

DOI: 10.13382/j.jemi.B2508116

基于改进 SDAE-GATransformer 的航空变压整流器故障诊断方法*

李耀华¹ 杨通江¹ 张宇²

(1. 中国民航大学交通科学与工程学院 天津 300300; 2. 中国民航大学航空工程学院 天津 300300)

摘要:航空变压整流器(transformer rectifier unit, TRU)是飞机二次电源系统中关键电能变换装置之一,在 TRU 工作过程中易受温湿度变化和负载波动的影响导致其组成元件出现相应故障,降低设备的可靠性继而影响飞行安全。针对 TRU 硬件故障类别多且故障数据特征相似导致故障定位困难的问题,提出一种基于改进堆叠降噪自动编码器(stacked denoising auto encoder, SDAE)结合遗传算法(genetic algorithm, GA)优化 Transformer 的故障诊断方法。首先,对采集的故障数据进行归一化处理;其次,在 SDAE 训练阶段引入对比中心损失(contrastive center loss, CCL)函数,利用样本标签信息在 SDAE 逐层非线性映射中学习最佳分类特征,实现类内距离缩小,类间距离扩大。同时,将 CCL 与重构成本损失(reconstructing cost losses, RCL)函数联合优化得到基于改进 SDAE 特征提取模块,实现对原始故障数据的特征预提取。为进一步提取特征信息并诊断,构建 GA 优化 Transformer 的诊断模块,提高故障检测的准确率。最后,利用 Simulink 仿真故障数据与现有诊断方法进行对比研究。结果表明,所提方法可以较好的实现 101 种故障的诊断,准确率达 96.05%,且具有良好的抗噪能力。

关键词:故障诊断;变压整流器;堆叠降噪自动编码器;Transformer

中图分类号: V267+.3; TN06 **文献标识码:** A **国家标准学科分类代码:** 580.60

Fault diagnosis method of aircraft transformer rectifier unit based on improved SDAE-GATransformer

Li Yaohua¹ Yang Tongjiang¹ Zhang Yu²

(1. College of Transportation Science and Engineering, Civil Aviation University of China, Tianjin 300300, China;

2. College of Aeronautical Engineering, Civil Aviation University of China, Tianjin 300300, China)

Abstract: The transformer rectifier unit (TRU) is one of the key power conversion devices in the secondary power supply system of an airplane. During the operation of the TRU, it is susceptible to temperature and humidity variations and load fluctuations, leading to corresponding failures of its components, which reduces the reliability of the equipment and then affects the safety of flight. In view of the problem that TRU hardware has many fault categories and similar fault data characteristics, a fault diagnosis method based on stacked denoising auto encoder (SDAE) combined with genetic algorithm (GA) to optimize the Transformer is proposed. The following is an example of the optimization of Transformer's fault diagnosis method. First, the collected fault data are normalized; second, the contrastive center loss (CCL) function is introduced in the training phase of SDAE to learn the optimal classification features in the layer-by-layer nonlinear mapping of SDAE by using the sample label information, so as to realize the reduction of the distance within classes and the expansion of the distance between classes. At the same time, the CCL and reconstructing cost losses (RCL) function are jointly optimized to obtain the improved SDAE-based feature extraction module, which realizes the feature pre-extraction of the original fault data; in order to further extract the feature information and diagnose the problem, the diagnostic module of the GA-optimized Transformer is constructed to improve the accuracy of fault detection. Finally, Simulink is utilized to simulate the fault data to compare with the existing diagnostic methods. The results show that the proposed method can better realize the diagnosis of 101 kinds of faults, with an accuracy rate of 96.05% and good noise resistance.

Keywords: fault diagnosis; transformer rectifier unit; stacked denoising autoencoders; transformer

收稿日期:2025-01-09 Received Date: 2025-01-09

* 基金项目:国家自然科学基金委员会-中国民航局民航联合研究基金(U2033209)项目资助

0 引言

航空变压整流器 (transformer rectifier unit, TRU) 是飞机电源系统中的关键部件之一,负责将电源系统中 115 V 400 Hz 交流电转换成 28.5 V 低压直流或 270 V 高压直流,为机载电子设备和其他重要系统提供稳定的直流电源^[1-2]。在实际运行中,TRU 的工作环境会经历温度、湿度等大幅变化,随着运行时间的增加内部器件会出现老化、腐蚀等现象,一旦出现故障,不仅会直接影响到机载设备的正常工作,还可能威胁到飞行安全^[3],因此,TRU 的故障诊断及健康状态监控,对飞机的安全可靠运行具有重要的现实意义。

目前在电气系统故障诊断领域的研究可归纳为基于解析模型的方法、信号处理的方法以及人工智能的方法 3 种类型^[4]。基于解析模型的方法需要对系统建立精确的数学模型,然而,电气系统中功率型器件的开关动作会产生严重的非线性特性,导致精确模型建立不易^[5]。基于信号处理的方法多从故障信号进行分析,利用快速傅里叶变换^[6] (fast Fourier transform, FFT)、小波包分解^[7] (wavelet packet decomposition, WPD)、集成经验模态分解^[8] (ensemble empirical modal decomposition, EEMD) 等方法对原始故障信号进行处理。FFT 对故障信号的局部特征提取效果较差,而 WPD 则可以弥补这一缺点,但分析对比步骤繁多。EEMD 虽解决了经验模态分解存在的模态混淆问题,但在数据的降噪过程中易丢失数据的重要特征。基于人工智能法又可以分为专家系统 (expert system, ES),支持向量机 (support vector machine, SVM) 和人工神经网络 (artificial neural network, ANN),ES 在实际应用中相关知识库建立不易;SVM 本质上是二分类,在多类别问题上处理困难;ANN 因其卓越的数据处理能力在故障诊断领域被学者广泛研究和应用^[9]。

以上诊断方法各有优缺点,为了优势互补,两种或者多种方法的集成在 TRU 故障诊断领域已经成为研究热点。例如,将基于信号处理的方法与人工智能方法集成实现 TRU 故障诊断,文献[10]利用 WPD 将故障信号分解,再利用 ANN 提取故障的频谱特征并进行诊断,虽取得不错的诊断效果,但对 TRU 所有硬件故障模式诊断的准确率仍有提升空间。文献[11]利用设定阈值判断故障开短路,之后利用主成分分析 (principal component analysis, PCA) 和 SVM 实现 TRU 整流二极管开短路故障分级诊断,但对于 TRU 硬件故障模式诊断不够全面。文献[12]考虑到基于信号处理方法的局限性,使用堆叠降噪自编码器 (stacked denoising autoencoders, SDAE) 和 SVM 的方法实现 TRU 整流二极管的故障诊断,虽有较好的准确率,但在故障模过多时,特征空间中容易出现特征

混淆问题,影响后续的故障诊断准确率。为解决上述问题,本文提出一种基于改进 SDAE-GATransformer 的航空变压整流器故障诊断方法,实现故障定位到元件。利用改进 SDAE 进行故障特征提取与降维,考虑到输入量本身是序列数据,采用 GA 优化 Transformer 进一步特征提取并诊断。通过实验对比分析,该方法表现出良好的性能,为 TRU 故障诊断提供一种新思路。

1 问题描述

本文研究对象为隔离型 12 脉冲变压整流 (isolated transformer rectifier unit, ITRU-12)。其主要结构有一个移相变压器,两组三相整流桥 RF1 和 RF2,一个平衡电抗器,如图 1 所示。为了便于后续故障分类研究,将变压器绕组按顺序标号 1~9,平衡电抗器为 $L_1 \sim L_2$,整流二极管为 $D_1 \sim D_{12}$ 。TRU 的典型硬件故障模式^[13]有各变压器绕组间发生开路故障 (open-circuit fault between windings, OCW)、单桥臂短路故障 (single-diode short, SDS)、单桥臂开路故障 (single-diode open, SDO)、双桥臂同时发生开路故障 (double-diode open, DDO) 和平衡电抗相间开路故障 (open-circuit fault in balance reactor, OCR) 5 大故障类型,其中各大类型的故障又分为同类型元器件不同位置故障,共计 101 种故障类别。

ITRU-12 带额定负载时,正常情况与不同故障模式的部分三相输入电流波形如图 2 所示,代表 A、B、C 三相输入电流,整流输出电压波形如图 3 所示。正常情况下,移相变压器输出两组相位差 30° 的三相电压,两组整流桥中 12 个二极管规律导通,在工频周期形成 12 个自然换相,平衡电抗器实现并联整流桥间的动态均流控制,此时三相输入电流为规整阶梯波,整流输出电压波形呈现等间隔周期脉动,波形中相邻峰相位差 30° 。OCR 故障时,仅有一组整流桥工作,ITRU-12 由 12 脉冲变为 6 脉冲,输出电压波形也呈现等间隔周期脉动,但波形中相邻峰相位差 60° ;OCW 故障时,移相变压器输出电压不再满足特定的相位和幅值关系,导致整流二极管不再按照原先的导通电角度和顺序导通,三相输入电流畸变严重,整流输出电压纹波过大;SDO 和 DDO 故障时,由于整流桥存在开路,二极管导通电流会发生改变,导致三相输入电流产生畸变,SDO 故障时整流输出电压波形相较于正常情况表现为缺少对应的波头,DDO 故障时整流输出电压波形一般表现为单二极管故障时波形叠加;SDS 故障时,会造成移相变压器副边绕组相间短路,使电网侧输入端承受极大的冲击电流,整流输出电压也严重不规则。

为全面反映不同故障模式下的故障特点,本文选取输入三相电流和整流输出电压作为诊断判据。如何快速准确的从原始故障数据中精准提取出故障分类特征,则

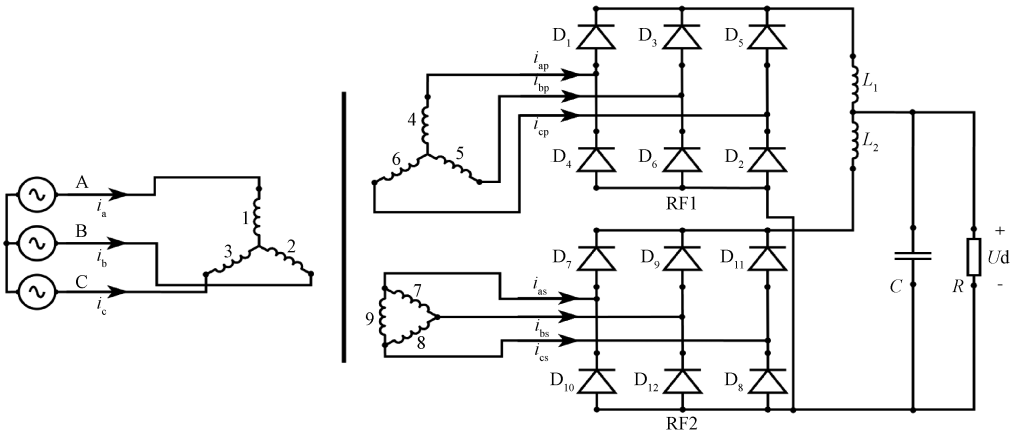


图 1 ITRU-12 电气原理

Fig. 1 ITRU-12 electrical principle

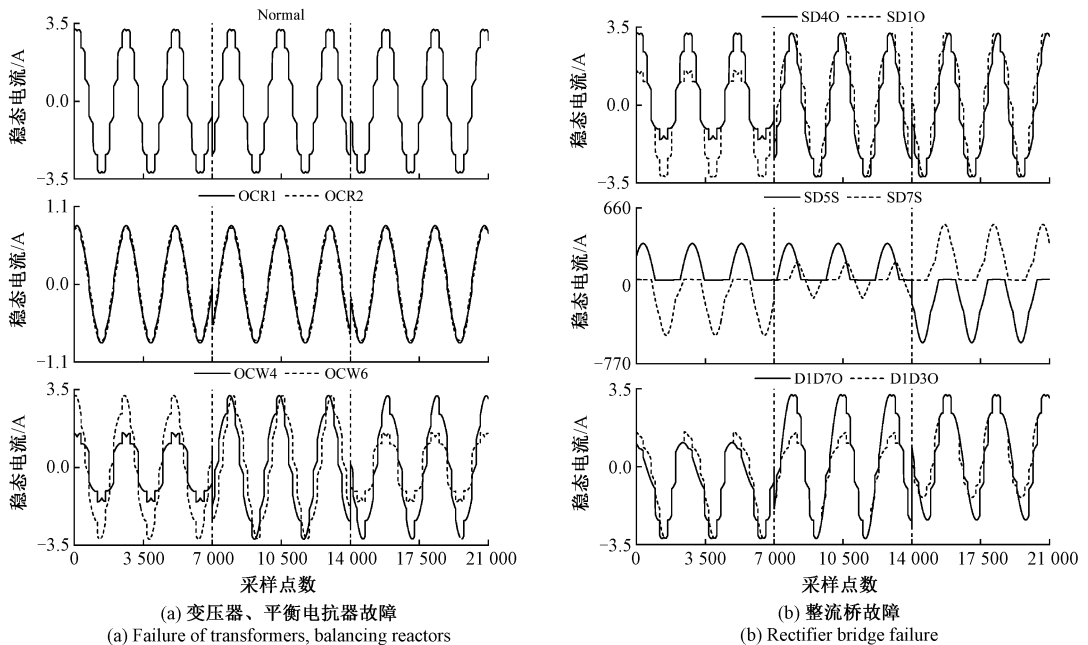


图 2 部分输入三相电流波形

Fig. 2 Partial input three-phase current waveforms

是 TRU 故障诊断的关键。本文针对这一问题进行研究,设计基于改进 SDAE-GATransformer 的 TRU 故障诊断方法,实现更优的诊断性能。

2 基于改进 SDAE-GATransformer 的 TRU 故障诊断方法

故障诊断模型总体结构如图 4 所示。基于改进 SDAE-GATransformer 的 TRU 故障诊断方法包括 5 个模块,输入层、基于改进 SDAE 的特征提取模块、基于 Transformer 的诊断模块、基 GA 的 Transformer 超参数寻

优模块和输出层。首先通过输入层采集故障原始序列数据并进行归一化预处理,之后将预处理后的数据输入基于改进 SDAE 的特征提取模块,实现关键分类特征提取与降维。然后,将所提取的故障特征信息传递至基于 Transformer 的诊断模块,该模块能够有效地捕捉故障特征长距离依赖关系,从而提高故障诊断的准确率。同时引入 GA 对诊断模块的超参数寻优,提升诊断模块的泛化能力和诊断效率;最后输出层输出诊断结果。

2.1 输入层

为消除电压电流数据量纲影响,降低计算复杂度和提升模型收敛速度,对数据进行归一化到 $[-1, 1]$ 区间:

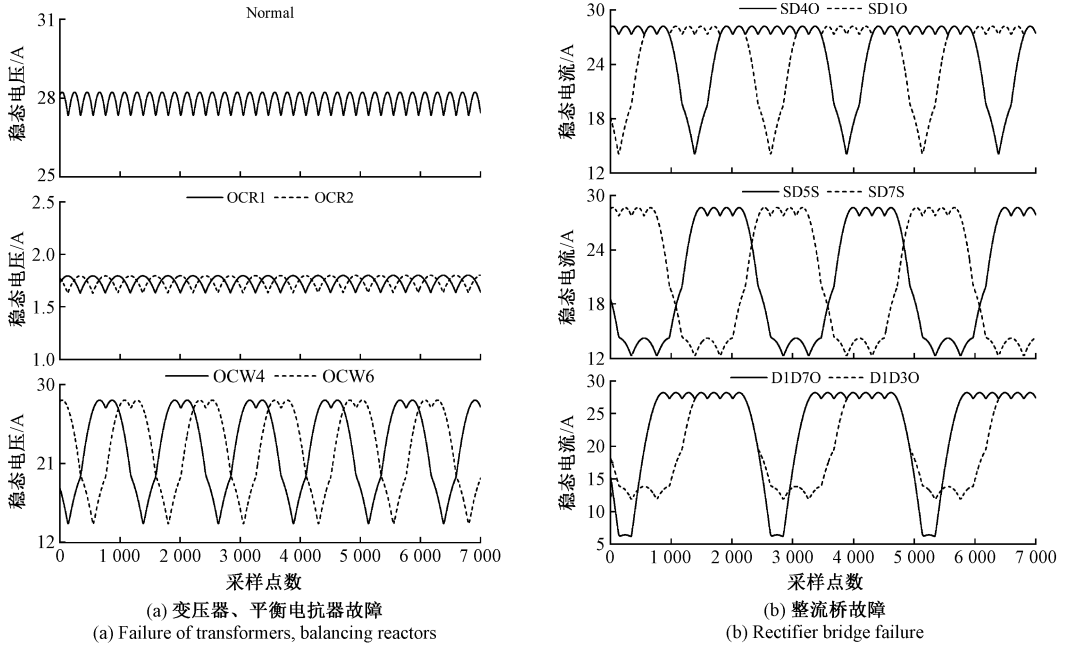


图 3 部分整流输出压波形

Fig. 3 Waveform of partially rectified output voltage

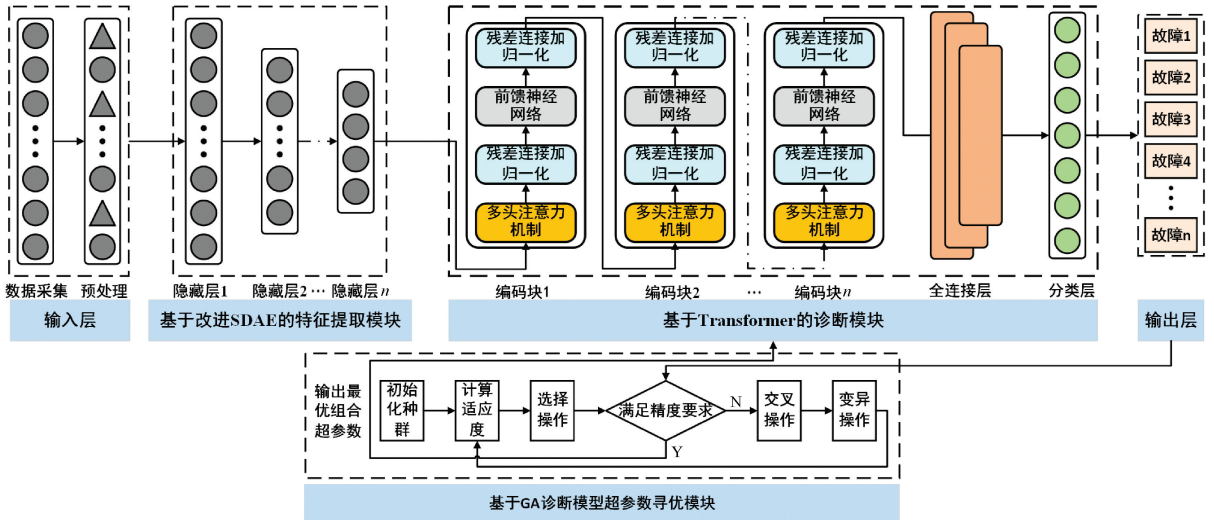


图 4 故障诊断模型总体结构

Fig. 4 Overall structure of the fault diagnosis model

$$X_N = 2 \frac{X - X_{\min}}{X_{\max} - X_{\min}} - 1 \quad (1)$$

式中: X_N 是预处理输出数据; X 是原始数据; X_{\max} 是单个样本中的最大值; X_{\min} 是单个样本中的最小值。

2.2 基于改进 SDAE 的特征提取模块

传统 SDAE 在故障类别数较少时,展现出较好的特征提取能力^[14-15]。然而,当故障类别数过多时,其训练目标仅通过最小化重构成本损失(reconstructing cost losses, RCL)函数来实现,而未能充分考虑类别标签信息。因此,所提取的特征可能包含与分类无关的信息,进而影响

后续故障诊断的准确性。

针对高维过多类别故障数据,不仅能从原始故障数据中提取关键特征并有效降维,还能保留显著分类判别信息,从而增强特征类间可分性,优化后续分类模型的泛化性能,本文提出一种改进 SDAE 模型。该模型通过联合对比中心损失(contrastive center loss, CCL)函数^[16]和 RCL 函数来优化 SDAE,其结构如图 5 所示。

图 5 中, f_{θ} 为编码过程,将各层的输入数据映射到隐藏层。各隐藏层和输入层之间的关系为:

$$H = f_{\theta}(W_e X + b_e) = \sigma(W_e \times f_{n-1}(X) + b_e) \quad (2)$$

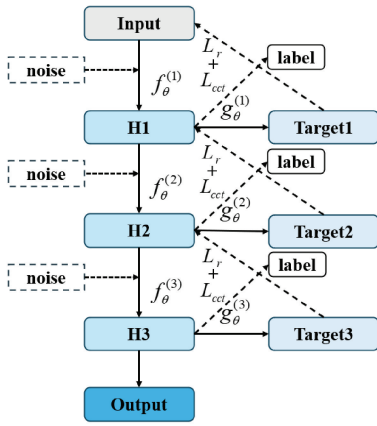


图 5 改进 SDAE 结构

Fig. 5 Improved SDAE structure diagram

式中: \mathbf{W}_e 为编码器的权重矩阵; b_e 为编码器的偏置向量; 训练时 X 为添加高斯噪声后的数据; H 为 SDAE 隐藏层数据; $\sigma(\cdot)$ 为非线性激活 Tanh 函数。

$$\sigma(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (3)$$

g_θ 为解码过程,旨在训练时从各隐藏层降噪重构出数据,用以计算重构误差成本损失。重构过程为:

$$Y = g_\theta(\mathbf{V}_d H + c_d) = \sigma(\mathbf{V}_d \sigma(\mathbf{W}_e \times f_{n-1}(X) + b_e) + c_d) \quad (4)$$

式中: \mathbf{V}_d 为解码器件的权重矩阵; c_d 为解码器的偏置向量; Y 为重构输出的数据。CCL 在深度神经网络逐层非线性映射的应用为在特征空间尽可能让类内间距缩小,类间间距扩大。如带标签仿真故障数据 $X = \{x_1, x_2, \dots, x_n\}$ 由 n 个样本构成,其中有 K 个类别, $X = \{X_1, X_2, \dots, X_K\}$, 每个样本有 m 维。对比中心损失函数在特征空间先为每个类别生成一个相同维度的类别中心向量 c , 计算中心损失为:

$$S_p = \frac{1}{2} \sum_i^m \|h_i - c_{y_i}\|_2^2 \quad (5)$$

式中: $h_i = f_\theta(\mathbf{W}_e X_i^j + b_e)$ 为隐藏层输出数据; c_{y_i} 为对应类别的中心向量。所有样本与非对应类别中心的距离表示为:

$$S_n = \sum_{i=1}^m \sum_{j=1, j \neq y_i}^k \|h_i - c_j\|_2^2 \quad (6)$$

式中: c_j 为本数据非对应类别中心向量。所以对比中心损失函数为:

$$L_{ccl} = \frac{S_p}{S_n} = \frac{1}{2} \sum_{i=1}^m \frac{\|h_i - c_{y_i}\|_2^2}{\sum_{j=1, j \neq y_i}^k \|h_i - c_j\|_2^2 + \delta} \quad (7)$$

为了防止公式无意义,令 $\delta = 10^{-6}$ 。本文 RCL 函数为:

$$L_r = \frac{1}{2m} \sum_{i=1}^m \|h_i - y_i\|_2^2 \quad (8)$$

式中: m 为样本数量; $\|\cdot\|$ 为 2 的范数; h_i 为上一个隐藏层输出数据; y_i 为重构输出数据。改进后的堆叠降噪自编码器的目标损失函数为:

$$L\{\mathbf{W}_e, b_e, \mathbf{V}_d, c_d\} = L_r + L_{ccl} \quad (9)$$

在 SDAE 逐层贪婪训练中,联合 RCL 与 CCL 的协同优化机制可有效规范隐层表征学习过程。其中 RCL 通过最小化原始输入与解码输出的差异,驱动网络有效捕获关键特征;CCL 函数则通过建立类内紧凑性与类间差异性的双重约束,引导特征空间满足最大可分性准则。该联合优化策略通过反向传播算法实现网络参数的同步迭代更新,提升模型特征提取性能。

2.3 基于 Transformer 的诊断模块

经过改进 SDAE 提取后的故障样本在特征空间虽已最大化的实现特征提取目标,但仍有少许故障样本在特征提取空间存在特征混淆问题,也考虑到原始故障数据是序列数据,因此,本文基于 Transformer 设计诊断模块,旨在进一步特征提取的同时实现故障诊断。传统的 Transformer 是编码加解码的结构,将其直接应用到 TRU 故障诊断领域并不适用。本文舍去解码部分,设计一个分类器代替解码,在简化模型结构同时,提高模型诊断效率。基于 Transformer 的诊断模块是通过堆叠单个编码模块实现的。每个基础模块包含一个多头注意力机制(multi-head attention, MHA)、一个前馈神经网络(feedforward neural network, FNN)和残差连接与层归一化^[17-18]。

1) 多头注意力机制

MHA 是 Transformer 中一个核心部分,其主要思想是通过多个头并行地执行注意力操作,从而捕捉输入中不同位置间的关系。假设输入的故障样本数据是 $\mathbf{X} = [x_1, x_2, \dots, x_n]$ 每个向量的维度是 d ; 先将输入向量转换为查询(Q)、键(K)和值(V),公式为:

$$\mathbf{Q} = \mathbf{XW}_Q \quad (10)$$

$$\mathbf{K} = \mathbf{XW}_K \quad (11)$$

$$\mathbf{V} = \mathbf{XW}_V \quad (12)$$

式中: $\mathbf{W}_Q, \mathbf{W}_K, \mathbf{W}_V$ 是可学习权重。使用点积计算 Q 和 K 之间的相似度,并进行缩放:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{QK}^T}{\sqrt{d_K}}\right)\mathbf{V} \quad (13)$$

式中: d_K 是键的维度,用于缩放以避免数值过大。MHA 的思想就是重复上述过,让每个头使用不同的权重矩阵:

$$\text{Head}_i = \text{Attention}(\mathbf{QW}_{Q_i}, \mathbf{KW}_{K_i}, \mathbf{VW}_{V_i}) \quad (14)$$

式中: $\mathbf{W}_{Q_i}, \mathbf{W}_{K_i}, \mathbf{W}_{V_i}$ 表示第 i 个注意力头中 Q, K, V 的权重矩阵。最后将所有头的输出拼接起来并通过线性变换:

$$MHA(Q, K, V) = Concat(Head_1, Head_2, \dots, Head_k) W_o \quad (15)$$

式中: W_o 为最后线性变换的权重矩阵。多头注意力机制能够让模型关注局部和全局的重要特征,从而提高了模型的表达能力。

2) 前馈神经网络

前馈神经网络是一种基本的 ANN 结构,由输入层、隐藏层和输出层构成。信息在网络中单向流动,经过加权求和后,通过激活函数进行非线性变换,前馈神经网络将多头注意力提取到的特征映射为更加抽象的特征表达。考虑到 Relu 激活函数存在导数不连续且在负值部分存在死区现象,改用 GeLU 激活函数:

$$\sigma(Z) = Z \cdot \frac{1}{2} \left(1 + \operatorname{erf}\left(\frac{Z}{\sqrt{2}}\right) \right) \quad (16)$$

式中: $\operatorname{erf}(\cdot)$ 是误差函数,用以计算 Z 的高斯积分,这样可以使得 GeLU 具有平滑且单调的性质。此外引入 Dropout 机制避免前馈神经网络模型过拟合。

3) 残差连接加层归一化

残差连接加层归一化被添加在 Transformer 的 MHA 和 FNN 的输出部分,公式为:

$$O = LayerNorm(x + Sublayer(X)) \quad (17)$$

4) 分类层

利用 FNN 搭建一个故障分类器。该分类器结构包括一个全连接层和 Softmax 层。每个类别被预测的概率值如下:

$$P_j = \operatorname{Softmax}(Z_j) = \frac{e^{Z_j}}{\sum_{j=1}^K e^{Z_j}} \quad (18)$$

$$Z_j = XW_j + b_j \quad (19)$$

式中: P_j 是每个类别输出的概率; W_j 和 b_j 分别是全连接层的对应类别的可学习权重偏置; K 为类别数,利用极大似然准则即可实现 TRU 的故障诊断。

2.4 基于遗传算法的诊断模块超参数寻优模块

基于 Transformer 的诊断模块不同超参数组合直接影响收敛速度和诊断准确率。因此利用 GA 在求解空间自适应搜索问题的最优解^[19]。以诊断模块的准确率为目标函数,基本步骤包括初始化种群、评估适应度、选择优秀个体、交叉生成新个体以及变异以增加多样性。经过多代演化,种群逐渐逼近最优解本文遗传算法采用实值编码、模拟二进制交叉、多项式变异和轮盘赌选择,如图 6 所示。

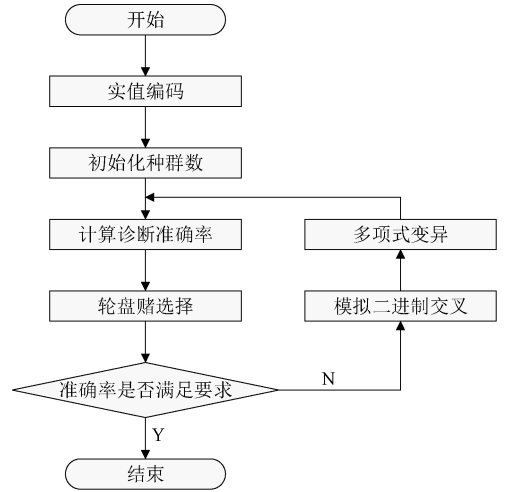


图 6 GA 优化流程

Fig. 6 GA optimization flowchart

3 仿真与实验

3.1 ITRU-12 仿真模型

文本利用 Simulink 对 ITRU-12 进行建模仿真,如图 7 所示。负载为纯电阻负载,仿真输出的电压电流的幅值、波纹等相关参数都满足 EMC 试验标准 DO-160G。

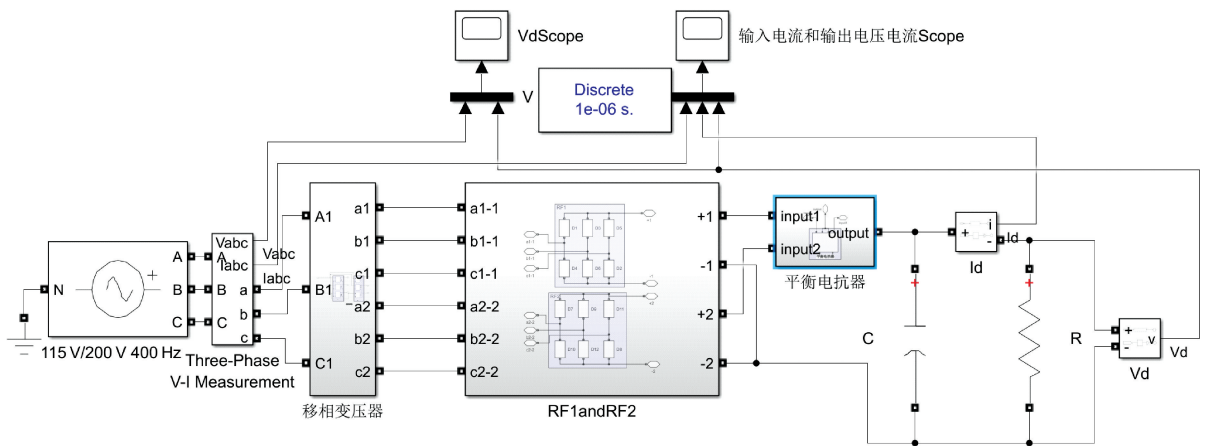


图 7 ITRU-12 仿真模型

Fig. 7 ITRU-12 simulation model

3.2 故障仿真与数据采集

将正常也视为一种故障模式 (Normal) 共 102 种故障,按 Normal、OCR、OCW、SDS、SDO、DDO 的顺序,为其从 0~101 打上对应的标签,如表 1 所示。设置仿真时间 0.6 s,采样频率为 1 000 kHz,将采集数据限制在

20 000 个点,以 ITRU-12 输入三相电流和整流输出的电压作为原始故障信号进行采集,每种故障采集 30 次,得到 3 060×20 000 原始数据集。之后将经过预处理的故障数据按照 7 : 3 的比例划分成训练集和测试集。

表 1 故障类别及样本分布

Table 1 Fault type and sample distribution

故障标签	故障模式	种类	样本数量	故障标签	故障模式	种类	样本数量
0	Normal	1 种	30	66~73	D4D50~D4D120	8 种	240
1~2	OCR1~OCR2	2 种	60	74~80	D5D60~D5D120	7 种	210
3~11	OCW1~OCW9	9 种	270	81~86	D6D70~D6D120	6 种	180
12~23	SD1S~SD12S	12 种	360	87~91	D7D80~D7D120	5 种	150
24~35	SD10~SD120	12 种	360	92~95	D8D90~D8D120	4 种	120
36~46	D1D20~D1D120	11 种	330	96~98	D9D100~D9D12	3 种	900
47~56	D2D30~D2D120	10 种	300	99~100	D10D110~D10D120	2 种	600
57~65	D3D40~D3D120	9 种	270	101	D11D120	1 种	300

3.3 TRU 故障诊断实验

1) 改进 SDAE 实验

改进 SDAE 特征提取模块的性能主要受到隐藏层数和隐藏层节点数等结构参数的影响。设定网络的结构参数为 3 层隐藏层,其中每层的节点数依次设置为 [1 000, 500, 250],训练优化器采用 Adam,模型学习率为 0.001。改进 SDAE 特征提取模块与传统 SDAE 特征提取模块,提取的故障特征利用 t-SNE 技术二维可视化,如图 8 所示。

由图 8(a)和 8(b)可知,相较于未改进 SDAE 的特征提取效果,本文方法有较大提升,从图 8(a)可以看出,绝大部分的故障特征都已经实现缩小类内间距,扩大类间间距,但仍有少部分依旧存在特征混淆问题,其中标签为 6 的 OCW4 和标签为 38 的 D1D40、标签为 7 的 OCW5 和标签为 59 的 D3D60、标签为 8 的 OCW6 和标签为 49 的 D2D50 几乎完全重叠,为此,需要进一步特征提取,以获得更好的故障特征表达。

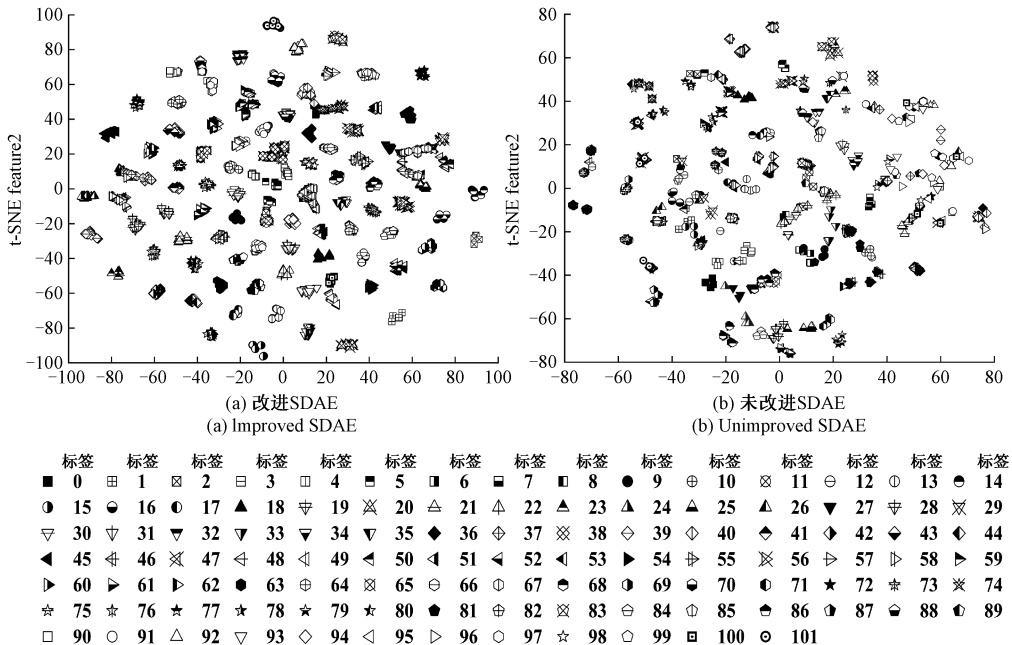


图 8 改进 SDAE 与未改进 SDAE 特征提取二维可视化

Fig. 8 Two-dimensional visualization of feature extraction with and without improved SDAE

2) 基于遗传算法优化 Transformer 的诊断模块实验

影响诊断模型性能的 5 个主要超参数,注意力机制的多头数 (MH)、编码块个数 (EN)、隐藏层节点数 (HD)、Dropout P 和学习率 (Lr),与之对应的超参数取值范围,如表 2 所示。

表 2 超参数及取值范围

Table 2 Hyperparameters and value ranges

超参数	超参数范围
MH	[2,10]
EN	[1,6]
HD	[16,256]
P	[0.01,0.2]
Lr	[0.01,0.000 01]

本文利用 GA 优化组合超参数,选取模型在训练集上的准确率作为目标函数,种群数量 50,交叉概率 0.7,变异概率 0.3,算法迭代 200 次,目标函数变化曲线如图 9 所示。




图 9 GA 超参数优化过程

Fig. 9 GA hyperparameter optimization process

经过 15 次迭代后,目标函数趋于稳定。在目标函数为最优值时获得一组超参数组合, MH 、 EN 、 HD 、 P 、 Lr 依次为 5、3、197、0.03、0.000 1,将超参数组合带入 Transformer 诊断模型训练,得到损失率和准确率变化曲线如图 10 所示。




图 10 训练准确率和损失率变化曲线

Fig. 10 Training accuracy and loss rate variation curves

经过 5 次迭代后训练准确率达到 95% 以上,迭代 100 次时,准确率可达 96.34%,且训练损失函数基本接近 0,验证了本文方法快速性和有效性。

图 11 所示为单次测试样本诊断结果图。204 个测试样本中只有 32、71、83、94、124、138、170、183 号样本共计 8 个样本诊断错误,故障诊断准确率有 96.07%。图 11 中,纵轴表示每种故障类别标签,故标签范围是 0~101。




图 11 测试集故障诊断结果

Fig. 11 Diagram of test set troubleshooting results

对模型进行 20 次诊断试验,计算其平均准确率作为诊断准确率,可得模型在训练集上诊断准确率为

96.14%,测试集上诊断准确率为 96.05%,训练集准确率与测试集准确率差别较小,表明基于 GATransformer 的诊

断模型经过训练后性能良好,也表明此算法对 TRU 故障故障定位到元件具有较好的诊断效果。

3) 与其他算法对比

为验证模型的有效性,与 SDAE-PSOSVM^[12]、CNN^[13]、ResNet-BiLSTM^[20] 模型进行对比实验,每个模型进行 20 次重复实验,每次迭代 100 次,得到对应模型的诊断准确率 (precision)、召回率 (recall)、F1 得分 (F1-Score) 和每次输出所需时间取均值,实验结果如表 3 所

表 3 不同模型性能对比

Table 3 Performance comparison of different models

序号	模型名称	Precision/%	Recall/%	F1-Score	测试时间/s
1	本文	96.05	96.34	0.96	0.133 2
3	SDAE-PSOSVM	82.02	82.34	0.82	0.073 0
4	CNN	90.69	90.72	0.91	0.701 2
5	ResNet-BiLSTM	91.48	91.57	0.92	2.530 2

由表 3 可以看出,在 100 次迭代的情况下,本方法在 Precision、Recall 和 F1-Score 三个方面均展现出优于其他 3 种模型的表现。与其他 3 个模型中最高性能的 ResNet-BiLSTM 模型相比,本文方法分别提高 5.00%、5.21% 和 4.21%,与最低性能的 SDAE-PSOSVM 相比,本方法分别提高 17.1%、17.00% 和 17.07%。

其次,由表 3 中测试时间对比结果可知,尽管本文方法的单次测试所需时间略长于 SDAE-PSOSVM 的 0.073 0 s,达到 0.133 2 s。但本文所提方法的诊断效率依旧可以满足实际 TRU 离线或在线检测需求。

4) 模型抗噪性能实验

为验证所提方法的抗噪性能,在测试集上添加不同信噪比的高斯白噪声进行对比测试,诊断结果如表 4 所示。

表 4 不同信噪比对诊断结果影响

Table 4 Effect of different SNR on diagnostic results

信噪比/dB	准确率/%
20	94.55
25	95.45
30	95.64
35	95.78
40	95.92
45	95.78
50	95.92
无噪声	96.05

由表 4 可知,当信噪比从 20~50 dB 变化时,本文方法依有 94.55% 以上的诊断准确率。测试集无噪声时诊断准确率为最高,为 96.05%。随着噪声含量的增大,测试集的诊断准确率有小幅下降,当信噪比为 20 dB 时,测试集的准确率为最低,为 94.55%,与无噪声相比相差了 1.5%。可以认为本文所提方法具有良好的抗噪能力,

其中 Recall 的计算公式为:

$$Recall = \frac{T}{T + F} \quad (20)$$

式中: T 为诊断正确的样本数; F 为诊断错误的样本数。

F1-Score 计算公式如下

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (21)$$

能够应对 TRU 故障诊断时出现的噪声情况。

4 结 论

本文提出了基于改进 SDAE-GATransformer 的 TRU 故障诊断方法,并将其应用于飞机电源设备 TRU 的故障诊断。利用 TRU 三相输入电流数据和整流输出电压数据实现其硬件故障定位到元件,得出如下结论:

1) 在 TRU 故障类别过多且不同故障模式的数据类似情况下,在传统 SDAE 中引 CCL 函数,可高效实现类内间距缩小,类间间距扩大的故障特征提取。

2) 简化 Transformer 结构,舍去其解码块部分以便适用于航空变压整流器的故障分类,并利用 GA 优化模块超参数实现高效的故障诊断。

3) 通过对比实验该方法在 101 种故障模式下可以较为准确的实现故障分类,准确率达 96.05%,且具有良好的抗噪能力,为相关故障诊断研究提供了一种新的思路。

但由于 TRU 硬件故障模式特征复杂多变,所提方法在特征提取和诊断上仍有提升空间。下一步将针对 TRU 故障特点,结合多源数据融合的方式,实现高效的 TRU 故障诊断。

参考文献

- [1] 史艳博,葛红娟,王永帅,等. 基于无源电压纹波注入的 24 脉航空交直流变换器[J]. 哈尔滨工程大学学报, 2024, 45(3): 590-598.
SHI Y B, GE H J, WANG Y SH, et al. A 24-pulse air-to-air AC-DC converter based on passive voltage ripple injection[J]. Journal of Harbin Engineering University, 2024, 45(3): 590-598.
- [2] 陈涛,陈小强,王英,等. 一种新型升压 18 脉波自耦变压整流器的研究[J]. 电网技术, 2021, 45(4):

- 1527-1535.
- CHEN T, CHEN X Q, WANG Y, et al. Research on a new type of boosted 18-pulse wave autocoupled variable rectifier[J]. *Grid Technology*, 2021, 45(4):1527-1535.
- [3] YANG C, ZHANG F, CHENG L, et al. Open-circuit fault research on asymmetric delta-polygon 18-Pulse autotransformer rectifier unit for more electric aircraft[C]. *IEEE Transactions on Power Electronics*, 2022: 14615-14630.
- [4] LIN Y, GE H, CHEN S, et al. Two-level fault diagnosis RBF networks for auto-transformer rectifier units using multi-source features[J]. *Journal of Power Electronics*, 2020, 20(2):754-763.
- [5] 杨彦杰,董哲,姚芳,等. 基于 1D-CNN-LSTM 混合神经网络模型的双桥并联励磁功率单元故障诊断[J]. *电网技术*, 2021, 45(5):2025-2032.
- YANG Y J, DONG ZH, YAO F, et al. Fault diagnosis of double-bridge parallel excitation power unit based on 1D-CNN-LSTM hybrid neural network model[J]. *Grid Technology*, 2021, 45(5):2025-2032.
- [6] 尹项根,乔健,贺儒飞,等. 基于 FFT-LSTM 的变速抽蓄机组转子绕组短路故障和偏心故障诊断方法[J]. *电力系统保护与控制*, 2023, 51(6):73-81.
- YIN X G, QIAO J, HE R F, et al. FFT-LSTM-based diagnosis method for short-circuit faults and eccentricity faults in rotor windings of variable-speed pumped storage units[J]. *Power System Protection and Control*, 2023, 51(6):73-81.
- [7] 白辉,许志红. 基于小波包变换和高阶累积量的电弧故障识别方法[J]. *电力自动化设备*, 2020, 40(11):195-202, 224, 203.
- BAI H, XU ZH H. Arc fault identification method based on wavelet packet transform and high-order accumulation[J]. *Power Automation Equipment*, 2020, 40(11):195-202, 224, 203.
- [8] WANG F, HE P, ZHOU C, et al. A fault diagnosis method for rectifier-filter circuit integrating EEMD algorithm and transformer network[J]. *Journal of Physics Conference Series*, 2024, DOI: 10.1088/1742-6596/2762/1/012054.
- [9] 梁郑秋,郝亮亮,周艳真,等. 基于卷积神经网络的核电多相无刷励磁系统旋转整流器故障诊断[J]. *电工技术学报*, 2023, 38(20):5458-5472.
- LIANG ZH Q, HAO L L, ZHOU Y ZH, et al. Convolutional neural network-based fault diagnosis of rotating rectifier in nuclear power multiphase brushless excitation system [J]. *Journal of Electrotechnology*, 2023, 38(20):5458-5472.
- [10] 董慧芬,郑坤,杨占刚. 基于 GA-BRBPNN 的航空自耦变压整流器故障诊断方法[J]. *电子测量与仪器学报*, 2022, 36(9):217-225.
- DONG H F, ZHENG K, YANG ZH G. Fault diagnosis method of aviation autocoupled variable voltage rectifier based on GA-BRBPNN [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(9):217-225.
- [11] XIANG Y, LIU F, LI Z. Fault diagnosis for transformer rectifier unit on more-electric aircraft[C]. *2022 IEEE 5th International Electrical and Energy Conference (CIEEC)*, 2022:4039-4044.
- [12] 石旭东,徐海义,吴东华,等. 基于 SDAE-PSOSVM 的航空变压整流器故障诊断方法研究[J]. *北京理工大学学报*, 2021, 41(10):1069-1076, 1083.
- SHI X D, XU H Y, WU D H, et al. Fault diagnosis method for aviation transformer rectifier unit based on SDAE-PSOSVM[J]. *Transactions of Beijing Institute of Technology*, 2021, 41(10):1069-1076, 1083.
- [13] CHEN S, GE H, LI H, et al. Hierarchical deep convolution neural networks based on transfer learning for transformer rectifier unit fault diagnosis [J]. *Measurement*, 2021, 167:108257.
- [14] DU X J, JIA L L, HAQ I U. Fault diagnosis based on SPBO-SDAE and transformer neural network for rotating machinery[J]. *Measurement*, 2022, 188:110545.
- [15] CHENG Z, DAI M, LIU J, et al. Life prediction of IGBT module for nuclear power plant rod position indicating and rod control system based on SDAE-LSTM [J]. *Nuclear Engineering and Technology*, 2024, 56(9):3740-3749.
- [16] QI C, SU F. Contrastive-center loss for deep neural networks[C]. *2017 IEEE International Conference on Image Processing (ICIP)*, 2017:2851-2855.
- [17] 周海成,石恒初,曾令森,等. 基于关系超图增强 Transformer 的智能站二次设备故障诊断研究[J]. *电力系统保护与控制*, 2024, 52(12):123-132.
- ZHOU H CH, SHI H CH, ZENG L S, et al. Research on fault diagnosis of secondary equipment of intelligent station based on relational hypergraph enhanced Transformer[J]. *Power System Protection and Control*, 2024, 52(12):123-132.
- [18] 刘晨宇,李志农,熊鹏伟,等. 融合路径聚合网络的 Swin Transformer 的故障诊断方法研究[J]. *振动与冲击*, 2024, 43(18):258-266.
- LIU CH Y, LI ZH N, XIONG P W, et al. Research on fault diagnosis method of Swin Transformer with fused path aggregation network [J]. *Vibration and Shock*, 2024, 43(18):258-266.

- [19] 和征,张同静,杨小红. 基于 BP 神经网络和遗传算法的设备故障诊断与健康模型研究[J]. 制造技术与机床, 2024(11):9-15.

HE ZH, ZHANG T J, YANG X H. Research on equipment fault diagnosis and health management model based on BP neural network and genetic algorithm[J]. Manufacturing Technology and Machine Tools, 2024(11):9-15.

- [20] 张建良,季瑞松. 基于贝叶斯优化 ResNet-BiLSTM 的多电飞行器故障检测技术[J]. 实验技术与管理, 2024, 41(10):10-17.

ZHANG J L, JI R S. Fault detection technique for multi-electric vehicle based on Bayesian optimization ResNet-BiLSTM[J]. Experimental Technology and Management, 2024,41(10):10-17.

作者简介



李耀华, 1996 年于辽宁工程技术大学获得学士学位, 2002 年于辽宁工程技术大学获得硕士学位, 2005 年于大连理工大学获得博士学位, 现为中国民航大学教授, 主要研究方向为维修工程分析和智能优化。

E-mail: yh_li@cauc.edu.cn

Li Yaohua received his B. Sc. degree from Liaoning University of Engineering and Technology in 1996, M. Sc. degree

from Liaoning University of Engineering and Technology in 2002, and Ph. D. degree from Dalian University of Science and Technology in 2005, respectively. Now he is a professor in Civil Aviation University of China. His main research interests include maintenance engineering analysis and intelligent optimization.



杨通江 (通信作者), 2023 年于中国民航大学获得学士学位, 现为中国民航大学硕士研究生, 主要研究方向为航空器智能维修。

E-mail: 1765231723@qq.com

Yang Tongjiang (Corresponding Author)

received his B. Sc. degree from Civil Aviation University of China in 2023. Now he is a M. Sc. candidate in Civil Aviation University of China. His main research interest includes intelligent maintenance of aircraft.



张宇, 2022 年于西华大学获得学士学位, 现为中国民航大学硕士研究生, 主要研究方向为航空器运维。

E-mail: z329284563@163.com

Zhang Yu received his B. Sc. degree

from Xihua University in 2022. Now he is a M. Sc. candidate in Civil Aviation University of China. His main research interests include aircraft operations and maintenance.