doi:10.3969/j.issn.1671-4172.2023.01.001

基于 CSSA-F-SVM 模型的矿用卡车发动机智能故障诊断

顾清华[1,2,3],王培培[1,2],李学现[1,2],姜秉佼[2,3]

(1. 西安建筑科技大学 管理学院,西安 710055;
2. 西安建筑科技大学 矿山系统工程研究所,西安 710055;
3. 西安建筑科技大学 资源工程学院,西安 710055)

摘　要:针对矿用卡车发动机小样本故障数据导致诊断精度不足的问题,提出了一种基于改进的麻雀搜索算法优化基于凸半径边缘的 SVM 模型(F-SVM)的矿用卡车发动机智能故障诊断方法。首先,针对麻雀搜索算法中全局搜索能力不足的问题引入链式搜索策略。其次,遵循位置最优原则,对加入者位置更新进行改进,以提高其收敛性能。最后,使用改进后的麻雀算法对 F-SVM 的核参数 g 和惩罚因子 C 进行寻优,进而构建矿用卡车发动机故障诊断模型。实验结果表明,本文 CSSA-F-SVM 模型方法的预测准确度更高,分别较传统 SVM 和 F-SVM 模型提高了 21.5%和 4.1%。该模型能够较好地实现矿用卡车发动机常见故障的诊断,适用于小样本数据的故障预测,可为矿山机械设备的智能故障诊断提供参考。

关键词:矿用卡车发动机;小样本;智能故障诊断;参数优化;支持向量机

中图分类号:TP18;TP277;TK44　　**文献标志码**:A　　**文章编号**:1671-4172(2023)01-0001-08

Intelligent fault diagnosis of mining truck engine based on CSSA-F-SVM model

GU Qinghua[1,2,3], WANG Peipei[1,2], LI Xuexian[1,2], JIANG Bingjiao[2,3]

(1. School of Management, Xi'an University of Architecture & Technology, Xi'an 710055, China;
2. Institute of Mine Systems Engineering, Xi'an University of Architecture & Technology, Xi'an 710055, China;
3. School of Resources Engineering, Xi'an University of Architecture & Technology, Xi'an 710055, China)

Abstract: Aiming at the problems that mining truck engine have poor fault diagnosis accuracy in the case of small samples, a mining truck engine intelligent failure diagnosis method based on the improved sparrow search algorithm optimizing convex radius-margin-based SVM model (F-SVM) was proposed. Firstly, a chain search strategy was introduced to solve the problem of insufficient global search ability in the sparrow search algorithm. Secondly, following the principle of optimal location, the location update of the joiners was optimized to improve its convergence performance. Finally, the improved sparrow algorithm was adopted to optimize the kernel parameter g and penalty factor C of F-SVM, and then a fault diagnosis model of mining truck engine was constructed. The experimental results prove that the prediction accuracy of the proposed CSSA-F-SVM model method is higher, which is 21.5% and 4.1% higher than that of the traditional SVM and F-SVM models, respectively. The model can better realize the diagnosis of common faults of mining truck engines. It is suitable for fault prediction of small sample data, and provides a reference for intelligent fault diagnosis of mining machinery and equipment.

Key words: mining truck engine; small sample; intelligent fault diagnosis; parameter optimization; support vector machines

随着“智慧矿山”建设的推进,矿山机械设备运行数据监测能力得到了较大的提升,但大多现有的矿山机械设备监测监控系统停留在传感数据可视化显示和简单阈值分析(信号值超标、超限)

收稿日期:2022-08-25
基金项目:国家自然科学基金资助项目(52074205);陕西省自然科学基础研究计划(2020JC-44)
作者简介:顾清华(1981-),男,教授,博士,矿业工程专业,主要研究方向为多目标优化、机器学习、复杂系统建模及仿真,E-mail:qinghuagu@126.com。

层面,能够对机械设备的运行过程进行监测,但无法识别设备关键部位的早期故障[1]。矿山恶劣的作业环境导致矿用卡车的维修任务占到总维修任务的一半以上,其中发动机故障大约占卡车故障的50%[2]。能够根据矿卡发动机的监测数据对计划维修外的卡车发动机故障进行提前诊断对矿山生产具有重大意义。然而,由于发动机故障维修记录不够完善,实际可以获取的有效故障数据极少,能够在小样本故障数据中实现对发动机的高精度预测是故障诊断的关键。

随着智能化的不断推进,机器学习、深度学习和数据挖掘等技术逐渐被应用到发动机故障诊断当中,如,神经网络[3]、深度网络[4]、随机森林[5]、支持向量机[6]等。周俊博等[3]针对目前拖拉机柴油机故障诊断中单个神经网络模型的局限性,提出一种LWD-QPSO-SOMBP神经网络模型的拖拉机柴油机故障诊断模型;仲国强等[4]为了提高船舶柴油机智能故障诊断的精度,引入深度学习方法,提出了一种基于深度置信网络的船用柴油机智能故障诊断方法;魏东海等[5]针对单一分类器的柴油机常见故障诊断识别效果不理想的问题,探索了一种随机森林分类器用于柴油发动机的故障诊断。然而神经网络由于具有较多的网络参数,更适用于大样本数据集,在样本数量有限的情况下,神经网络算法往往表现出较差的泛化能力;基于深度理论的故障诊断方法对大规模的复杂数据往往会有更准确的识别效果,对复杂设备的故障诊断有天然优势[7],但往往训练速度较低,导致预测效率不高;随机森林算法受决策树数量的影响,对噪声较大的数据集容易陷入过拟合,会导致预测效果不佳。相较于以上方法,支持向量机有参数少、模型简单等特点,且泛化能力优秀,能够在有限的样本中找到尽可能多的信息,适用于小样本数据的学习,符合矿用卡车发动机实际故障数据不足的特点。2018年,WU等[8]提出了一种基于凸半径边缘的F-SVM模型,通过结合主成分分析,将特征变换和SVM分类器的联合学习,实现了数据与分类器的契合,故本文选择F-SVM作为故障诊断的主体模型。然而,对于多分类问题,支持向量机的优劣一定程度上取决于本身惩罚因子C和核参数g的选择,这些参数的选取会影响识别准确率和效率[9],F-SVM模型也面临同样的问题。许多学者的研究已经证明,借助群智能算法对支持向量机模型的参数进行优化,可以显著提高其分类精度,在设备故障诊断领域有了很好的应用。文献[10-12]分别选用PSO、WOA、GA算法对SVM的参数进行寻优,均在故障诊断精度上取得了一定的提升。文献[13]提出了借助果蝇算法对F-SVM进行参数寻优的方法。然而上述算法在全局搜索能力、收敛速度上存在不足,有陷入局部最优的可能,影响诊断模型的精度。麻雀搜索算法(Sparrow Search Algorithm,SSA)[14]具有搜索精度高、收敛速度快、寻优能力强的突出特点,与其他群智能算法相比表现出极强的优势,目前已经应用于各种分类器的参数优化上;曹伟嘉等[15]利用改进后的麻雀算法(JYBack-SSA)优化随机森林,建立了变压器的故障诊断模型;单亚峰等[16]提出利用麻雀算法对AdaBoost-SVM模型进行优化,寻找最优的弱分类器权重和SVM参数;李黄曼等[17]通过改进麻雀算法优化SVM,建立基于DGA的ISSA-SVM故障诊断模型。以上参数优化方法均提高了原始模型的预测精度,可见,麻雀算法在参数优化方面已经取得了很大的成功。

针对矿用卡车发动机故障数据不足而导致诊断精度不高的问题,本文提出了一种基于改进麻雀搜索算法优化F-SVM的矿用卡车发动机故障诊断模型。通过引入链式搜索策略,对麻雀算法进行改进,优化了麻雀发现者和加入者的位置更新过程,提高了原麻雀算法的收敛速度和全局寻优能力。借助改进后的麻雀算法对F-SVM联合模型寻优,构建了CSSA-F-SVM故障诊断模型,通过寻找最合适的惩罚因子和核参数来平衡诊断模型的训练精度和泛化能力,降低了由于样本数据过少产生过拟合现象的可能。将本文模型与原始SVM和用传统SSA、PSO、FOA、EHO算法分别优化SVM和F-SVM的诊断模型对比,实验结果验证了所提方法应用于诊断小样本故障数据时的可行性和高精度。

1 改进麻雀算法优化F-SVM的矿卡发动机故障诊断模型

基于凸半径边缘的SVM模型,即F-SVM,在提高分类精度的同时也实现了将数据的特征提取与SVM相结合。F-SVM模型如下:

$$\min \frac{1}{2}(\omega^{\mathrm{T}} M^{-1} \omega) + C\sum_{i=1}^{n}\xi_i + \rho tr(MSv)$$

$$\text{st.} \quad y_i(\omega^{\mathrm{T}} f_i + b) \geqslant 1 - \xi_i,$$

$$\xi_i \geqslant 0, i = 1, \cdots, n$$
$$\boldsymbol{M} > 0 \tag{1}$$

式中：矩阵 $\boldsymbol{M} = \mathrm{A}^{\mathrm{T}} A$，$A$ 为转换矩阵；$S_v = \sum_{i=1}^{n} \omega_i v_i v_i^{\mathrm{T}}$，$v_i = V^{\mathrm{T}} \varphi(x_i)$，$V = [v_1, v_2, \cdots, v_{D0}]$ 代表第一个特征值的特征向量。对于核 F-SVM，映射函数选用高斯核函数。

对于 F-SVM 模型而言，惩罚因子 C 和核参数 g 的选择在一定程度上决定着 F-SVM 的分类性能和泛化能力，因此选取最合适的参数组合将会极大提高分类精度。本文借助麻雀搜索算法进行参数组合的寻优，并为提高其寻优能力对算法进行改进。

1.1　麻雀搜索算法改进过程

标准的麻雀搜索算法具有设置参数少、寻优能力强等特点，但仍存在种群迭代后期多样性降低、容易陷入局部最优值等不足。本文针对种群中发现者和加入者的位置更新进行改进，引入链式搜索策略以协调发现者的局部搜索和全局搜索的能力，遵循位置最优原则对加入者的位置更新公式进行改进以提高加入者的收敛性能。

1）引入链式搜索策略

在传统麻雀算法中，当 $R_2 < ST$ 时，发现者个体的位置更新是以指数下降的方式急速向零点靠近，每次迭代后的发现者位置都在变小，并以很快的下降速度趋于零，使算法在零点附近有较好的局部搜索能力。但同时，这种搜索方式也导致了麻雀搜索算法在非零附近的搜索能力有限，全局搜索能力不足，有容易陷入局部最优的可能。为了解决以上问题，借鉴樽海鞘算法中领导者位置更新方式，引入链式搜索策略。樽海鞘领导者的相关公式如下：

$$X_j^1 = \begin{cases} F_j + c_1((ub - 1b)c_2 + 1b), & c_3 \geqslant 0.5 \\ F_j - c_1((ub - 1b)c_2 + 1b), & c_3 < 0.5 \end{cases} \tag{2}$$

式中：$X_j{}^1$ 为领导者在第 j 维空间的位置，F_j 为食物在第 j 维的位置，ub 和 $1b$ 分别是对应的上界和下界。c_2 和 c_3 均为[0，1]之间的随机数，用来增强 $X_j{}^1$ 的随机性，可以起到提高链群的全局搜索和个体多样性；c_1 是算法中的收敛因子，由 2 递减到 0，用于平衡全局搜索和局部开发能力。

$$c_1 = 2e^{-(\frac{4l}{L})^2} \tag{3}$$

式中：l 是当前迭代次数，L 是最大迭代次数。

借鉴链式搜索的思想，将麻雀算法中发现者的位置更新改进如下：

$$X^{t+1i,j} = \begin{cases} X_{i,j}^t c^* [(ub - 1b)c_2 + 1b], & if \quad R_2 < ST \\ X_{i,j}^t + QL, & if \quad R_2 \geqslant ST \end{cases} \tag{4}$$

式中：$(ub - 1b)c_2 + 1b$ 可以协调麻雀的全局搜索能力，但直接引入将会导致搜索范围过大，降低发现者的搜索精度和效率，因此需相应增加麻雀向零点靠近的速度，以平衡搜索范围过大的风险。改进后的收敛因子 c^* 表达式如下：

$$c^* = 2\exp\frac{-4l}{(\alpha \cdot L)^2} \tag{5}$$

当周围环境安全时，改进后的发现者既能带领加入者以链式的方式广泛搜索食物，又能实现以更高的搜索效率寻找食物，从而协调了算法的全局搜索和局部搜索的能力。

2）加入者位置更新策略

加入者位置更新策略如下：

$$X^{t+1i,j} = \begin{cases} Q \cdot \exp(\frac{X_{i,j}^t - X_{\mathrm{best}}}{i^2}) & if \quad i > n/2 \\ X_p^{t+1} + |X_{i,j}^t - X_P^{t+1}| \cdot A^+ \cdot L & \text{otherwise} \end{cases} \tag{6}$$

式中：X_{best} 表示当前全局最优的位置。当 $i > n/2$ 时，表明第 i 个加入者适应度较低，为获得更多的能量，需要飞往其它地方觅食，且此时的位置距当前全局最差的位置更近，距离当前全局最优的位置更远。基于此，当加入者进行随机搜索时，遵循位置最优的原则，改进后的加入者会以更快的收敛速度进行位置更新。

在基于改进麻雀搜索算法的参数优化过程中，利用 F-SVM 分类器的分类精度构建合适的适应度函数，指导麻雀位置的更新，并通过麻雀种群个体位置的不断迭代来寻找最优的参数 C、g。

1.2　基于参数优化的 F-SVM 矿用卡车发动机故障诊断过程

本文基于改进的麻雀算法 CSSA 和 F-SVM，建立矿用卡车发动机故障诊断模型，CSSA-F-SVM 模型结合了半径信息和参数优化。如图 1 所示，整个诊断模型可分为两部分：参数优化部分和模型训练及诊断部分。参数优化部分主要是使用分类器精度构造适应度函数来指导麻雀位置的更新，并通过位置的不断迭代来寻找最合适的参数；模型训练及诊断部分是利用参数优化部分得到的最优惩罚因子和核参数建立 F-SVM 分类器，通过该分类器在测试集上得到最终的分类结果。诊断模型具体步骤

如下：

Step 1：采集矿用卡车发动机故障数据，进行归一化处理，并将其划分为训练集和测试集；

Step 2：种群初始化，设置 CSSA 算法的种群规模、最大迭代次数和初始参数；

Step 3：初始化 M 矩阵并将数据集放入特征空间 L 中；

Step 4：利用 SVM 平均交叉验证分类精度计算适应度值，进行迭代寻优，按照式(4)、(6)分别对发现者、加入者进行位置更新；

Step 5：重新计算每个个体的适应度值并进行排序；

Step 6：重复 Step 4 和 Step 5，直至达到最大迭代次数，输出适应度值最好的麻雀位置，

确定最优参数 C、g，利用最优参数建立故障诊断模型，使用十倍交叉验证的方法进行训练。

Step 7：根据训练结果对测试集进行预测，为保证预测结果的可靠性，对测试集进行 $K=5$ 次预测，输出故障诊断结果，并计算平均预测精度。

故障诊断流程图如图 1：

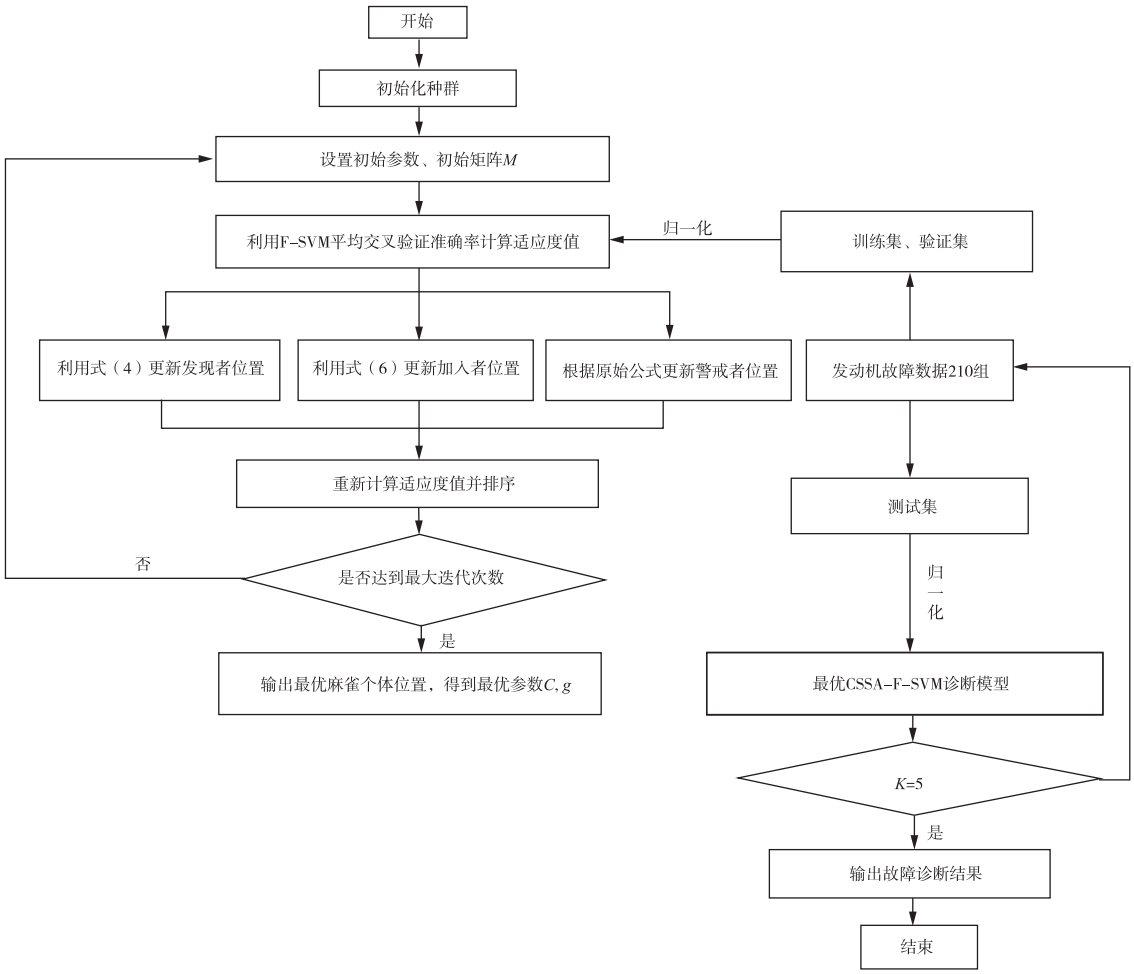

图 1 基于 CSSA-F-SVM 的矿用卡车发动机故障诊断流程图

Fig. 1 Flow chart of fault diagnosis of mining truck engine based on CSSA-F-SVM

2 仿真分析与实验验证

本文以潍柴 WP12G460E310 发动机为研究对象，借助潍柴智多星路谱监测装置采集了河南某露天矿自卸卡车发动机的 210 组 21 维故障数据，来测试 CSSA-F-SVM 的性能。由于矿山作业环境的特殊性，矿用卡车发动机的故障类型主要为滤芯及管道堵塞等故障。本文采集了八种故障类型数据，分别为正常、进气管堵塞、增压器故障、空滤堵塞、中冷器配套故障、燃滤堵塞、中冷器内部堵塞。将所有数据分为训练集 170 组和测试集 40 组，并对训练集采用 10 倍交叉验证的方法进行训练，部分实验数据见表 1，实验数据分类情况及状态编号见表 2。

表 1　潍柴发动机 WP12G460E310 的部分故障数据

Table 1　Partial fault data of Weichai engine WP12G460E310

发动机转速/(r·min^{-1})	车速/(km·h^{-1})	冷却液温度/℃	机油温度/℃	机油压力/hPa	…	进气压力/hPa	轨压设定值/bar	轨压峰值/bar	输出扭矩/(N·m)	扭矩负荷率/%	当前喷油量/mg
1 894	23.79	49.56	52.56	6 132	…	2 021	1 071.20	969.40	525.88	42.58	61.59
1 799	23.19	49.69	53.69	5 974	…	1 651	988.80	957.50	367.28	37.50	45.78
1 683	22.03	49.81	52.83	5 764	…	1 449	1 043.20	1 042.80	580.02	59.77	60.98
1 532	20.48	50.00	55.00	5 611	…	1 392	1 039.50	1 046.80	626.69	63.28	65.22
1 492	18.98	50.19	55.20	5 492	…	1 347	1 060.10	1 058.20	630.86	64.45	77.03
1 402	18.10	50.31	55.32	5 437	…	1 326	1 059.50	1 054.60	762.28	75.00	88.75
1 398	17.29	50.44	55.46	5 377	…	1 321	1 076.00	1 083.90	932.27	81.64	95.55
1 319	16.89	50.63	55.67	5 308	…	1 327	1 073.40	1 090.60	971.78	81.25	109.42
1 315	16.29	50.75	55.75	5 276	…	1 328	1 074.80	1 077.10	917.78	80.47	110.34
1 352	15.89	50.88	55.86	5 281	…	1 322	1 071.40	1 070.90	1 110.25	92.58	106.94

表 2　数据集分类情况

Table 2　Classification of datasets

运行状态	正常	进气管堵塞	增压器故障	空滤堵塞	中冷器配套故障	燃滤堵塞	中冷器内部堵塞
状态编号	1	2	3	4	5	6	7
训练集个数	30	11	19	30	42	24	14
测试集个数	11	3	4	6	5	5	6

2.1　不同算法优化 SVM 性能对比

对训练集进行数据归一化及降维,利用改进麻雀搜索算法(Convergent Sparrow Search Algorithm,CSSA)、麻雀搜索算法(Sparrow Search Algorithm,SSA)、粒子群优化算法(Particle Swarm Optimization,PSO)、象群优化算法(Elephant Herding Optimization,EHO)、果蝇优化算法(Fruit Fly Optimization Algorithm,FOA)对 SVM 进行参数优化,得到最优的 C、g 值。对测试集进行数据归一化后输入优化后的 SVM 模型中进行故障诊断,诊断结果如图 2 至图 7 所示。

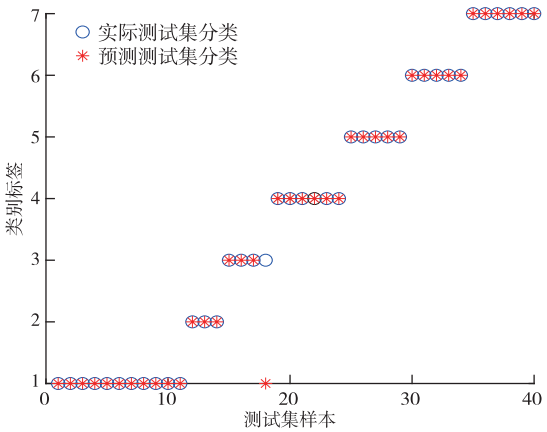

图 2　CSSA-SVM 故障诊断结果(97.5%)

Fig. 2　Fault diagnosis results of CSSA-SVM (97.5%)

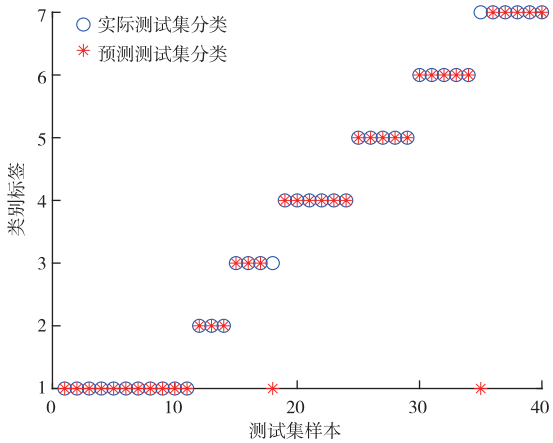

图 3　SSA-SVM 故障诊断结果(95%)

Fig. 3　Fault diagnosis results of SSA-SVM (95%)

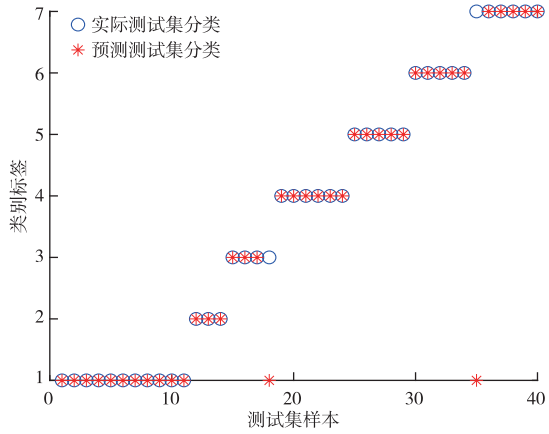

图 4　PSO-SVM 故障诊断结果(95%)

Fig. 4　Fault diagnosis results of PSO-SVM (95%)

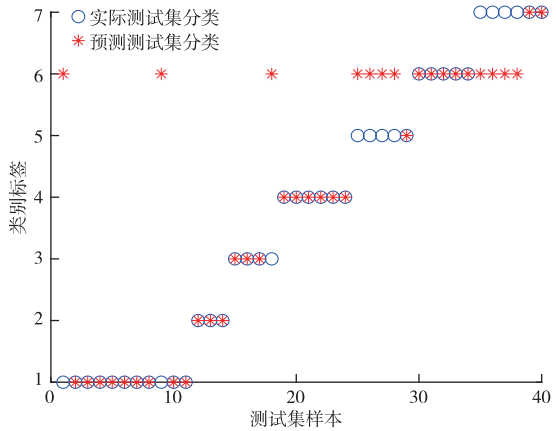

图 5 EHO-SVM 故障诊断结果(72.5%)

Fig. 5 Fault diagnosis results of EHO-SVM (72.5%)

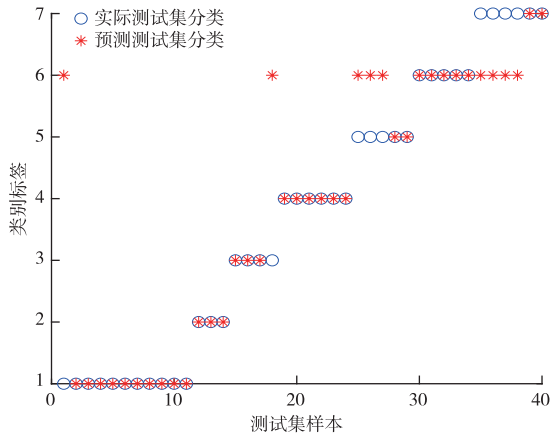

图 6 SVM 故障诊断结果(77.5%)

Fig. 6 Fault diagnosis results of SVM (77.5%)

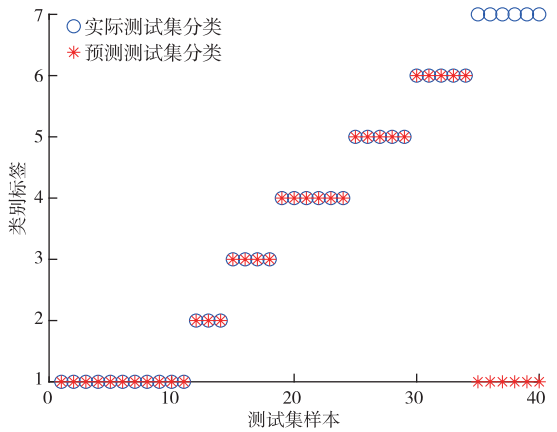

图 7 FOA-SVM 故障诊断结果(85%)

Fig. 7 Fault diagnosis results of FOA-SVM(85%)

通过对比可知,CSSA-SVM 模型对测试集的预测准确度达到最高值 97.5%,均明显高于其他算法优化的 SVM 模型,证明了本文改进的麻雀算法良好的参数寻优能力。此外,CSSA-SVM 模型提高了对燃滤堵塞故障(类别 6)及中冷器内部堵塞故障(类别 7)与其他故障类型的区分准确度,而在增压器故障(类别 3)的诊断上仍存在失误。

2.2 不同算法优化 F-SVM 性能对比

用 CSSA、SSA、PSO、EHO、FOA 算法对 F-SVM 进行参数优化,得到最优的 C、g 值。对测试集进行数据归一化后输入优化后的 F-SVM 模型中进行故障诊断,不同模型运行 5 次的平均对比结果如表 3 所示。

表 3 不同算法优化 F-SVM 故障诊断精确度对比(运行 5 次)

Table 3 Comparison of F-SVM fault diagnosis accuracy optimized by different algorithms(5 runs) /%

诊断模型	FOA-F-SVM	EHO-F-SVM	PSO-F-SVM	SSA-F-SVM	CSSA-F-SVM
平均训练准确率	100	97.06	100	100	100
平均测试准确率	96.25	93.75	96	97.5	99

从平均训练精度和预测精确度来看,不同算法优化 F-SVM 模型的诊断精确度整体高于优化 SVM 模型的诊断精度,CSSA-F-SVM 模型诊断性能更为突出。其中,CSSA-F-SVM 模型分别较 PSO-F-SVM、EHO-F-SVM、FOA-F-SVM、SSA-F-SVM 模型准确精度提高了 3%、5.25%、2.75%、1.5%。

又从表 4 中可知,采用 CSSA 优化的 F-SVM

表 4 CSSA-F-SVM 寻优与诊断结果

Table 4 Optimization and diagnosis results of CSSA-F-SVM

实验次数	CSSA-F-SVM			F-SVM		
	惩罚因子 C	核参数 g	准确率/%	惩罚因子 C	核参数 g	准确率/%
1	0.328 7	0.328 2	100(40/40)	1	0.1	97.5(39/40)
2	0.496 1	0.335 1	100(40/40)	1.056 9	1.034 6	90(36/40)
3	0.364 5	0.349 4	97.5(40/40)	1	0.1	97.5(39/40)
4	0.332 8	1e-04	97.5(39/40)	1	0.1	97.5(39/40)
5	0.346 3	0.558 7	100(39/40)	1.031 3	1.036 0	90(36/40)
平均准确率	——	——	99	——	——	94.9

模型的最高准确率可达 100%，最低为 97.5%，平均准确率 99%；而采用 F-SVM 模型的最高、最低和平均诊断精度分别为 97.5%、90%、94.5%。惩罚因子和核参数均是在一定范围内随机变化的。证明了本文基于改进麻雀算法优化 F-SVM 的模型针对小样本发动机数据进行故障诊断的优秀性能。

由图 8 所示，采用本文模型对各个状态的诊断正确率均可达 100%。对于相同的故障数据，其他四种诊断方法对各状态下的分类结果如表 5 所示。本文所提的方法弥补了对比方法对于发动机进排气系统中冷器内部堵塞、增压器故障和中冷器配套故障诊断效果不足的缺陷，在故障数据有限的条件下，对各种常见故障类型起到了真正的诊断效果。

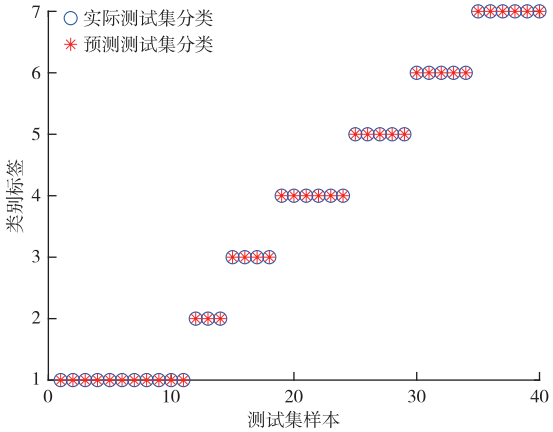

图 8　CSSA-F-SVM 故障诊断结果(单次 100%)

Fig. 8　Fault diagnosis results of CSSA-F-SVM (single result 100%)

表 5　其他算法优化 F-SVM 模型的正确率

Table 5 The correct rate of optimizing the F-SVM model with other algorithms　　/%

模型	正常	进气管堵塞	增压器故障	空滤堵塞	中冷器配套故障	燃滤堵塞	中冷器内部堵塞	平均
FOA-F-SVM	100	100	100	100	100	100	33.33	90.48
EHO-F-SVM	90.91	100	75	100	0	100	83.33	78.46
PSO-F-SVM	100	100	100	100	100	100	83.33	97.61
SSA-F-SVM	90.91	100	100	100	100	100	83.33	96.32

2.3　与其他机器学习方法的对比结果

为了进一步分析本文所提方法在解决矿用卡车发动机小样本故障诊断问题上的优越性，将本文方法与 KNN(K-Nearest Neighbor)、AdaBoost(Adaptive Boosting)、GBDT(Gradient Boosting Decision Tree)传统的机器学习方法做了对比。如图 9 所示，在样本数量相同的情况下，每种方法取 5 次运行的平均结果，本文所提方法的预测精度明显高于其他方法。

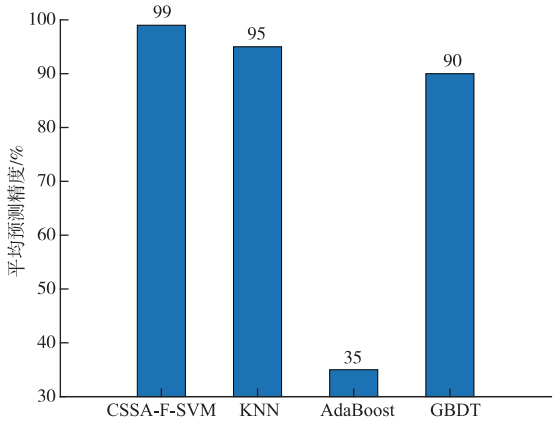

图 9　与其他机器学习方法对比结果

Fig. 9　Comparison results with other machine learning methods

3　结论

本文针对矿卡发动机实际故障数据较少导致诊断精度不足的问题，通过对麻雀算法的改进和对 F-SVM 方法的研究，提出了基于 CSSA-F-SVM 模型的矿用卡车发动机智能故障诊断方法。可得出以下结论：

1)通过改进后的麻雀算法寻找 F-SVM 的最优参数 C、g，降低了参数选择对诊断精度的影响。实验结果表明，基于 CSSA-F-SVM 模型方法的平均诊断准确率为 99%，分别较传统 SVM 和 F-SVM 模型提高了 21.5%和 4.1%。

2)新 CSSA-F-SVM 模型方法克服了其他群智能算法优化 SVM 模型对于中冷器内部堵塞、增压器故障等诊断不足的缺点。能够较好地实现矿用卡车发动机常见故障的诊断，可为实际应用提供一定的参考。

参　考　文　献

[1]　丁恩杰，俞啸，廖玉波，等. 基于物联网的矿山机械设备状态智能感知与诊断[J]. 煤炭学报，2020，45(6)：2308-2319.
DING Enjie，YU Xiao，LIAO Yubo，et al. Key technology of mine equipment state perception and online diagnosis under Internet of Things[J]. Journal of China Coal Society，2020，45(6)：2308-2319.

[2] 田辉. 矿用汽车发动机故障诊断的研究[D]. 兰州:兰州交通大学,2020.
TIAN Hui. Research on fault diagnosis of mine truck engine[D]. Lanzhou:Lanzhou Jiaotong University,2020.

[3] 周俊博,朱烨均,肖茂华,等. 采用LWD-QPSO-SOMBP神经网络的拖拉机柴油机故障诊断[J]. 农业工程学报,2021,37(17):39-48.
ZHOU Junbo, ZHU Yejun, XIAO Maohua, et al. Fault diagnosis of tractor diesel engine based on LWD-QPSO-SOMBP neural network[J]. Transactions of the Chinese Society of Agricultural Engineering,2021,37(17):39-48.

[4] 仲国强,贾宝柱,肖峰,等.基于深度信念网络的船舶柴油机智能故障诊断[J].中国舰船研究,2020,15(3):136-142,184.
ZHONG Guoqiang,JIA Baozhu,XIAO Feng,et al. Intelligent fault diagnosis of marine diesel engine based on deep belief network[J]. Chinese Journal of Ship Research,2020,15(3):136-142,184.

[5] 魏东海,王磊,赵志超,等.随机森林算法在柴油机故障诊断中的应用[J].机械设计与制造,2020(7):63-66.
WEI Donghai,WANG Lei,ZHAO Zhichao,et al. Application of random forest algorithm in fault diagnosis of diesel engine[J]. Machinery Design & Manufacture,2020(7):63-66.

[6] 曹愈远,张建,李艳军,等. 基于模糊粗糙集和SVM的航空发动机故障诊断[J]. 振动·测试与诊断,2017,37(1):169-173,207.
CAO Yuyuan,ZHANG Jian,LI Yanjun,et al. Aero-engine fault diagnosis based on fuzzy rough set and SVM[J]. Journal of Vibration,Measurement & Diagnosis,2017,37(1):169-173,207.

[7] 彭成,李凤娟,蒋金元.基于深度学习的故障诊断与预测方法综述[J].现代电子技术,2022,45(3):111-120.
PENG Cheng,LI Fengjuan,JIANG Jinyuan. Summary of fault diagnosis and prediction methods based on deep learning[J]. Modern Electronics Technique,2022,45(3):111-120.

[8] WU X H,ZUO W M,LIN L,et al. F-SVM:combination of feature transformation and SVM learning via convex relaxation[J]. IEEE Transactions on Neural Networks and Learning Systems,2018,29(11):5185-5199.

[9] 樊红卫,张旭辉,曹现刚,等. 智慧矿山背景下我国煤矿机械故障诊断研究现状与展望[J]. 振动与冲击,2020,39(24):194-204.
FAN Hongwei, ZHANG Xuhui, CAO Xiangang, et al. Research status and prospect of fault diagnosis of China's coal mine machines under background of intelligent mine[J]. Journal of Vibration and Shock,2020,39(24):194-204.

[10] 罗巍,卢博,陈菲,等. 基于PSO-SVM及时序环节的数控刀架故障诊断方法[J]. 吉林大学学报(工学版),2022,52(2):392-399.
LUO Wei,LU Bo,CHEN Fei,et al. Fault diagnosis method of NC turret based on PSO-SVM and time sequence[J]. Journal of Jilin University(Engineering and Technology Edition),2022,52(2):392-399.

[11] 赵春华,胡恒星,陈保家,等. 基于深度学习特征提取和WOA-SVM状态识别的轴承故障诊断[J]. 振动与冲击,2019,38(10):31-37,48.
ZHAO Chunhua,HU Hengxing,CHEN Baojia,et al. Bearing fault diagnosis based on the deep learning feature extraction and WOA-SVM state recognition[J]. Journal of Vibration and Shock,2019,38(10):31-37,48.

[12] 周建民,王发令,张臣臣,等. 基于特征优选和GA-SVM的滚动轴承智能评估方法[J]. 振动与冲击,2021,40(4):227-234.
ZHOU Jianmin,WANG Faling,ZHANG Chenchen,et al. An intelligent method for rolling bearing evaluation using feature optimization and GA-SVM[J]. Journal of Vibration and Shock,2021,40(4):227-234.

[13] GU Q,CHANG Y,LI X,et al. A novel F-SVM based on FOA for improving SVM performance[J]. Expert Systems with Applications, 2020, 165: 113713. DOI: 10. 1016/j. eswa. 2020. 113713.

[14] XUE J,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.

[15] 曹伟嘉,杨留方,徐天奇,等. 基于精英反策略麻雀搜索优化随机森林的变压器故障诊断[J]. 国外电子测量技术,2022,41(2):138-143.
CAO Weijia,YANG Liufang,XU Tianqi,et al. Transformer fault diagnosis based on elite counter strategy sparrow search algorithm optimized random forest[J]. Foreign Electronic Measurement Technology,2022,41(2):138-143.

[16] 单亚峰,段金凤,付华,等.基于SSA-AdaBoost-SVM的变压器故障诊断[J].控制工程,2022,29(2):280-286.
SHAN Yafeng,DUAN Jinfeng,FU Hua,et al. Transformer fault diagnosis based on SSA-AdaBoost-SVM[J]. Control Engineering of China,2022,29(2):280-286.

[17] 李黄曼,张勇,张瑶. 基于ISSA优化SVM的变压器故障诊断研究[J].电子测量与仪器学报,2021,35(3):123-129.
LI Huangman, ZHANG Yong, ZHANG Yao. Study of transformer fault diagnosis based on improved sparrow search algorithm optimized support vector machine[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(3): 123-129.

(编辑:周叶)