

DOI:10.19651/j.cnki.emt.2417657

基于数据增强与 IEVO-GRNN 的飞机引气系统故障诊断*

江佩瑶 王洪亮 吴兴华 王艺霖 麦 舸
(昆明理工大学民航与航空学院 昆明 650500)

摘要: 飞机发动机引气系统是保证飞行安全的关键系统,其故障检测对于维护飞行安全至关重要。本文针对飞机发动机引气系统故障,首先利用改进自适应综合过采样算法(MDADASYN)处理飞机引气系统故障数据不平衡问题。然后,利用佳点集初始化种群、高斯-柯西变异策略和动态调整参数机制改进的多策略改进的能量谷优化算法(IEVO)优化广义回归神经网络(GRNN)进行故障诊断。CEC2014 测试函数结果表明,该融合策略有效增强了算法的种群多样性及全局和局部搜索能力;基于引气系统真实故障数据仿真验证试验表明,基于 MDADASYN-IEVO-GRNN 的引气系统故障诊断模型显著提高了飞机发动机引气系统故障诊断准确率,有助于提升飞机的运行安全和引气系统故障维修效率。

关键词: 故障诊断;发动机引气系统;广义回归神经网络;数据增强

中图分类号: TN707;V267 **文献标识码:** A **国家标准学科分类代码:** 590

Fault diagnosis of aircraft bleed air systems based on data augmentation and IEVO-GRNN

Jiang Peiyao Wang Hongliang Wu Xinghua Wang Yilin Mai Ge

(School of Civil Aviation and Aeronautics, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: The bleed air system of aircraft engines is a critical system to ensure flight safety, and fault detection is essential for maintaining it. This study addressed the fault detection problem of the bleed air system by first using the modified density-adaptive synthetic oversampling algorithm (MDADASYN) to handle the imbalanced fault data. Then, a multi-strategy improved energy valley optimization algorithm (IEVO), enhanced with good point set population initialization, Gaussian-Cauchy mutation strategy, and dynamic parameter adjustment, was applied to optimize the general regression neural network (GRNN) for fault diagnosis. Results from CEC2014 test functions demonstrated that the proposed strategy effectively improved population diversity as well as global and local search capabilities. Simulation experiments based on real fault data from the bleed air system verified that the MDADASYN-IEVO-GRNN fault diagnosis model significantly enhanced diagnostic accuracy for bleed air system faults in aircraft engines, contributing to improved operational safety and maintenance efficiency.

Keywords: fault diagnosis; engine bleed air system; general regression neural network; data enhancement

0 引言

飞机发动机引气系统是保障飞行安全的重要组成部分,其故障检测对于维护飞行安全至关重要。由于B737NG飞机引气系统缺乏故障自检和记录功能^[1],因此实际运行中存在故障率高、排故周期长的问题;且存在引气系统故障数据不平衡的问题。

近年来,利用机器学习方法进行智能故障诊断的模型逐步扩展,比如支持向量机(support vector machine, SVM)^[2]、K最近邻(k-nearest neighbor, KNN)^[3]、极限学习机(extreme learning machine, ELM)^[4]和广义回归神经网络(generalized regression neural network, GRNN)^[5]等。然而,在实际应用中,智能诊断模型在不平衡数据下训练时,容易因故障数据分布不均导致模型过拟合,从而影响其

收稿日期:2024-12-18

* 基金项目:国家自然科学基金(62163021)、云南省基础研究专项(202301AT070420)项目资助

泛化能力。因此,提升数据不平衡情况下的诊断效果,尤其是对少数故障类别的诊断,具有重要的工程应用价值。

目前,利用合成过采样算法(synthetic minority over-sampling technique, SMOTE)和自适应过采样算法(adaptive synthetic sampling, ADASYN)处理数据不平衡问题较为主流。祖璇等^[6]利用 Borderline-SMOTE 算法对心脏病诊断预测模型的训练数据集进行数据增强;郑晓亮等^[7]利用 K-means SMOTE 算法对煤与瓦斯突出预测模型数据进行不平衡处理;然而,相比于 SMOTE 算法,ADASYN 算法更关注少数类和多数类边界处的样本合成,使得合成的样本数据更利于分类器在边界处的学习。刘迪迪等^[8]利用 ADASYN 算法来平衡化变压器故障诊断数据集;余松等^[9]利用 TLR-ADASYN 算法平衡变压器故障诊断模型数据集;传统 ADASYN 通常采用欧几里得距离来生成新样本,这可能会忽视样本间特征的相关性。因此,本文采用马氏距离对其进行改进,能够更好地捕捉数据特征的相关性和协方差结构,从而生成更精确、更具代表性的少数类样本。

GRNN 具有较快的学习能力和较强的处理非线性问题的能力,被广泛应用于故障诊断方面。然而,其性能极大地依赖于其平滑参数^[10]。Wang 等^[11]利用狼群算法优化 GRNN 对模拟电路进行故障诊断,为模拟电路的故障诊断的发展提供了支撑;邹红波等^[12]利用 PSO 对 GRNN 进行优化,对电网分区进行故障诊断;许家才等^[13]利用混沌扰动改进 FOA 算法优化 GRNN 对行星齿轮箱进行故障诊断。由于能量谷优化算法(energy valley optimizer, EVO)具有较快的收敛速度及无特殊参数的优点^[14],于是本文利用 EVO 对 GRNN 进行优化。为进一步提升 EVO 的性能,张嘉辉等^[15]利用混沌映射和二进制对 EVO 进行改进,有效提升了算法的收敛速度和性能;叶馨^[16]利用 sinusoidal 混沌对 EVO 进行改进,有效提升了算法性能;为了提升 EVO 的寻优能力,本文提出改进能量谷优化算法(improved energy valley optimizer, IEVO),该算法结合佳点集初始化、高斯-柯西变异策略及动态参数调整优化的能量谷优化算法对 GRNN 进行优化。通过这些方法的结合,不仅为飞机引气系统的故障诊断提供了新的解决思路,也为其他复杂系统的健康管理技术提供了重要参考。

1 改进 ADASYN 算法

1.1 基本 ADASYN 算法

飞机发动机引气系统的故障报文数据呈现显著的不平衡性,为了解决这一问题,利用 ADASYN 对飞机引气系统故障数据进行数据增强。ADASYN 是 He 等^[17]在 2008 年提出的一种过采样样本合成算法,旨在处理数据不平衡问题的过采样样本合成方法。

该算法通过分析少数类样本的 K 最近邻中的多数类样本数量,确定需要为每个少数类样本生成的合成样本数,

从而针对性地增强少数类样本。具体而言,ADASYN 计算每个少数类样本在所有训练样本中的 K 最近邻,并通过权重分配确定需要生成的新样本数量。对于每个少数类样本,从其 K 最近邻的少数类样本中随机选择一个样本,在两者之间随机插值生成新的数据点。最终,所有生成的样本被加入原始数据集,形成一个更加平衡的新数据集。这种方法特别适用于少数类样本难以区分的情形,有助于提升分类模型的性能和鲁棒性^[9]。

1.2 改进的 ADASYN 算法

尽管 ADASYN 算法能够通过样本与最近邻之间的距离自适应生成合成样本,但其距离计算通常依赖欧氏距离。然而,在存在复杂特征关系或特征尺度差异的数据集中,欧氏距离可能无法准确捕捉样本间的真实相似性。马氏距离是一种有效的度量方式,考虑了数据特征之间的协方差。不同于欧氏距离,马氏距离通过式(1)定义,可以消除特征间尺度的影响,并考虑特征间的相关性:

$$D(\mathbf{x}, \mathbf{y}) = \sqrt{(\mathbf{x} - \mathbf{y})^T \mathbf{S}^{-1} (\mathbf{x} - \mathbf{y})} \quad (1)$$

式中: \mathbf{x} 和 \mathbf{y} 是两个样本向量, \mathbf{S}^{-1} 是数据集的协方差矩阵的逆。

因此,马氏距离改进自适应综合过采样算法(mahalanobis distance improved adaptive synthetic sampling, MDADASYN)在原始 ADASYN 的基础上引入马氏距离,用于计算少数类样本的 K 最近邻。通过结合数据集协方差矩阵及其逆矩阵,MDADASYN 更准确地衡量样本间的相似性,并根据多数类样本的比例自适应生成合成样本。相比传统方法,该改进算法充分考虑了特征间的关联性,能够进一步提升生成样本的质量和分类模型的性能。

2 改进能量谷优化算法

能量谷优化算法是由 Azizi 等^[18]2023 年提出的一种新颖的元启发式算法,其灵感来源于关于稳定性和不同粒子衰变模式的物理原理。即:若粒子的富集水平高于富集边界,则每个粒子有两个新生成的位置;否则,重新随机生成新的位置向量。传统 EVO 算法在复杂和高维优化问题中,容易陷入局部最优解,且初始种群的多样性不足会导致搜索效率下降。为了提升 EVO 算法的全局搜索能力并增强算法的多样性,引入了佳点集初始化种群来提高搜索的多样性,采用高斯-柯西变异结合动态调整参数,来提高算法的全局和局部搜索能力。通过这些策略的结合,算法能够在保持种群多样性的同时,增强探索能力,避免局部收敛并加速收敛速度,从而提升算法性能和效率。

2.1 佳点集初始化种群

由于能量谷优化算法是随机生成初始化种群,使得算法高度分散、优化速度慢、收敛性能差等,因此,使用佳点集初始化种群策略使得种群分布更为均匀、更能遍历整个解空间^[19],从而提高搜索的多样性。佳点集表示为:

$$P_n(k) = \{(\{r_1^{(n)} \cdot k\}, \{r_2^{(n)} \cdot k\}, \dots, \{r_s^{(n)} \cdot k\}), 1 \leq k \leq n\} \quad (2)$$

式中： $P_n(k)$ 称为佳点集， r 称为佳点集。佳点集 r 的值为：

$$r_i = 2\cos \frac{2\pi i}{p}, 1 \leq i \leq s \quad (3)$$

式中： p 是满足 $(p-3)/2 \geq s$ 的最小素数。

则，佳点集初始化策略为：

$$x_i(k) = (ub - lb)\{P_n(k) + lb\} \quad (4)$$

式中： ub 为上界， lb 为下界。通过这种均匀分布的初始解，算法能够更好地覆盖整个搜索空间，减少陷入局部最优的可能性。

2.2 高斯-柯西变异策略

为了增强算法的全局和局部搜索能力，引入高斯-柯西变异策略^[20]。高斯变异利用正态分布的特性生成小幅度的扰动，柯西分布由于具有较长的尾部，更容易产生较大幅度的跳跃，从而增强全局搜索能力。这两种变异策略的结合使得算法具有更强的全局和局部搜索能力，避免出现早期收敛和陷入局部最优。

高斯分布分量：

$$v_g = w_s \cdot N(0, 1) \quad (5)$$

式中： w_s 为步长， $N(0, 1)$ 为标准正态分布随机数。

柯西分布分量：

$$v_c = w_r \cdot \tan(\pi \cdot (r - 0.5)) \quad (6)$$

式中： w_r 为步长， r 为在 $[0, 1]$ 范围内均匀分布的随机数。

混合变异公式为：

$$v = m_r \cdot v_g + (1 - m_r) \cdot v_c \quad (7)$$

式中： m_r 为混合变异比例权重因子。

2.3 动态调整参数

在优化算法中，参数的选择直接影响收敛速度和搜索性能。传统的固定参数设置难以适应优化过程中的不同阶段，因此本文提出了动态调整参数的方法。主要对影响粒子搜索范围的步长和控制高斯分布和柯西分布的比例权重因子进行动态调整：

$$\begin{cases} w_s = w_{\min} + (w_{\max} - w_{\min}) \cdot \left(1 - \frac{t}{T}\right) \\ m_r = m_{\min} + (m_{\max} - m_{\min}) \cdot \frac{t}{T} \end{cases} \quad (8)$$

式中： t 为当前迭代次数； T 为最大迭代次数； w_{\min} 和 w_{\max} 分别为设置的步长最小值和最大值； m_{\min} 和 m_{\max} 分别为设置的比例权重因子的最小值和最大值。

动态调整参数与高斯-柯西变异策略相结合，通过动态调整步长能够直接影响高斯和柯西分布中的搜索范围，对于初期较大的步长利用柯西分布提高全局搜索能力，而后期较小的步长则利用高斯分布提高局部搜索精度。通过动态调整比例权重因子来控制两种变异的权重分配，确保算法能够在初期进行更多全局探索，而在后期更专注于局部开发。

2.4 CEC2014 测试函数

为了对 IEVO 算法的性能进行评估，本文针对传统优化算法及已有的改进能量谷优化算法，例如：粒子群优化算法 (particle swarm optimization, PSO)、鲸鱼优化算法 (whale optimization algorithm, WOA)、灰狼优化算法 (grey wolf optimizer, GWO)、EVO、BEVO、CEVO 和 IEVO，在 CEC2014 测试函数上选取了 9 个典型函数进行了测试分析，其中包含了单峰函数、多峰函数和混合函数与复合函数。本文测试环境为：Intel(R) Core(TM) i5-8265U CPU @ 1.60 GHz，内存为 8.00 GB 操作系统为 64 位 Windows11，编程软件为 Matlab2021b。具体测试函数表如表 1 所示。且为保证实验的公平性，所有算法均使用相同的初始化方式，并统一设置参数如表 2 所示。

表 1 CEC2014 测试函数

Table 1 CEC 2014 benchmark functions

函数编号	特性	函数名称
F1	单峰	Rotated High Conditioned Elliptic Function
F2	单峰	Rotated Bent Cigar Function
F4	多峰	Shifted and Rotated Rosenbrock's Function
F10	多峰	Shifted Schwefel's Function
F13	多峰	Shifted and Rotated HappyCat Function
F17	混合	Hybird Function 1(N=3)
F21	混合	Hybird Function 5(N=5)
F25	复合	Composition Function 3(N=3)
F26	复合	Composition Function 4(N=5)

表 2 测试函数参数设置

Table 2 Test function parameter settings

参数类型	参数设置
维度	30
种群规模	50
最大迭代次数	500
搜索空间上下界	$[-100, 100]$

各算法在 CEC2014 测试函数集上的均值和标准差结果如表 3 所示。总体而言，在大部分测试函数中，IEVO 算法在寻优性能和稳定性上都具有明显的优势；而除了 IEVO 算法，CEVO 和 BEVO 也优于其他传统算法，但略逊于 IEVO。但在 F26 函数中，CEVO 和 BEVO 的性能表现接近于 IEVO，甚至在 F25 函数中，BEVO 和 CEVO 函数的性能稍微较优于 IEVO 算法。

IEVO 在多种测试问题中表现出较高的搜索效率和稳定性，相较于 EVO 和其他主流优化算法，IEVO 具有较好的全局和局部搜索能力，从而提高了算法在高维复杂函数优化问题中的鲁棒性。

2.5 改进能量谷搜索算法优化 GRNN

GRNN 作为一种高效的回归工具，其性能极大依赖于

表 3 各算法的均值和标准差

Table 3 Mean and standard deviation of each algorithm

函数	评价指标	PSO	GWO	WOA	EVO	BEVO	CEVO	IEVO
F1	Avg	1.193×10^8	8.266×10^7	4.510×10^7	5.581×10^7	4.312×10^7	3.484×10^7	1.192×10^7
	Std	1.014×10^8	5.170×10^7	2.538×10^7	2.118×10^7	1.371×10^7	8.233×10^6	3.073×10^6
F2	Avg	1.385×10^{10}	1.751×10^9	1.571×10^9	1.430×10^7	1.852×10^7	1.930×10^7	3.007×10^6
	Std	7.069×10^9	1.470×10^9	1.785×10^9	8.216×10^6	8.789×10^6	1.002×10^7	9.330×10^5
F4	Avg	1.287×10^3	6.769×10^2	8.411×10^2	6.044×10^2	6.139×10^2	6.143×10^2	5.583×10^2
	Std	8.458×10^2	1.286×10^2	2.180×10^2	5.421×10^1	5.508×10^1	4.152×10^1	3.711×10^1
F10	Avg	4.478×10^3	3.778×10^3	5.568×10^3	2.878×10^3	4.085×10^3	2.637×10^3	1.576×10^3
	Std	7.358×10^2	9.593×10^2	9.737×10^2	5.717×10^2	6.680×10^2	5.130×10^2	2.090×10^2
F13	Avg	1.302×10^3	1.300×10^3	1.301×10^3	1.301×10^3	1.301×10^3	1.301×10^3	1.300×10^3
	Std	1.276	1.104	0.142	0.122	0.124	0.105	0.093
F17	Avg	4.874×10^6	2.834×10^6	2.548×10^6	3.828×10^6	2.027×10^6	2.712×10^6	9.336×10^5
	Std	4.846×10^6	2.315×10^6	1.773×10^6	3.273×10^6	1.139×10^6	1.174×10^6	8.975×10^5
F21	Avg	6.266×10^5	9.631×10^5	1.264×10^6	8.516×10^5	9.448×10^5	6.587×10^5	4.484×10^5
	Std	5.815×10^5	1.804×10^6	1.208×10^6	5.167×10^5	5.704×10^5	4.315×10^5	3.595×10^5
F25	Avg	2.714×10^3	2.712×10^3	2.700×10^3	2.705×10^3	2.700×10^3	2700	2.717×10^3
	Std	7.997	4.139	0	1.024×10^1	1.629	0	4.109
F26	Avg	2.743×10^3	2.748×10^3	2.707×10^3	2.737×10^3	2.790×10^3	2800	2.783×10^3
	Std	7.390×10^1	6.017×10^1	2.524×10^1	4.879×10^1	3.037×10^1	0	3.787×10^1

平滑参数的选择。在传统方法中,这一参数往往是静态选定的,这种静态设定会导致模型在不同数据集上的表现不一致。为了克服这一局限性,通过结合佳点集初始化种群、高斯-柯西变异策略及动态调整参数改进的能量谷优化

算法对 GRNN 神经网络进行优化,IEVO 算法改进 GRNN 的流程图如图 1 所示。这种混合策略不仅增强了种群的多样性,还提高了全局搜索的能力,为 GRNN 模型的应用提供了更高的灵活性和更强的适应能力。

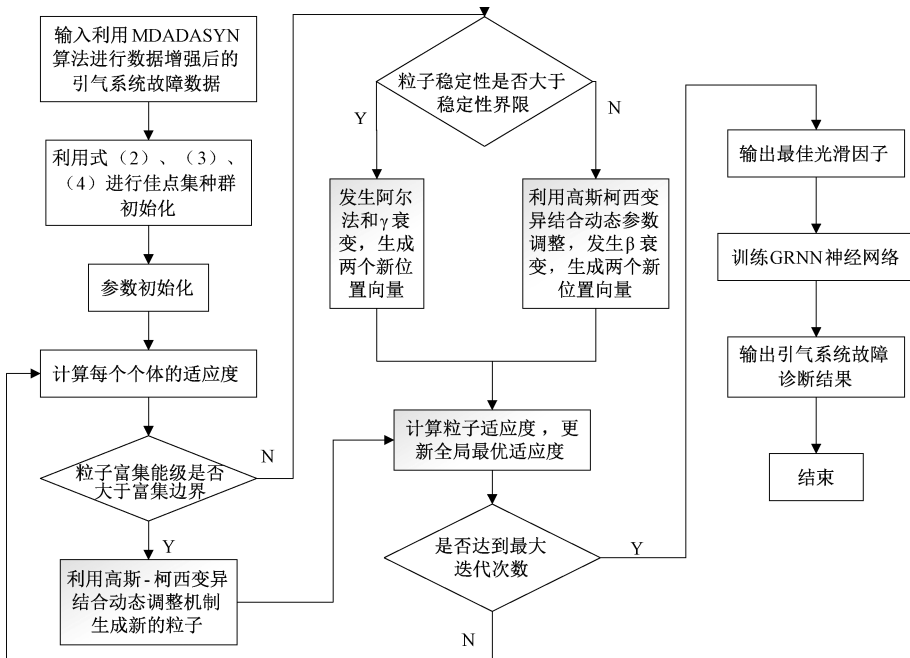


图 1 IEVO 算法改进 GRNN 的流程

Fig. 1 Flowchart of enhancing GRNN with the IEVO algorithm

3 故障诊断模型实例验证

3.1 基于 MDADASYN 的数据平衡化处理

本文通过在机务在线、机务论坛等平台搜集 B737NG 飞机引气系统故障 ACARS 报文作为数据集,其中选取飞行高速、左右发动机转速、左右发动机引气压力、左右发动机引气温度和防冰系统状态作为参数,主要故障部件有:连接导线、引气调节器(BAR)、高压级调节器(HRS)、空调附件组件(ACAU)、预冷器控制活门(PCCV)、450°F 传感器、数据异常但无部件故障和 390°F 传感器。由于搜集到的飞机引气系统故障数据极其不平衡,最多数样本占总数的 27.0%,最少数类样本占总数的 8.5%,会导致对少数类样本特征学习不足,从而影响故障诊断效率。

为更好地捕捉少数类样本的分布特征,采用马氏距离改进的 ADASYN 算法对故障数据进行处理,原始数据分布柱状图如图 2 所示,MDADASYN 数据增强后的分布柱状图如图 3 所示。通过对比能够看出,MDADASYN 算法进行数据增强后的样本类别分布更为平衡,而原始数据分布的样本类别数量相差太大。




图 2 原始数据分布柱状图

Fig. 2 Raw data distribution bar chart




图 3 MDADASYN 算法分布柱状图

Fig. 3 MDADASYN algorithm distribution bar chart

原始 ADASYN 算法合成数据分布图如图 4 所示,TLR-ADASYN 算法的合成数据分布图如图 5 所示,MDADASYN 算法的合成数据分布图如图 6 所示。从 3 个图中能够对比看出,图 4 的数据分布过于分散,而图 6 的数据最为集中,且相较于图 5、6 的分布也更为集中。因此,MDADASYN 算法进行数据增强能够使得数据更为集中,具有较高的相似性从而提升模型的分类能力。




图 4 原始 ADASYN 算法合成数据分布

Fig. 4 Data distribution of the synthetic data from the original ADASYN algorithm




图 5 TLR-ADASYN 算法的合成数据分布

Fig. 5 Data distribution of the synthetic data from the TLR-ADASYN algorithm

3.2 基于 MDADASYN-IEVO-GRNN 的引气系统故障诊断

将 MDADASYN 算法平衡处理过后的飞机引气系统故障数据按 4 : 1 分为训练集和测试集,分别利用原始 GRNN 模型、EVO-GRNN 模型和 IEVO-GRNN 模型进行故障诊断。本文设置 EVO-GRNN 和 IEVO-GRNN 的最大迭代次数为 100,并利用十折交叉验证对模型进行训练和评估。




图 6 MDADASYN 算法的合成数据分布

Fig. 6 Data distribution of the synthetic data from the MDADASYN algorithm

1) 优化参数结果分析

由于光滑因子对 GRNN 精度的影响较大,因此采用 IEVO 算法对 GRNN 进行优化,且为了提高 EVO 算法的全局搜索能力、加快收敛速度和避免陷入局部最优,利用佳点集初始化种群、高斯-柯西变异策略和动态调整参数机制改进的 IEVO 算法来提高 GRNN 的精度。将均方误差 (mean squared error, MSE) 视为优化目标,IEVO-GRNN 引气系统故障诊断模型的迭代曲线如图 7 所示,IEVO-GRNN 引气系统故障诊断模型的迭代曲线如图 8 所示。EVO 算法在 80 次左右进行收敛,而 IEVO 算法在 40 次左右就进行了收敛。因此,改进后的 IEVO 算法具有收敛速度快,全局搜索能力强的特点。




图 7 EVO-GRNN 引气系统故障诊断模型迭代曲线

Fig. 7 Iteration curve of the EVO-GRNN aeration system fault diagnosis model

2) 消融分析

为了评估某单一模块对故障诊断准确率的影响,以及各模块的有效性,本文将 GRNN、IEVO-GRNN、MDADASYN-EVO-GRNN、MDADASYN-IEVO-GRNN 3 种模型进行消融试验,模型消融对比如表 4 所示,GRNN、




图 8 IEVO-GRNN 引气系统故障诊断模型迭代曲线

Fig. 8 Iterative curve of the IEVO-GRNN aeration system fault diagnosis model

MDADASYN-GRNN、IEVO-GRNN 和 MDADASYN-IEVO-GRNN 模型的混淆矩阵图如图 9~12 所示。

表 4 模型消融对比

Table 4 Comparison of MSE among the three models

模型	MSE	准确率/%
GRNN	0.719 13	76.34
MDADASYN-GRNN	0.456 48	82.99
IEVO-GRNN	0.588 24	79.25
MDADASYN-IEVO-GRNN	0.029 41	97.10




图 9 EVO-GRNN 模型故障诊断测试集混淆矩阵图

Fig. 9 EVO-GRNN model fault diagnosis test set confusion matrix diagram




图 10 MDADASYN-GRNN 模型故障诊断测试结果图

Fig. 10 MDADASYN-GRNN model fault diagnosis test set confusion matrix diagram




图 11 IEVO-GRNN 模型故障诊断测试集结果图

Fig. 11 IEVO-GRNN model fault diagnosis test set confusion matrix diagram




图 12 MDADASYN-IEVO-GRNN 模型故障诊断测试集结果图

Fig. 12 MDADASYN-IEVO-GRNN model fault diagnosis test set confusion matrix diagram

通过表 4 可以看出,MDADASYN-IEVO-GRNN 模型的训练效果最好,其均方误差最小,故障诊断的准确率最高,相较于相较于 GRNN、IEVO-GRNN 和 MDADASYN-GRNN 模型准确率分别提高了 20.76%、17.85% 和 14.11%。

其中,混淆矩阵图中 1、2、3、4、5、6、7 和 8 分别代表连接导线故障、PCCV 故障、ACAU 故障、390°F 传感器故障、BAR 故障、HRS 故障、数据异常但无故障和 450°F 传感器故障。

3)对比分析

为了验证本文优化算法的优势,利用传统的粒子群优化算法、灰狼优化算法、鲸鱼优化算法以及现有的改进能量谷优化算法 BEVO、CEVO 和本文的 IEVO 均对 GRNN 进行优化,且均使用 MDADASYN 算法数据增强后的数据,优化算法对比分析结果如表 5 所示。

由表 5 可知,IEVO-GRNN 模型的均方误差最小,故障诊断准确率最高,相较于 BEVO-GRNN、CEVO-GRNN、EVO-GRNN 模型准确率分别提高了 7.06%、5.92%和 8.82%;且相较于其他传统优化算法,如 PSO、WOA、GWO 优化算法,传统 EVO 优化算法的优化效果更好,均方误差更小,准确率更高。

表 5 不同优化算法故障诊断结果对比

Table 5 Comparison of fault diagnosis results from different optimization algorithms

模型	均方误差	准确率/%
PSO-GRNN	0.352 94	84.23
WOA-GRNN	0.336 90	85.41
GWO-GRNN	0.382 35	82.98
EVO-GRNN	0.301 26	88.38
BEVO-GRNN	0.248 87	90.04
CEVO-GRNN	0.205 88	91.18
IEVO-GRNN	0.029 41	97.10

4 结 论

本文提出了一种基于 MDADASYN-IEVO-GRNN 的飞机发动机引气系统故障诊断方法。通过利用马氏距离对 ADASYN 算法进行改进,解决飞机发动机引气系统故障数据不平衡问题,再利用 IEVO-GRNN 构建飞机发动机引气系统故障诊断模型。CEC2014 测试函数结果表明,结合佳点集初始化种群、高斯-柯西变异策略和动态调整参数机制改进的能量谷优化算法有效地提高了 EVO 的种群多样性及全局和局部搜索能力。基于引气系统真实故障数据的仿真结果表明,MDADASYN 方法有效地处理了飞机发动机引气系统样本不平衡问题;IEVO-GRNN 模型能有效提高飞机引气系统故障诊断准确率;基于 MDADASYN-IEVO-GRNN 的故障诊断方法在引气系统故障诊断中表现优异,能够有效提高飞机发动机引气系统的故障诊断效率。

参考文献

[1] 肖晓阳. 基于 RBF 神经网络的波音 737NG 飞机引气系统故障诊断模型[J]. 航空维修与工程, 2020(7): 81-84.
XIAO X Y. Fault diagnosis model of pneumatic system based on RBF neural network for B737NG[J]. Aviation Maintenance & Engineering, 2020(7): 81-84.

[2] 陈晓梅, 王行健, 蔡焯, 等. 基于 AVMD 和排列熵的 t 分布邻域嵌入流形 HHO-SVM 模拟电路故障诊断方法[J]. 电子测量与仪器学报, 2024, 38(6): 233-240.
CHEN X M, WANG X J, CAI Y, et al. Analog fault diagnosis method based on AVMD and t-SNE using HHO-SVM[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(6): 233-240.

[3] 刘应东, 刘韬, 李华, 等. 变工况轴承的联合分布适应迁移故障诊断[J]. 电子测量与仪器学报, 2021, 35(5): 69-75.

- LIU Y D, LIU T, LI H, et al. Transfer fault diagnosis of bearings under variable working conditions based on joint distribution adaptation[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(5):69-75.
- [4] 戴郎杰, 蔡开龙, 王阿久, 等. 基于 CNN-BES-ELM 的航空发动机气路故障诊断研究[J]. 电子测量技术, 2024, 47(13):27-34.
- DAI L J, CAI K L, WANG A J. Research on aero-engine gas path fault diagnosis based on CNN-BES-ELM[J]. Electronic Measurement Technology, 2024, 47(13):27-34.
- [5] 贾宝惠, 谭楚懿, 高原, 等. 基于 GRNN 的前起落架液压收放系统健康评估方法[J/OL]. 北京航空航天大学学报, 1-15[2025-01-20]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0708>.
- JIA B H, TAN CH Y, GAO Y, et al. Health assessment of landing gear hydraulic retraction/extension system based on GRNN[J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 1-15 [2025-01-20]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0708>.
- [6] 祖璇, 张广海. 基于 Borderline-SMOTE 和 OOA-SVM 的心脏病诊断预测模型[J]. 兰州文理学院学报(自然科学版), 2025, 39(1):46-52.
- ZU X, ZHANG G H. Prediction model of heart disease diagnosis based on Borderline-SMOTE and OOA-SVM[J]. Journal of Lanzhou University of Arts and Science(Natural Sciences), 2025, 39(1):46-52.
- [7] 郑晓亮, 董梦媛, 夏迎节, 等. 基于改进的 Kmeans-SMOTE-RF 的煤与瓦斯突出预测[J/OL]. 重庆工商大学学报(自然科学版), 1-10[2025-01-20]. <http://kns.cnki.net/kcms/detail/50.1155.N.20241018.1342.002.html>.
- ZHENG X L, DONG M Y, XIA Y J, et al. Coal and gas outburst prediction based on improved Kmeans-SMOTE-RF[J]. Journal of Chongqing Technology and Business University(Natural Science Edition), 1-10[2025-01-20]. <http://kns.cnki.net/kcms/detail/50.1155.N.20241018.1342.002.html>.
- [8] 刘迪迪, 王洋, 刘辉乾, 等. 基于 ADASYN 平衡化数据集的 POA-SVM 变压器故障诊断[J]. 电网与清洁能源, 2023, 39(8):36-44.
- LIU D D, WANG Y, LIU H Q, et al. POA-SVM transformer fault diagnosis based on ADASYN balanced data set [J]. Power System and Clean Energy, 2023, 39(8):36-44.
- [9] 余松, 胡东, 唐超, 等. 基于 TLR-ADASYN 平衡化数据集的 MSSA-SVM 变压器故障诊断[J]. 高电压技术, 2021, 47(11):3845-3853.
- YU S, HU D, TANG CH, et al. MSSA-SVM transformer fault diagnosis method based on TLR-ADASYN balanced data set [J]. High Voltage Engineering, 2021, 47(11):3845-3853.
- [10] 梁伟, 陈志雄, 欧阳忠杰, 等. 基于 LPSO-GRNN 模型的螺栓松紧状态预测研究[J]. 机电工程, 2023, 40(11):1814-1822.
- LIANG W, CHEN ZH X, OUYANG ZH J, et al. Prediction of tension state of bolt based on LPSO-GRNN [J]. Journal of Mechanical & Electrical Engineering, 2023, 40(11):1814-1822.
- [11] WANG H. Fault diagnosis of analog circuit based on wavelet transform and neural network[J]. Archives of Electrical Engineering, 2020, 69(1):175-185.
- [12] 邹红波, 宋璐, 张馨煜, 等. 基于 PSO-GRNN 和 D-S 证据理论的电网分区故障诊断[J]. 智慧电力, 2023, 51(3):25-30, 45.
- ZOU H B, SONG L, ZHANG X Y, et al. Divisional fault diagnosis of power grids based on PSO-GRNN and D-S evidence theory [J]. Smart Power, 2023, 51(3):25-30, 45.
- [13] 许家才, 吕亮, 陆崇山, 等. 基于混合特征和 CFOA-GRNN 的行星齿轮箱故障诊断研究[J]. 机床与液压, 2022, 50(6):186-191.
- XU J C, LYU L, LU CH SH, et al. Research on fault diagnosis of planetary gearbox based on hybrid features and CFOA-GRNN [J]. Machine Tool & Hydraulics, 2022, 50(6):186-191.
- [14] 张华美, 邓贵雄. 基于能量谷优化算法的分布式阵列综合[J/OL]. 微波学报, 1-8[2025-01-20]. <http://kns.cnki.net/kcms/detail/32.1493.TN.20240419.1703.002.html>.
- ZHANG H M, DENG G X. Synthesis of distributed array based on energy valley optimizer algorithm[J/OL]. Journal of Microwaves, 1-8 [2025-01-20]. <http://kns.cnki.net/kcms/detail/32.1493.TN.20240419.1703.002.html>.
- [15] 张嘉辉, 蒙志君, 何家政, 等. 基于改进能量谷优化的多无人机空战目标分配[J]. 系统工程与电子技术, 2024, 46(11):3754-3763.
- ZHANG J H, MENG ZH J, HE J ZH, et al. Multi-UAV air combat target allocation based on improved energy valley optimization [J]. Systems Engineering and Electronics, 2024, 46(11):3754-3763.
- [16] 叶馨, 叶尹. 基于 sinusoidal 混沌与能量谷优化算法的工程结构设计[J]. 智能物联技术, 2024, 56(3):

- 117-123.
- YE X, YE Y. Engineering structure design based on sinusoidal chaotic energy valley optimization algorithm[J]. Technology of IoT & AI, 2024, 56(3): 117-123.
- [17] HE H B, BAI Y, GARCIA E A, et al. ADASYN: Adaptive synthetic sampling approach for imbalanced learning[C]. IEEE International Joint Conference on Neural Networks. IEEE World Congress on Computational Intelligence. Hong Kong, China: IEEE, 2008: 1322-1328.
- [18] AZIZI M, AICKELIN U, KHORSHIDI H A, et al. Energy valley optimizer: A novel metaheuristic algorithm for global and engineering optimization[J]. Scientific Reports, 2023, 13(1):226.
- [19] 崔琳, 张熠鑫. 改进鸡群优化算法的二维 MUSIC 谱峰搜索研究[J]. 电子测量与仪器学报, 2020, 34(3): 142-148.
- CUI L, ZHANG Y X. Research on spectral peak searching of two-dimensional MUSIC based on improved chicken swarm optimization algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(3):142-148.
- [20] 王文成, 余智科, 郑诗翰. 基于改进型蜣螂算法 Fuzzy-Smith-LADRC 混凝投药[J]. 电子测量技术, 2025, 48(3):10-17.
- WANG W CH, YU ZH K, ZHENG SH H. Coagulation dosing based on an improved dung beetle algorithm Fuzzy-Smith-LADRC [J]. Electronic Measurement Technology, 2025, 48(3):10-17.

作者简介

江佩瑶, 硕士研究生, 主要研究方向为航空故障诊断、航空风险评估。

E-mail: 1509774772@qq.com

王洪亮(通信作者), 博士后, 硕士生导师, 主要方向为智能监测与控制、物联网技术。

E-mail: 27735367@qq.com