Logistic混沌映射在 $a \in (1.53, 2]$ 范围内,能够很大程度达到满映射状态。

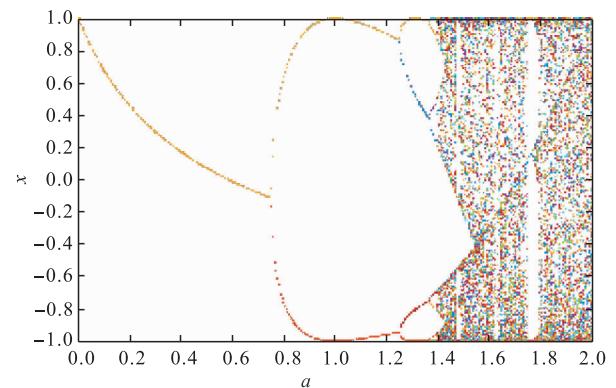


图4 改进 Logistic 映射分岔图

1.3.2 边界探索和警戒解除机制

在SSA中,由于麻雀行为的随机性,麻雀个体很容易越过边界,导致算法进入边界计算,而缺少了对边界区域的探索,可能导致算法陷入局部最优。SSA的边界计算公式为:

$$X_i^{t+1} = \begin{cases} u_b, & X_i^{t+1} > u_b \\ l_b, & X_i^{t+1} \leq l_b \end{cases} \quad (6)$$

式中: u_b 表示边界的上限值; l_b 表示边界的下限值。

针对这个问题,引入一个随机算子,以增强算法的边界搜索能力,从而提高算法的寻优能力,具体公式为:

$$X_i^{t+1} = \begin{cases} u_b - mq, & X_i^{t+1} > u_b \\ l_b + mq, & X_i^{t+1} \leq l_b \end{cases} \quad (7)$$

式中: m 是根据边界大小定义的倍数因子; $q \in (0, 1]$ 是一个随机数。

警戒者的存在能够增强算法的全局搜索能力,但其在迭代过程中数量保持不变,会导致算法后期收敛速度变慢^[15]。因此,在算法运算过程中自适应的改变警戒者的数量,既有利于算法初期的全局搜索,又有利于算法后期的数值收敛,故引入警戒解除机制,使警戒者的数量进行自适应的降低,但为防止种群被破坏,应始终保持数量比例为 p 的警戒者进行侦查预警,具体数学模型为:

$$S_D = \begin{cases} S_D(1 - \frac{t}{i}), & S_D > p \\ p, & S_D \leq p \end{cases} \quad (8)$$

式中: S_D 为警戒者比例。

1.3.3 自适应 t 分布策略

t 分布又称学生分布,含有参数自由度 n ,当 $t(n \rightarrow \infty) \rightarrow N(0, 1)$,当 $t(n=1) = C(0, 1)$,其中 $N(0, 1)$ 为高斯分布, $C(0, 1)$ 为柯西分布,即标准的高斯分布和柯西分布是 t 分布的 2 个边界特例^[16],3 种函数分布图见图 5。

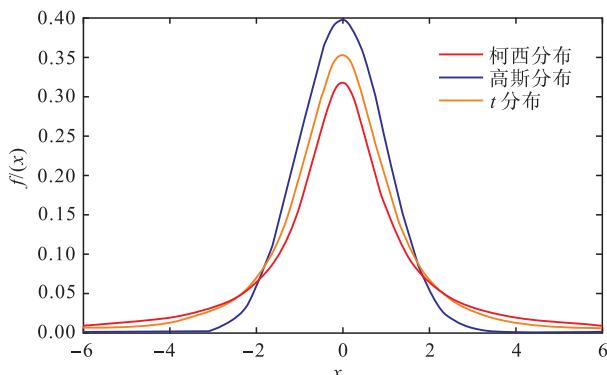


图 5 3 类分布曲线图

t 分布能够充分利用当前种群信息,以迭代次数 t 作为自由度参数,前期 t 较小类似柯西变异具有较强的全局搜索能力,后期 t 较大类似高斯变异具有较强的局部搜索能力,从而提高算法的寻优能力,具体数学模型如下:

$$X_{\text{new}} = X_i + X_i t(i) \quad (9)$$

式(9)在 X_i 的基础上增加了 t 分布型随机干扰项,充分利用当前种群的信息干扰,因此,自适应 t 分布能使麻雀种群跳出局部极值点的束缚,收敛于全局极值点,同时也提高了收敛速度。定义 t 分布变异概率 v ,当满足 $\alpha < v$ 时,进行一次 t 分布变异, v 越大,变异越频繁。

ISSA 具体流程图见图 6。

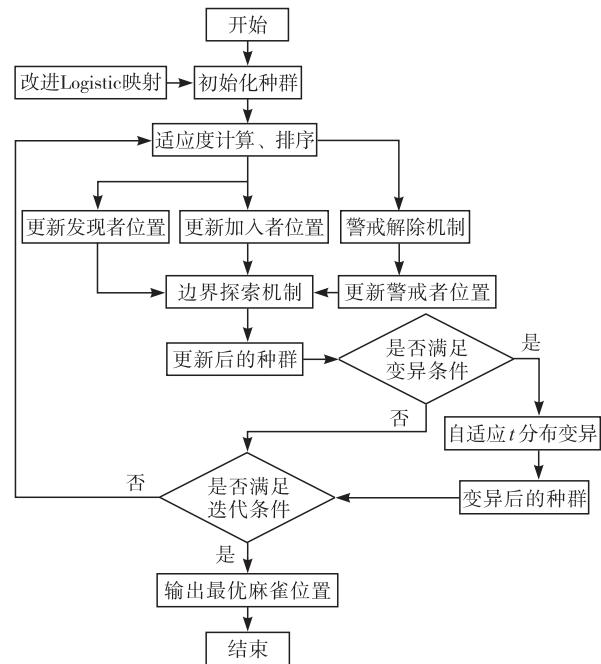


图 6 ISSA 流程图

1.4 支持向量机

支持向量机于 1995 年由 Cortes 和 Vapnik 正式发表^[17]。它最初是针对二分类问题设计的,该模型的求解需要使用凸优化的方法。

图 7 为 SVM 分类示意图。图中 H 是分类面, H_1 和 H_2 为平行于 H 的面。

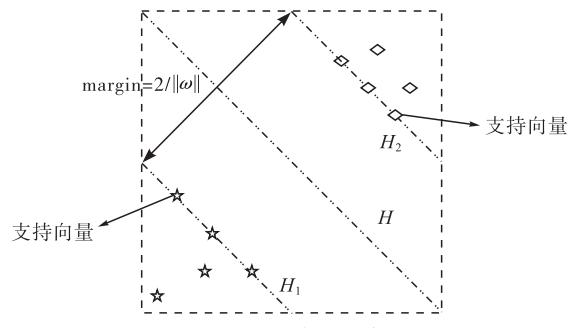


图 7 SVM 分类示意图

2 ISSA-SVM 故障诊断模型

基于改进麻雀搜索算法优化支持向量机故障诊断模型见图 8,模型分为信号输出、数据提取和优化诊断 3 个部分,具体实现过程如下。

1) 建立光纤陀螺信号模型,进行仿真设计。对光纤陀螺的正常状态和故障信号进行小波包分解,并提取子带能量作为特征向量,划分 SVM 的训练集和测试集。

2) 预先设置好改进麻雀搜索算法的参数,将 SVM 的惩罚参数 c 和核参数 g 的取值范围作为麻雀的活动范围,利用改进 Logistic 混沌映射生成麻雀初始种群。

3) 利用改进麻雀搜索算法进行参数寻优,以

SVM 故障诊断准确率为适应度函数进行迭代计算, 将得到的最优参数组合(c, g)导入到 SVM 模型中, 进行光纤陀螺的故障识别和故障诊断。

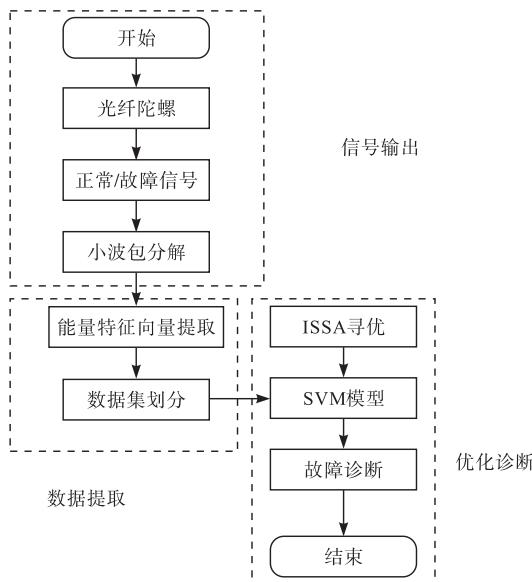


图 8 ISSA-SVM 原理图

2.1 光纤陀螺信号输出

对于光纤陀螺漂移模型, 可以描述为:

$$\epsilon(t) = \epsilon_0 + A \sin(2\pi ft + \theta_0) + \sigma n(t) + \omega(t) \quad (10)$$

式中: $\epsilon(t)$ 为光纤陀螺总漂移; ϵ_0 为光纤陀螺的常值漂移; A 为周期分量的幅值; $\sigma n(t)$ 为强度为 σ 的白噪声; $\omega(t)$ 为有色噪声。

有色噪声 $\omega(t)$ 产生方式为:

$$\omega(t) = 4 \frac{n(k-1) \sin(n(k))}{1+n^2(k-1)} \quad (11)$$

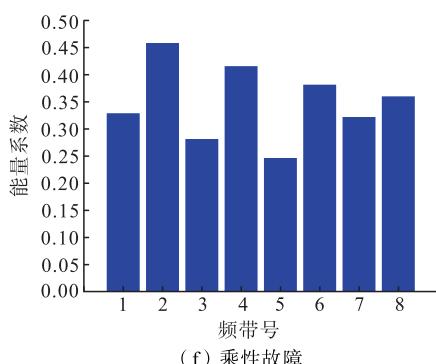
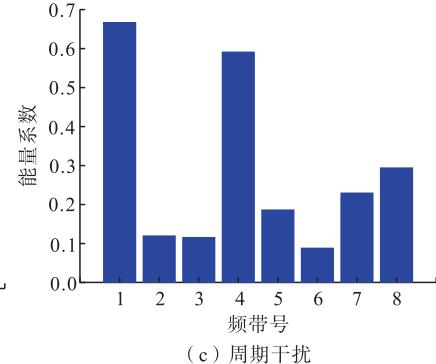
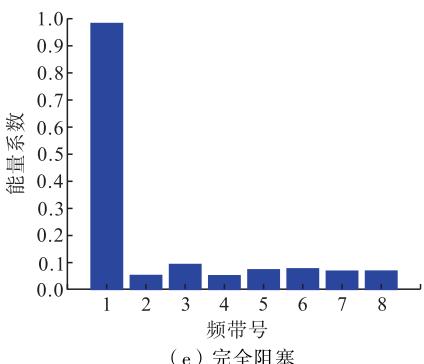
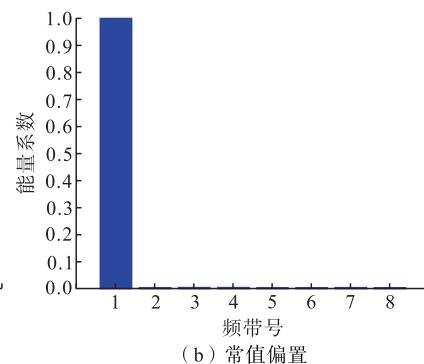
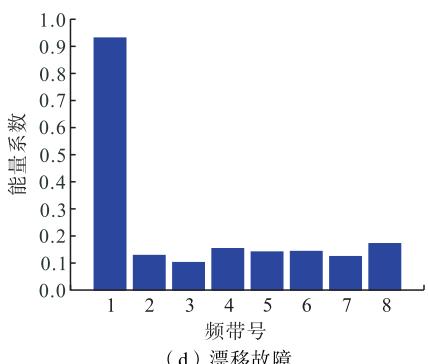
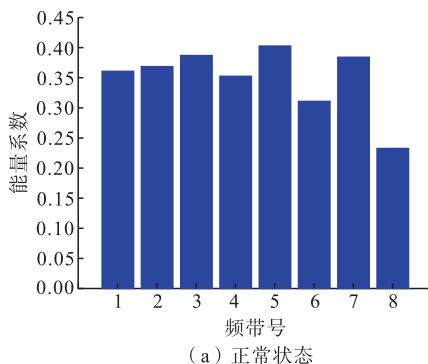


图 9 光纤陀螺各状态能量直方图

光纤陀螺的故障信号一般包括以下几类:

1) 偏置故障

$$y_s = \begin{cases} y(t), & t < t_s \\ y(t) + k, & t \geq t_s \end{cases} \quad (12)$$

式中: k 为偏置常值。

2) 完全阻塞故障

$$y_s = \begin{cases} y(t), & t < t_s \\ y(t_s), & t \geq t_s \end{cases} \quad (13)$$

3) 漂移故障

$$y_s = \begin{cases} y(t), & t < t_s \\ y(t) + Lt, & t \geq t_s \end{cases} \quad (14)$$

式中: L 为漂移速率。

4) 周期干扰故障

$$y_s = \begin{cases} y(t), & t < t_s \\ y(t) + \text{square}(t), & t \geq t_s \end{cases} \quad (15)$$

式中: square 为方波信号。

5) 乘性故障

$$y_s = \begin{cases} y(t), & t < t_s \\ ky(t), & t \geq t_s \end{cases} \quad (16)$$

式中: k 为比例系数。

对光纤陀螺的正常信号和故障信号进行 3 层小波包分解, 小波函数采用 db4, 该函数在满足基本要求的同时能够达到较好的分解效果。图 9 为光纤陀螺正常信号和故障信号经小波包分解和归一化处理后的能量分布直方图。

部分能量特征数据如表 1 所示。

表 1 部分能量特征向量

编号	陀螺状态	能量特征向量							
		0.397 8	0.334 5	0.315 1	0.379 7	0.349 7	0.329 1	0.352 0	0.362 8
1	正常状态	0.359 5	0.312 9	0.318 4	0.360 3	0.312 6	0.384 0	0.333 8	0.429 8
2		0.999 9	0.004 3	0.003 6	0.003 4	0.002 9	0.003 0	0.003 0	0.002 9
3	偏置故障	0.999 9	0.005 6	0.003 2	0.003 2	0.003 1	0.002 8	0.003 3	0.002 6
4		0.982 9	0.057 2	0.076 1	0.058 5	0.084 8	0.074 5	0.066 7	0.063 8
5	完全阻塞	0.983 4	0.081 9	0.055 1	0.081 9	0.057 9	0.076 8	0.054 3	0.064 8
6		0.927 5	0.107 6	0.157 3	0.133 1	0.142 9	0.150 1	0.161 9	0.127 8
7	漂移故障	0.919 3	0.144 7	0.137 9	0.151 9	0.151 5	0.120 5	0.168 6	0.161 4
8		0.691 0	0.134 8	0.140 3	0.559 7	0.217 8	0.097 5	0.188 5	0.280 6
9	周期干扰	0.686 8	0.137 3	0.078 2	0.576 6	0.237 6	0.068 8	0.169 8	0.284 1
10		0.476 1	0.294 1	0.381 3	0.320 5	0.280 8	0.284 7	0.330 9	0.411 2
11	乘性故障	0.426 3	0.339 9	0.406 8	0.253 1	0.325 5	0.324 9	0.410 8	0.304 4
12									

2.2 参数设置

SVM 核函数的作用是对特征进行从低维到高维的转换, 实验使用径向基作为核函数, 具有较高的灵活性。遵循公平原则, 设定各算法的最大迭代次

数为 100, 种群规模设置为 100。设定 SVM 的交叉验证系数为 5, 惩罚系数和核函数参数的寻优范围为 $(0, 100]$ 。实验的 6 种故障诊断模型参数设置见表 2。

表 2 模型参数取值

诊断模型	参数	数值	诊断模型	参数	数值
ISSA-SVM	预警值	0.6	PSO-SVM	加速度常数 1	1.5
	发现者比例	0.7		加速度常数 2	1.7
	警戒者比例	0.2		弹性系数 1	1
	t 分布变异概率	0.5		弹性系数 2	1
	映射参数	2.0		关系因子	0.6
	最小警戒者比例	0.05			
SSA-SVM	预警值	0.6	GA-SVM	代沟	0.9
	发现者比例	0.7		交叉概率	0.7
	警戒者比例	0.2		变异概率	0.05
BAS-SVM	步长因子	0.95	GWO-SVM	搜索维度	2
	初始步长	1.5		随机量 1	$(0, 1]$
				随机量 2	$(0, 1]$

试集为 90 个样本, 具体的诊断准确率见图 10。

3 结果与分析

用标签 $\{0, 1, 2, 3, 4, 5\}$ 依次表示光纤陀螺的正常状态、偏置故障、周期干扰故障、漂移故障、完全阻塞故障和乘性故障。每种状态分别取 35、30 和 25 个样本为训练集, 15、20 和 25 个样本为测试集, 设置 3 组实验。

为进一步说明 SVM 的优势, 分别以 SVM、反向神经网络(BPNN)和径向基神经网络(RBFNN)为分类器, 进行对比实验, 训练集为 210 个样本, 测

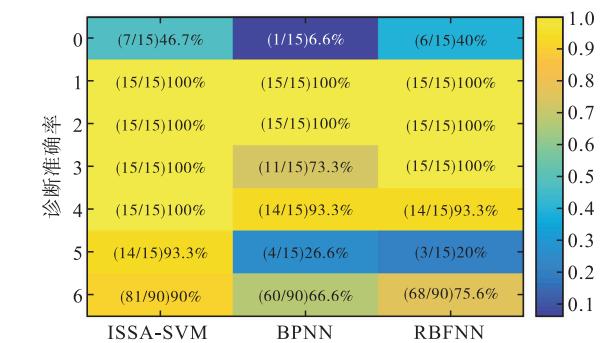
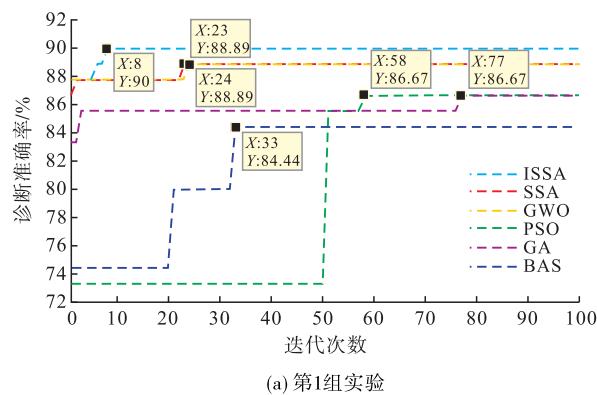


图 10 3 种分类器诊断结果

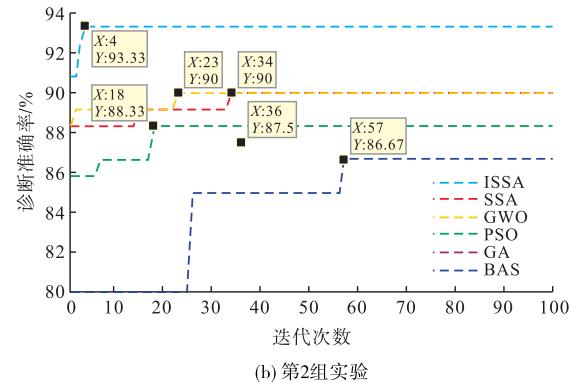
从图 10 可知,相比于 BPNN 和 RBFNN, SVM 能够更精确的识别光纤陀螺的状态,其故障诊断准确率达到了 90%,远高于 BPNN 和 RBFNN,诊断效果更好。而 BPNN 和 RBFNN 由于缺少样本进行训练,出现了欠学习情况。所以,在小样本条件下,SVM 的分类精度更高,能够有效实现光纤陀螺故障诊断。

为验证本文所提算法的优越性,选择 ISSA-SVM、SSA-SVM、GWO-SVM、BAS-SVM、PSO-SVM 和 GA-SVM 故障诊断模型进行对比实验。

图 11 为 3 组实验的模型预测收敛曲线对比。



(a) 第1组实验



(b) 第2组实验

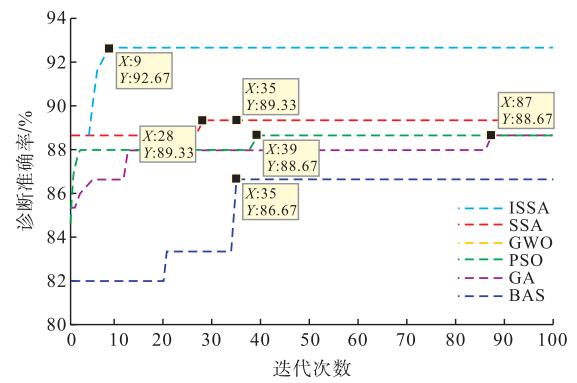


图 11 模型预测收敛曲线

3 组实验诊断结果对比直方图见图 12。

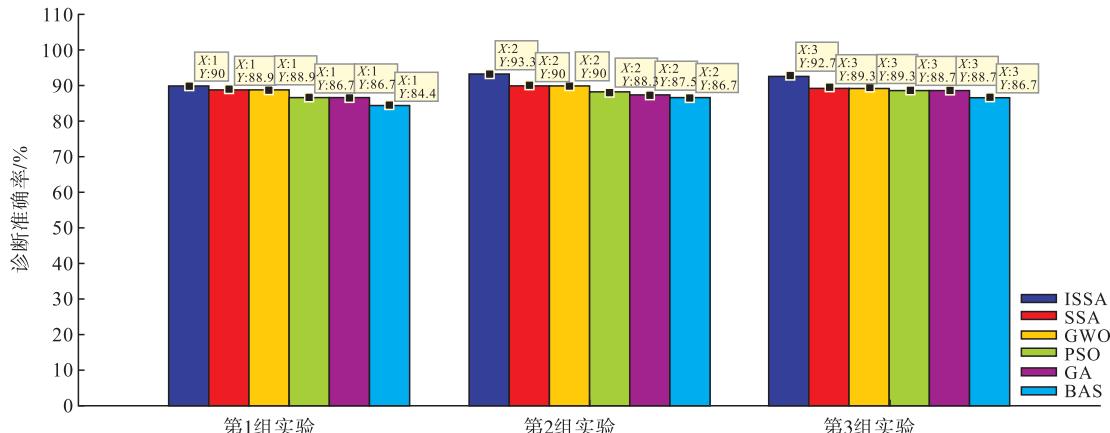


图 12 诊断结果对比

SVM 模型的平均诊断准确率和平均收敛迭代次数见表 3。

表 3 平均诊断准确率和平均迭代次数

模型	诊断准确率/%	收敛迭代次数
ISSA-SVM	92.0	7
SSA-SVM	89.4	28
GWO-SVM	89.4	27
PSO-SVM	87.9	38
GA-SVM	87.6	67
BAS-SVM	85.9	42

由图 11 可知,ISSA 模型拥有更快的收敛速度。在第 1 组实验中,ISSA 模型达到收敛的迭代次数为

8 次,较 SSA 模型、GWO 模型、PSO 模型、GA 模型和 BAS 模型分别加快了 15 次、16 次、50 次、69 次和 25 次。在第 2 组实验中,ISSA 模型达到收敛的迭代次数为 4 次,较 SSA 模型、GWO 模型、PSO 模型、GA 模型和 BAS 模型分别加快了 30 次、19 次、14 次、32 次和 53 次。在第 3 组实验中,ISSA 模型达到收敛的迭代次数为 9 次,较 SSA 模型、GWO 模型、PSO 模型、GA 模型和 BAS 模型分别加快了 19 次、26 次、30 次、78 次和 26 次。ISSA 模型与其他模型相比,能够迅速达到收敛,寻优效率更高。

从图 12 可知,ISSA 模型拥有更高的诊断精度。在第 1 组实验中,ISSA-SVM 相较于 SSA-SVM、

GWO-SVM、PSO-SVM、GA-SVM 和 BAS-SVM, ISSA-SVM 的诊断准确率分别提升了约 1.1%、1.1%、3.3%、3.3% 和 5.6%。在第 2 组实验中, ISSA-SVM 相较于 SSA-SVM、GWO-SVM、PSO-SVM、GA-SVM 和 BAS-SVM, ISSA-SVM 的诊断准确率分别提升了约 3.3%、3.3%、5%、5.8% 和 6.7%。在第 3 组实验中, ISSA-SVM 相较于 SSA-SVM、GWO-SVM、PSO-SVM、GA-SVM 和 BAS-SVM, ISSA-SVM 的诊断准确率分别提升了约 3.4%、3.4%、4%、4% 和 6%。实验结果表明, ISSA 有效提升了麻雀搜索算法的全局寻优能力, 从而提高了 SVM 的诊断准确率。

4 结论

1) 采用小波包分解可以提取故障信号的全部特征, 对故障诊断信息提取更加全面, 不会遗漏高频信号。

2) 将 Logistic 映射和自适应 t 分布引入麻雀搜索算法中, 并提出边界探索和警戒解除机制, 结合而成的 ISSA 具有更强的寻优能力和更快的收敛速度。

3) 本文所提出的 ISSA-SVM 模型, 相较于 SSA-SVM 模型, 诊断准确率提升了约 2.6%, 相较于 GWO-SVM 模型, 诊断准确率提升了约 2.6%, 相较于 PSO-SVM 模型, 诊断准确率提升了近 4.1%, 相较于 GA-SVM 模型, 诊断准确率提升了近 4.4%, 相较于 BAS-SVM 模型, 其准确率提升了近 6.1%。ISSA-SVM 模型为光纤陀螺故障诊断提供了一种新思路, 能够有效诊断出光纤陀螺的故障类型。

参考文献

- [1] 霍雷, 谢良平, 谌尧周, 等. 光纤陀螺的发展与应用[J]. 电子科技, 2015, 28(8): 174-177.
- [2] 李刚, 赵党军, 梁步阁, 等. 飞行器惯性导航陀螺仪故障诊断研究[J]. 计算机仿真, 2019, 36(3): 32-38.
- [3] 朱明. 基于信息熵的导航传感器故障诊断技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2010: 60-72.
- [4] 尹楚雄. 光纤陀螺的测试及智能故障诊断系统的研究[D]. 天津: 中国民航大学, 2013: 15-29.
- [5] 关键. 基于神经网络的光纤陀螺故障诊断技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2019: 47-59.
- [6] 何青, 褚东亮, 毛新华. 基于 EEMD 和 MFPCA-SVM 滚动轴承故障诊断[J]. 中国机械工程, 2016, 27(9): 1191-1197.
- [7] REN Q, YUN W, XUN D, et al. SVM Multi-Classification Optimization Research Based on Multi-Chromosome Genetic Algorithm[J]. International Journal of Reliability Engineering, 2018, 14(4): 631-638.
- [8] 胡云艳, 彭敏放, 田成来, 等. 基于粒子群算法优化支持向量机的模拟电路诊断[J]. 计算机应用研究, 2012, 29(11): 4053-4055.
- [9] 方涛, 钱晔, 郭灿杰, 等. 基于牛火搜索优化支持向量机的变压器故障诊断研究[J]. 电力系统保护与控制, 2020, 48(20): 90-96.
- [10] ZENG B, GUO J, ZHU W, et al. A Transformer Fault Diagnosis Model Based on Hybrid Grey Wolf Optimizer and LS-SVM[J]. Energies, 2019, 12(21): 4170-4187.
- [11] XUE J K, SHEN B. A Novel Swarm Intelligence Optimization Approach: Sparrow Search Algorithm[J]. Systems Science & Control Engineering an Open Access Journal, 2020, 8(1): 22-34.
- [12] NIKOLAOU N G, ANTONIADIS I A. Rolling Element Bearing Fault Diagnosis Using Wavelet Packets [J]. 2002, 35(3): 197-205.
- [13] WU G C, BALEANU D. Chaos Synchronization of the Discrete Fractional Logistic Map[J]. Signal Processing, 2014, 102: 96-99.
- [14] 倪磊, 达新宇, 胡航, 等. 基于改进 Logistic 相位扰码的抗截获通信[J]. 华中科技大学学报(自然科学版), 2019, 47(6): 35-40.
- [15] 汤安迪, 韩统, 徐登武, 等. 基于混沌麻雀搜索算法的无人机航迹规划方法[J/OL]. 计算机应用. <https://kns.cnki.net/kcms/detail/51.1307.TP.20201124.1519.002.html>
- [16] 王波. 基于自适应 t 分布混合变异的人工鱼群算法[J]. 计算机工程与科学, 2013, 35(4): 120-124.
- [17] CORTES C, VAPNIK V. Support-Vector Networks [J]. Machine Learning, 1995, 20(3): 273-297.

(编辑: 姚树峰)