DOI:10.12177/emca.2026.241 文章编号:1673-6540(2026)11-1130-15 中图分类号:TM 341 文献标志码:A

基于改进 SBOA-VMD-S4D 的航空三级式发电机旋转整流器故障诊断技术

陈启源, 崔 江*
(南京航空航天大学 自动化学院,江苏 南京 211106)

Fault Diagnosis Technology for Rotating Rectifiers in Aviation Three-Stage Generators Based on Improved SBOA-VMD-S4D

Chen Qiyuan, Cui Jiang*
(College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: [Objective] The aviation three-stage generator is the core equipment of the airborne power supply system. The rotating rectifier of the generator operates for extended periods under harsh airborne environments characterized by high temperature, high speed, and intense vibration, making its diodes highly susceptible to open-circuit faults. Once a diode fails open, the rectification path of the corresponding phase is cut off, directly causing distortion of the rectified output voltage waveform and a drop in direct current output voltage. If such a fault is not detected promptly, it will directly endanger flight safety. **[Methods]** To address the above issues, this paper proposed a fault diagnosis method based on an improved secretary bird optimization algorithm (SBOA) for optimizing variational mode decomposition (VMD), combined with a diagonal structured state space sequence (S4D) model. The improved SBOA was used to adaptively optimize the number of modes K and the bandwidth penalty factor α of VMD. By streamlining the original three-stage hunting strategy of SBOA and introducing a Lévy flight exploration mechanism and an exponential decay contraction mechanism, a balance between global exploration and local exploitation was achieved. Meanwhile, a dual-objective weighted fitness function that balanced decomposition quality and computational efficiency was designed. Firstly, the excitation current signal was preprocessed, and the optimized VMD was adopted to decompose it into several intrinsic mode components. Then, the obtained components were normalized and divided into sliding-window patches. The S4D model was used to learn discriminative energy and temporal features within the components to realize the classification of five types of fault modes. Finally, simulations and experiments were carried out to verify the effectiveness of the proposed method. **[Results]** The experimental results showed that the proposed method achieved an average diagnosis accuracy of over 98.5% under multiple operating conditions. Compared with traditional methods, it had significant advantages in accuracy and cross-load transfer capability, and maintained stable accuracy especially under high-load conditions. **[Conclusion]** The improved SBOA-VMD-S4D fault diagnosis method proposed in this paper can effectively separate fault information and exhibits strong classification performance and cross-load generalization capability. It provides an accurate and efficient technical solution for fault diagnosis of rotating rectifiers in three-stage aviation generators.

Key words: rotating rectifier; aviation three-stage generator; secretary bird optimization algorithm; variational mode decomposition; diagonal structured state space sequence model; fault diagnosis

摘 要:【目的】航空三级式发电机是机载供电系统的核心设备,发电机旋转整流器长期工作于高温、高速及强振动的恶劣机载环境下,其二极管极易发生开路故障。一旦某个二极管开路,对应相的整流路径被切断,引发整流输出电压波形失真、直流输出电压下降。若此类故障未能被及时检测,将直接威胁飞行安全。**【方法】**针对上述问题,本文提出一种基于改进秘书鸟优化算法(SBOA)优化变分模态分解(VMD)并结合对角结构化状态空间序列(S4D)模型的故障诊断方法。采用改进 SBOA 对 VMD 的模态分量数 K 和带宽惩罚因子 α 进行自适应寻优。通过

基金项目: 航空科学基金(201933052001)
Aeronautical Science Foundation of China (201933052001)

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

精简 SBOA 原有三阶段狩猎策略,并引入 Lévy 飞行探索机制和指数衰减收缩机制,实现全局探索与局部开发之间的平衡。同时设计兼顾分解质量与计算效率的双目标加权适应度函数。首先对励磁电流信号进行预处理,采用优化后的 VMD 将其分解为多个本征模态分量。然后,对所得分量进行归一化和滑动窗口划分,利用 S4D 模型学习其中具有判别力的能量与时序特征,实现五类故障模式分类。最后,通过仿真和试验验证所提方法的有效性。【结果】试验结果表明,所提方法在多工况下的平均诊断准确率超过 98.5%,相比传统方法在准确率和跨负载迁移能力上优势明显,尤其在较高负载工况下仍保持稳定精度。【结论】本文所提改进 SBOA-VMD-S4D 故障诊断方法能够有效分离故障信息,并具有较强的分类性能和跨负载泛化能力,可为航空三级式发电机旋转整流器故障诊断提供准确、高效的技术方案。

关键词:旋转整流器;航空三级式发电机;秘书鸟优化算法;变分模态分解;对角结构化状态空间序列模型;故障诊断

0 引言

作为多电/全电飞机的核心供电装置,三级式航空发电机承担着为机载仪表、雷达、通信设备及各类控制系统输送电能的任务,其内部结构主要包括永磁励磁机、交流励磁机、主发电机及旋转整流器等[1-2]。该类发电机通常持续运行在恶劣工况下,因此其运行安全性与可靠性非常重要。一旦发电机出现故障,航空电源系统的供电能力将受到直接冲击,情况严重时甚至会造成全机断电、飞机失事。围绕发电机及其组件开展故障检测技术研究,能够为飞机故障预测与健康管理领域提供有价值的技术支撑。

按照 CIGRE 分类标准,发电机故障可归纳为电气类与机械类两大类别[3]。其中整流部件故障是发电机电气类故障中的典型故障,也是关键性故障[4]。目前,针对航空三级式发电机旋转整流器的故障诊断方法大致可归为三类[5]。

(1)数学建模方法。该类方法需要对发电机运行机理有透彻理解并掌握其关键参数,从而搭建出精度较高的系统模型,将模型的输入输出结果与发电机实测数据进行比对,借助残差及相关性分析完成故障仿真、特征提取以及诊断。文献[6]将励磁机等效为倒置结构的同步发电机,通过励磁绕组谐波分析实现整流桥故障检测;文献[7]提出电流—磁链神经网络嵌入 dq 模型的建模方法,兼顾非线性特性与仿真效率;文献[8]基于 Simulink 搭建三级式发电系统仿真模型;文献[9]基于混合系统建模思路表征旋转二极管故障。数学建模方法的准确性很大程度上依赖于仿真模型与实际设备之间的贴合程度。然而,航空发电机结构复杂、耦合参数众多,建立既精确又具备工程可用性的数学模型难度较大,因此该类方法难以大规模推广应用。

(2)信号处理方法。此类方法通过采集发电机电压、电流等观测信号,利用频域、时频分析手段提取故障特征。文献[10-11]分别基于谐波分析、傅里叶分解建立故障与谐波特征间的对应关系;文献[12]提出基于快速傅里叶变换(Fast Fourier Transform, FFT)的角度轨迹监测技术,通过观察连续特征轨迹实现在线诊断;文献[13]利用转子电流矢量模的畸变特性,实现不依赖位置信息的故障识别;文献[14-16]围绕主励磁机转子电流轨迹的中心距、中心角和长宽比三种几何特征展开研究,三者分别对应故障检测、故障二极管定位与故障类别判定;文献[17]围绕主励磁机转子电流展开研究,提出一种可实现旋转部件电气故障检测与定位的方法;文献[18]基于励磁电流幅值提出改进方案,首次实现了系统起动、静止与发电全过程的旋转整流器诊断。信号处理方法工程可实现性强、物理意义明确,但故障特征的提取与判据阈值的设定高度依赖人工经验,难以自适应处理航空励磁电流这类强非平稳、非线性信号,在变工况条件下泛化能力有限。

(3)人工智能方法。随着深度学习理论的发展与计算机硬件的进步,深度网络被应用于故障诊断。基于深度学习的故障诊断方法通过建立合适的数学模型,将能够反映故障特征的训练样本输入模型中,由网络自动完成故障信号的特征提取与类别判别。文献[19]将混合逻辑动态模型与自适应阈值判据结合,用于牵引整流器绝缘栅双极型晶体管开路故障定位;文献[20]提出基于相电流幅值与相位关系的强鲁棒性故障诊断算法,可在一个基波周期内完成故障识别且计算量较小;文献[21]采用人工神经网络实现旋转整流器故障自动分类;文献[22]将互补式集合经验模

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

态分解与樽海鞘算法优化的极限学习机结合,用于航空三级式发电机整流器故障诊断;文献[23]基于长短期记忆网络(Long Short-Term Memory, LSTM)实现故障分类;文献[24]将时序诊断问题转化为图像识别任务,借助卷积神经网络(Convolutional Neural Network, CNN)与深度迁移学习缓解实际故障样本稀缺的问题。人工智能方法诊断精度较高,但其性能很大程度上依赖训练样本的数量与质量,在小样本、强变工况的航空实际场景下容易出现过拟合或迁移能力不足的问题。

综合以上研究,三类方法各有优劣:数学建模方法在模型较好的情况下诊断效果好但建模困难;信号处理方法工程性可实现性强但特征提取依赖人工设计的阈值,难以处理非平稳信号,变工况适应能力较弱;人工智能方法诊断精度高但对样本依赖性强。若能将信号处理方法在故障特征提取方面的优势与人工智能方法在特征学习与分类决策方面的优势相结合,则可在保证诊断精度的同时提升对变工况复杂航空运行环境的适应能力。因此,本文结合信号处理与人工智能方法,提出一种基于改进秘书鸟优化算法(Secretary Bird Optimization Algorithm, SBOA)优化变分模态分解(Variational Mode Decomposition, VMD)并结合对角结构化状态空间序列模型(Diagonal Structured State Space Model, S4D)的故障诊断方法。首先利用改进 SBOA 自适应优化 VMD 的模态分量数和带宽惩罚系数;然后用优化的 VMD 对航空三级式发电机交流励磁机励磁电流信号进行分解,提取各本征模态函数(Intrinsic Mode Function, IMF)分量的能量熵特征;随后对各 IMF 执行滑窗 Patch 提取,作为 S4D 的输入;最后利用 S4D 完成多类故障诊断。

需要说明的是,本文所提方法的诊断粒度为故障类型级别,即判定故障属于五类模式中的哪一类,而不进一步定位到具体发生开路故障的二极管编号。其原因在于交流励磁机的电枢绕组位于转子侧,励磁绕组位于定子侧,不同相别的二极管故障所引起的电枢电流不对称经转子旋转的频率搬移效应后,在定子励磁电流中激励出的谐波特征具有高度相似性,仅凭励磁电流信号难以区分同一故障类型下不同相别的具体故障二极管。

1 航空三级式发电机旋转整流器故障分析

航空三级式发电机旋转整流器结构如图 1 所示。依据其开路故障表现形式,划分为五个类别,如表 1 所示。

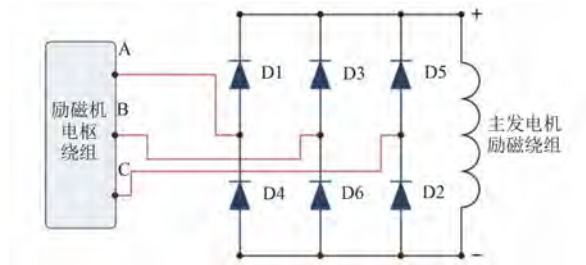


图 1 旋转整流器结构图

Fig. 1 Rotating rectifier structure diagram

表 1 故障模式

Tab. 1 Fault modes

故障模式	类别	类别说明	故障二极管
健康模式	I	正常状态	--
单管开路故障	II	单个二极管开路故障	D1、D2、D3、D4、D5、D6
	III	同一桥臂上的 2 个二极管开路故障	D1D4、D2D5、D3D6
双管开路故障	IV	不同桥臂上的 2 个二极管开路故障(同为上桥臂或同为下桥臂)	D1D3、D1D5、D3D5、D2D4、D4D6、D2D6
	V	不同桥臂上的 2 个二极管开路故障(1 个在上桥臂、1 个在下桥臂)	D1D2、D2D3、D3D4、D4D5、D5D6、D1D6

在旋转整流器各类故障中,二极管开路故障出现频率最高。当某二极管发生开路时,对应相的整流路径被切断,导致三相电枢电流出现不对称畸变,进而引起整流输出电压波形失真和直流输出电压下降。若不及时诊断,轻则影响发电机供电质量,重则导致整机停转,威胁飞行安全。

交流励磁机的电枢绕组位于转子侧,励磁绕组位于定子侧,两者间的磁场耦合系数随转子角度周期变化。根据谐波电枢理论[25],转子侧电枢电流中频率为 $n\omega$ 的谐波分量,经过转子旋转产

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

生的频率搬移效应(频移量等于基频 ω)，在定子励磁绕组中激励出频率为$(n-1)\omega$ 和$(n+1)\omega$ 的感应分量。

当整流二极管发生开路故障时，交流励磁机电枢电流的对称性遭到破坏，不同相和不同方向的电流发生畸变，从而在电流信号中产生特征性的谐波分量变化，励磁电流中也将出现谐波分量。由于电枢绕组位于转子侧，难以直接测量电流；而励磁绕组位于定子固定侧，可直接采集励磁电流，相较于旋转整流器本身的电流或电压信号，具有显著的工程可实现性优势，所以本文选用交流励磁机励磁电流作为故障信号。

2 基于改进 SBOA-VMD-S4D 的故障诊断方法

2.1 VMD

VMD 是基于经验模态分解(Empirical Mode Decomposition，EMD)的改进算法。EMD 把结构复杂的混合信号拆解为若干具有明确物理含义且振荡形式相对简单的 IMF 分量。旋转整流器发生二极管开路故障时，励磁电流信号的频率成分和幅值随时间动态变化，呈现出显著的非平稳特性。相对于传统傅里叶变换或小波变换，EMD 可以应对非平稳信号且具有自适应性。

但是，EMD 存在模态混叠问题，且其缺乏严格的数学理论支撑，分解结果高度依赖外部极值点寻找方法和停止准则。因此本文采用 VMD[26]，将模态分解问题转变为变分最优化问题，目标是找到一组具有特定中心频率的模态，使所有模态的带宽之和最小，并且这些模态加起来能重构原始信号。VMD 解决了模态混叠问题，同时具有严格的数学理论基础，且分解结果更稳定精确。

对第 k 个模态 u_k 作 Hilbert 变换得到解析信号后，把模态移动到基带，然后对时间求导得到频域偏移量，最后计算其范数平方，最小化范数平方即可得到最佳 VMD。如式(1)所示：

$$\min_{\{u_k\},\{\omega_k\}} \sum_{k=1}^{K} \left\| \partial_t \left[\left(\delta(t) + \frac{\mathrm{j}}{\pi t} \right) \times u_k(t) \right] \mathrm{e}^{-\mathrm{j}\omega_k t} \right\|_2^2 \tag{1}$$

式中：ω_k 为第 k 个模态的中心频率；$\delta(t)$ 为单位冲激函数；$\mathrm{j}/\pi t$ 为 Hilbert 变换的冲激响应核；K 为模态分量数，即信号被分解的 IMF 分量数。

本文借助交替方向乘子法依次对三组变量分别进行子优化，通过循环迭代直至结果收敛。

2.2 改进 SBOA 优化 VMD

VMD 的质量由模态分量数 K 和带宽惩罚系数 α 两个超参数共同决定。K 决定信号在频域的划分粒度。K 取值偏小时，具有不同频率特征的成分将被强制合并至同一 IMF 中，各故障类型间的特征被淹没；K 取值偏大时，VMD 会生成无实际意义的虚假模态，降低特征信噪比。α 控制各 IMF 带宽的约束强度。α 取值偏小时约束力弱，相邻 IMF 分量间存在频率重叠；α 取值偏大时约束力强，IMF 分量部分有效频率流失。

旋转整流器故障时，其励磁电流信号的频率成分随故障类型不同而呈现显著差异，且不同负载工况下信号幅值和频谱分布均存在变化，难以通过人工经验确定一组对所有工况均适用的固定参数。因此本文通过改进 SBOA 对 K 和 α 进行自适应寻优。

SBOA 是一种基于种群的元启发式算法[27]，该算法划分为探索与开发两个阶段，两个阶段受终止准则约束，重复迭代直至找到优化问题的最优解。

SBOA 将整个狩猎过程划分为三个相等的时间间隔，采用 3 种不同的策略，考虑到 VMD 优化参数空间仅 2 维，原三阶段结构冗余，因此本文仅采用一种策略。并且，SBOA 中每个个体每轮顺序执行探索和开发阶段，本文采用单次概率分支，以减小计算量。在每次迭代时生成随机数，如果小于 0.5 则进入探索阶段，大于等于 0.5 则进入开发阶段。

为平衡分解质量与计算效率，本文构造了双目标加权综合适应度函数，以一个权重系数控制两项目标的相对比重。改进 SBOA 以最小化综合适应度 F 为目标，执行 Lévy 飞行探索与收缩开发两种更新策略。探索阶段引入重尾 Lévy 随机步长，使种群具备跳出局部最优的能力；开发阶段采用指数衰减收缩因子，随迭代推进逐步向当前全局最优收敛。两种策略以 0.5 的等概率随机切换，兼顾全局搜索广度与局部精细程度，优化结束后输出最优参数 K^*、α^*。SBOA 流程如图 2

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

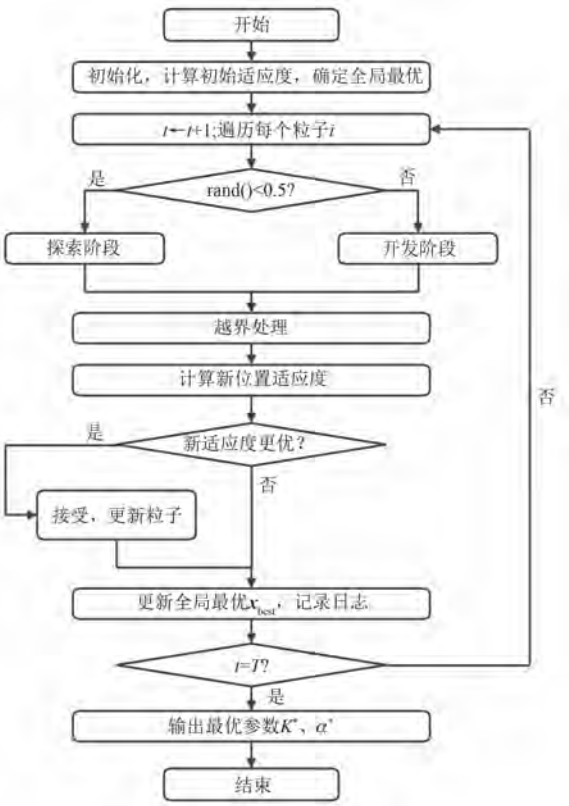


图 2 SBOA 流程

Fig. 2 Flowchart of the SBOA

所示。

在 SBOA 中,每只秘书鸟被视为种群的一个成员,搜索空间中每只秘书鸟的位置代表优化问题的候选解。采用式(2)对秘书鸟在搜索空间中的位置进行随机初始化。

$$X_{i,j} = lb_j + r \times (ub_j - lb_j),$$
$$i = 1,2,\cdots,N, j = 1,2,\cdots,Dim \tag{2}$$

式中:$X_{i,j}$ 为第 i 个个体第 j 维搜索的当前位置;ub_j、lb_j 分别为第 j 维搜索的上、下界;$r \in [0,1]$;Dim 为搜索空间维数;N 为种群规模。

双目标加权综合适应度函数如式(3)所示:

$$F(K,\alpha) = (1-w) \cdot H_{\text{norm}} + w \cdot T_{\text{norm}} \tag{3}$$

式中:H_{norm} 为所有 IMF 瞬时包络归一化信息熵的均值;T_{norm} 为 K 与搜索空间上限 $K_{\max}=6$ 之比,$T_{\text{norm}} \in [1/3, 1]$;$w$ 为权重系数,$w \in [0,1]$,当 $w=0$ 时退化为原始纯质量优先方案,本文取 $w=0.3$,在保证分解质量的前提下对较大的 K 施加适度惩罚。

采用信号长度 L 的理论熵上界 $\ln L$ 将 H_{norm} 归一化至区间[0, 1]:

$$H_{\text{norm}} = -\frac{1}{N_{\text{ref}} \cdot K \cdot \ln L} \times \sum_{i=1}^{N_{\text{ref}}} \sum_{k=1}^{K} \sum_{t=1}^{L} p_{i,k}(t) \ln[p_{i,k}(t)] \tag{4}$$

式中:$p_{i,k}(t)$ 为第 i 条参考信号第 k 个 IMF 的希尔伯特包络归一化概率;N_{ref} 为用于计算适应度的参考信号数量。

探索阶段的位置更新规则为

$$\boldsymbol{x}_i^{\text{new}} = \boldsymbol{x}_i + \boldsymbol{r}_1 \odot (\boldsymbol{x}_{\text{best}} - \boldsymbol{x}_i) \odot L(\lambda) + \boldsymbol{r}_2 \odot (\boldsymbol{x}_{\text{best}} - \bar{\boldsymbol{x}}) \tag{5}$$

式中:$\boldsymbol{r}_1$、$\boldsymbol{r}_2$ 为独立随机缩放向量,用于控制两个分量的贡献权重,$\boldsymbol{r}_1$, $\boldsymbol{r}_2 \sim U(0, 1)^2$;$L(\lambda)$ 为 Lévy 飞行步长,λ 为 Lévy 飞行指数;$\odot$ 为逐元素乘积;$\boldsymbol{x}_i$ 为第 i 个秘书鸟的位置向量;$\boldsymbol{x}_{\text{best}}$ 为当前种群的全局最优位置向量;$\boldsymbol{x}_i^{\text{new}}$ 为更新后的位置向量;$\bar{\boldsymbol{x}}$ 为当前种群所有个体位置的均值向量。

Lévy 飞行是一类步长服从重尾分布的随机游走,其特征是绝大多数步长较短,但偶尔出现极大跳跃,能有效跳出局部最优。Lévy 分布的概率密度函数如式(6)所示:

$$P(L) \sim L^{-(1+\lambda)}, 0 < \lambda \leqslant 2 \tag{6}$$

为了防止步长过大导致粒子飞出搜索空间太远,对步长幅值设限,设定限幅上限为 0.5,即每步最多在当前值基础上偏移 0.5($ub-lb$)的比例步长,约束搜索幅度。

开发阶段模拟秘书鸟躲避天敌时的收缩行为,位置更新规则为

$$\boldsymbol{x}_i^{\text{new}} = \boldsymbol{x}_{\text{best}} + \mathrm{e}^{-5t/T} \cdot (\boldsymbol{x}_i - \boldsymbol{x}_{\text{best}}) + \boldsymbol{N}(0,1)^2 \cdot \left(1 - \frac{t}{T}\right) \cdot (ub - lb) \tag{7}$$

式中:t 为当前迭代次数;T 为最大迭代次数;$\mathrm{e}^{-5t/T}$ 为收缩因子;$\boldsymbol{N}(0,1)^2$ 为由两个相互独立的标准正态随机变量构成的二维随机向量。

当 $t=0$ 时,收缩因子为 1,个体可在 $\boldsymbol{x}_{\text{best}}$ 附近大范围搜索;随着迭代推进,指数衰减使个体逐渐向 $\boldsymbol{x}_{\text{best}}$ 聚拢,收缩速度取决于衰减率。

探索和开发分支以 50% 的概率独立选择,并通过各自的时变因子实现自适应平衡。在探索分支中,迭代早期 Lévy 大步跳跃加上均值引导,搜索范围广;迭代中期 Lévy 步长随机波动,保持多样性;迭代后期均值项驱动向 $\boldsymbol{x}_{\text{best}}$ 聚拢。在开发分支中,迭代早期收缩因子为 1,保留多样性;迭

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

代中期开始收缩在 $\boldsymbol{x}_{\text{best}}$ 邻域;迭代后期收缩因子接近 0,精确跟随 $\boldsymbol{x}_{\text{best}}$。两阶段协同作用,使算法在整个迭代过程中既能保持全局探索能力,又能随时间逐步收敛到高精度局部解。无论探索分支还是开发分支,新位置均通过贪心策略决定是否接受,如式(8)所示:

$$\boldsymbol{x}_i \leftarrow \begin{cases} \boldsymbol{x}_i^{\text{new}}, & J(\boldsymbol{x}_i^{\text{new}}) < J(\boldsymbol{x}_i) \\ \boldsymbol{x}_i, & \text{其他} \end{cases} \tag{8}$$

式中:$J(\,)$为个体的适应度函数。

同时更新全局最优:

$$\boldsymbol{x}_{\text{best}} \leftarrow \begin{cases} \boldsymbol{x}_i^{\text{new}}, & J(\boldsymbol{x}_i^{\text{new}}) < J_{\text{best}} \\ \boldsymbol{x}_{\text{best}}, & \text{其他} \end{cases} \tag{9}$$

式中:J_{best} 为当前全局最优个体 $\boldsymbol{x}_{\text{best}}$ 对应的适应度值。

2.3 S4D 原理

经 VMD 得到 K^* 个 IMF 后,每条信号变为维度为 $K^* \times L$ 的多通道时序矩阵,本文参考视觉 Transformer 中的图像分块思想,对每个 IMF 沿时间轴做滑动窗口分块,将长序列切分为若干短 Patch,使模型能够在更细粒度上捕捉各时段的局部频率特征。

S4D 模型是一种在参数初始化上进行优化的状态空间序列(Structured State Space Sequence, S4)模型。状态空间模型(State Space Model, SSM)源自于控制理论,是描述线性动态系统输入、状态和输出关系的基础框架。对于给定输入向量 $\boldsymbol{u}(t)$,SSM 通过 N 维隐状态 $\boldsymbol{x}(t)$ 将其映射为输出 $\boldsymbol{y}(t)$,其连续时间形式为

$$\boldsymbol{x}'(t) = \boldsymbol{A}\boldsymbol{x}(t) + \boldsymbol{B}\boldsymbol{u}(t) \tag{10}$$

$$\boldsymbol{y}(t) = \boldsymbol{C}\boldsymbol{x}(t) + \boldsymbol{D}\boldsymbol{u}(t) \tag{11}$$

式中:$\boldsymbol{A}$ 为状态转移矩阵;$\boldsymbol{B}$ 为输入矩阵, $\boldsymbol{C}$ 为输出矩阵;$\boldsymbol{D}$ 为跳跃连接矩阵;$\boldsymbol{x}'(t)$为当前状态向量。

如果将 SSM 应用于离散序列,需对连续系统以采样间隔进行离散化,离散后的 SSM 表达式为

$$\boldsymbol{x}_k = \overline{\boldsymbol{A}}\boldsymbol{x}_{k-1} + \overline{\boldsymbol{B}}\boldsymbol{u}_k \tag{12}$$

$$\boldsymbol{y}_k = \boldsymbol{C}\boldsymbol{x}_k \tag{13}$$

式中:$\overline{\boldsymbol{A}}$ 为离散化的状态转移矩阵;$\overline{\boldsymbol{B}}$ 为离散化的输入矩阵;$\boldsymbol{x}_{k-1}$、$\boldsymbol{x}_k$ 分别为第 $k-1$、k 个离散时刻的隐状态向量;$\boldsymbol{u}_k$、$\boldsymbol{y}_k$ 分别为第 k 个离散时刻的输入向量、输出向量。

$\boldsymbol{y}_k$ 等于 $\boldsymbol{u}_k$ 与 SSM 卷积核 $\boldsymbol{K}$ 的卷积。$\boldsymbol{K}$ 的表达式为

$$\boldsymbol{K} = (\boldsymbol{C}\overline{\boldsymbol{B}}, \boldsymbol{C}\overline{\boldsymbol{A}}\overline{\boldsymbol{B}}, \cdots, \boldsymbol{C}\overline{\boldsymbol{A}}^{(L-1)}\overline{\boldsymbol{B}}) \in \mathbf{R}^L \tag{14}$$

$\boldsymbol{y}_k$ 由当前输入与历史状态共同决定,因而天然具备时序记忆能力。然而,SSM 在深度学习中的直接应用效果有限。根本原因在于,随机初始化的 $\boldsymbol{A}$ 往往导致隐状态对过去输入的记忆呈指数衰减,难以捕捉长程依赖关系。基于此,Gu 等人提出基于高阶多项式投影算子(High-order Polynomial Projection Operators, HiPPO)框架的特殊状态矩阵初始化方案[28]。HiPPO 矩阵由连续时间记忆的最优化问题推导而来,其核心思想是令隐状态$\boldsymbol{x}(t)$成为输入历史$\boldsymbol{u}(s)$$(s \leqslant t)$在一组正交多项式基函数上的投影系数,从而使系统对过去输入保持理论最优的记忆能力。HiPPO 矩阵的具体定义为

$$A_{nk} = -\begin{cases} (2n+1)^{1/2}(2k+1)^{1/2}, & n > k \\ n+1, & n = k \\ 0, & n < k \end{cases} \tag{15}$$

然而,以 HiPPO 矩阵直接参数化 SSM 计算成本很高,难以在实际深度学习场景中应用。S4 模型通过代数分解方法解决了此问题。HiPPO 矩阵虽然不可稳定对角化,但可以分解为正规矩阵加低秩项(Normal Plus Low-Rank, NPLR)的形式。NPLR 参数化方案涉及复数 Cauchy 核算法,实现较为复杂。Gu 等人进一步提出 S4D[29],通过直接采用对角复数矩阵 $\boldsymbol{A}$,在保证接近 S4 性能的前提下大幅简化了计算流程。

当 $\boldsymbol{A}$ 为对角矩阵时,记 $A_n$$(n = 0, \cdots, N-1)$为其对角元素,则式(14)的卷积核退化为 Vandermonde 矩阵乘积:

$$K_l = \sum_{n=0}^{N-1} C_n A_n^l B_n \Rightarrow \lambda(\boldsymbol{K}) = [\lambda(\boldsymbol{B}) \odot \lambda(\boldsymbol{C})] \cdot \boldsymbol{V}_L[\lambda(\boldsymbol{A})] \tag{16}$$

式中:K_l 为 $\boldsymbol{K}$ 的第 l 个系数;$\lambda(\,)$为矩阵的特征值;$\boldsymbol{V}_L$ 为 Vandermonde 矩阵。

由于 SSM 最终需要输出实数序列,将复数状态维度取共轭对称形式,只保留 $N/2$ 个独立参数,并取结果的两倍实部即可等价表示完整的 N 维实数 SSM。

2.4 基于改进 SBOA-VMD-S4D 的故障诊断流程

基于改进 SBOA-VMD-S4D 的故障诊断流程

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

如图 3 所示,主要步骤如下。

(1)载入励磁电流仿真数据,对全部信号减去各自均值以去除直流偏置。从训练集每类故障中各随机抽取 1 条去直流信号共 5 条,作为 SBOA 优化的参考信号集。

(2)采用 SBOA 自适应搜索 VMD 最优参数组合。以最小化 F 为目标,交替执行 Lévy 飞行探索与收缩开发两种更新策略,优化结束后输出最优参数组合(K^*, α^*),并记录全程收敛轨迹。

(3)以(K^*, α^*)分别对训练集和测试集的去直流信号执行批量 VMD;对每个 IMF 通道独立执行 mapminmax 归一化(训练集拟合,测试集同步应用);随后对各 IMF 执行滑窗 Patch 提取。

(4)初始化改进 SBOA-VMD-S4D 模型,经层归一化、全局均值池化与线性分类头输出 5 类预测。

(5)训练完成后对测试集执行批量推理,统计整体准确率,绘制训练损失与测试集准确率曲线及混淆矩阵,保存模型参数与配置。

准确率 acc 计算式为



图 3 故障诊断流程图

Fig. 3 Flowchart of the fault diagnosis process

$$acc = \frac{N_{cor}}{N_{tot}} \times 100\% \tag{17}$$

式中:N_{cor} 为预测正确样本数;N_{tot} 为总样本数。

3 故障测试

3.1 仿真与试验

基于 Matlab/Simulink 搭建仿真模型,对三级式发电机旋转整流器开展仿真故障模拟。仿真中,设定采样频率为 100 kHz、单次采样时长为 0.01 s。分别针对空载、1.5 kW 阻性负载和 3 kW 阻性负载三种工况采集样本。每种工况下各故障类别采样 100 次、每次采样含 1 000 个数据点,累计采集 1 500 组样本。

考虑到真实航空发电机在实际试验条件下难以获取,本文改用一台结构原理与航空发电机高度一致的民用三级式无刷交流发电机进行替代,以保证试验结果的等效参考价值。试验平台如图 4 所示,硬件构成包括变频器、驱动电机、民用三级式无刷发电机主体、数据采集单元及阻性负载模块等。为便于人为触发故障,将旋转整流器经电刷滑环结构固定于机身,并在各二极管支路中串接可控开关,通过手动控制开关通断状态实现对二极管开路故障的可重复模拟。发电机参数如表 2 所示。



图 4 试验平台

Fig. 4 Experimental platform

表 2 发电机参数

Tab. 2 Generator parameters

参数名称	参数值
额定功率/kW	7.5
额定电压/V	400
额定转速/(r·min^{-1})	1 500
额定频率/Hz	50
极对数	2

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

试验中，设定采样频率为 10 kHz，单次采样时长为 0.1 s。分别在空载、1.5 kW 阻性负载和 3 kW 阻性负载三种工况下采集样本。每种工况下各故障类别均采集 100 个样本，每个样本包含 1 000 个数据点，累计采集 1 500 组样本。

3.2 结果与分析

为了验证所提方法在不同负载下的可迁移性，选用空载下采集的数据作为训练样本，模型训练完成后分别在空载、1.5 kW 阻性负载和 3 kW 阻性负载及混合负载条件下开展测试。故障诊断算法运行于一台搭载 Win11 操作系统的计算机，内存容量为 16 GB，处理器主频为 2.0 GHz。模型相关参数配置如下：Patch 提取窗口尺寸为 20 个采样点，滑动步长为 10 个采样点；K 取值范围为[2，6]，α 取值范围为[500，5 000]；SBOA 优化种群规模为 10，迭代次数为 20，λ 为 1.5；S4D 模型的嵌入维度为 32，状态空间维度为 32，堆叠块数为 3；最大训练轮次为 20，初始学习率为 3×10^{-4}，批尺寸设置为 16。Adam 优化器动量参数设置如下：β_1 为 0.9、β_2 为 0.999、ε 为 10^{-8}。按 7∶3将数据集划分为训练集与测试集。

在空载数据集上对改进 SBOA-VMD-S4D 模型进行训练，以单管开路故障为例，VMD 结果如图 5 所示。

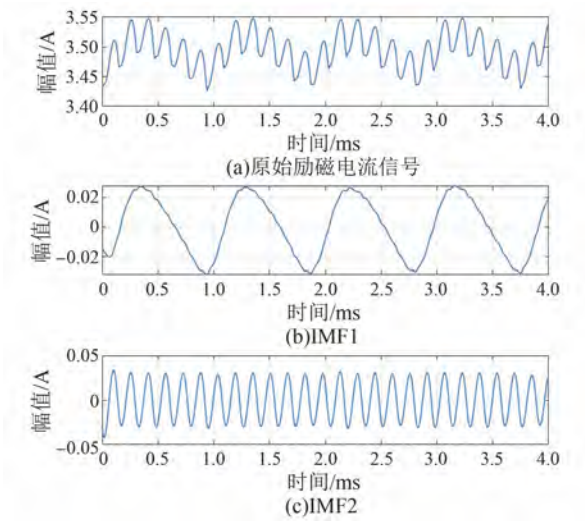


图 5 VMD 结果

Fig. 5 VMD results

由图 5 可知，原始励磁电流信号幅值集中在 3.40～3.55 A 之间，波形呈现出多频率成分叠加的复杂形态，直接从中提取故障特征比较困难，所以需要对信号进行去直流预处理。经改进 SBOA 优化后，VMD 将原始励磁电流信号自适应分解为 2 个 IMF 分量。IMF1 呈现出低频、大周期的正弦振荡特征，幅值为±0.02 A，对应励磁电流中由开路故障引起的基频分量；IMF2 呈现出高频、小周期的振荡特征，幅值为±0.05 A，对应电流中的高次谐波成分。

模型在训练中的损失和准确率如图 6、7 所示。

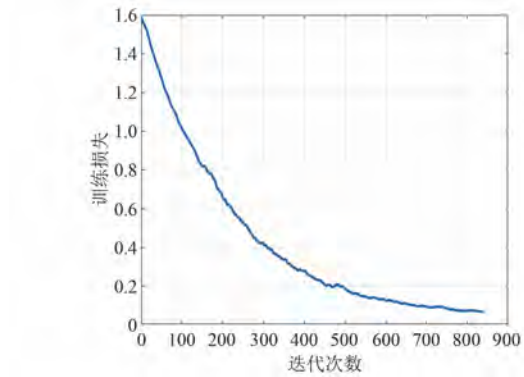


图 6 训练损失曲线

Fig. 6 Training loss curve

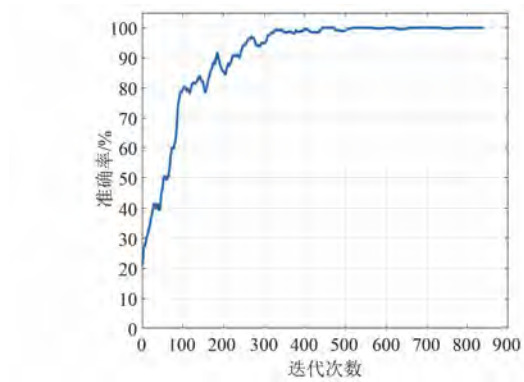


图 7 准确率曲线

Fig. 7 Accuracy curve

训练损失值从初始的 1.6 快速下降，在前 200 个迭代次数内降幅显著；200 次后下降速率放缓，最终稳定在 0.1。从损失曲线的下降趋势可以看出模型对故障特征的识别能力不断提升。前期快速下降表明模型快速学习到 VMD 后的 IMF 特征；后期缓慢收敛则体现模型的精细优化。损失平稳收敛，无反弹、振荡，表明训练过程稳定可靠，未出现过拟合或梯度爆炸问题。准确率的提升与损失下降高度同步，从初始的 20% 快速上升，迭代 300 次后接近 100%，之后稳定在 100%。结合

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

训练损失与准确率曲线可知,改进 SBOA-VMD-S4D 模型能够对航空发电机旋转整流器的开路故障作出高效且准确的判别。

在测试集上对已训练完成的模型进行验证,混淆矩阵如图 8 所示。

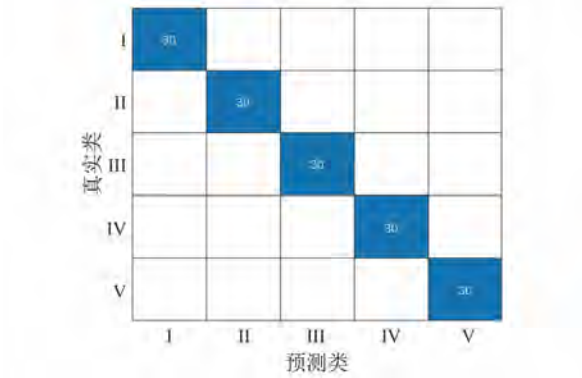


图 8　混淆矩阵

Fig. 8　Confusion matrix

从混淆矩阵中可以看出,改进 SBOA-VMD-S4D 模型能正确识别空载条件下的各类故障,诊断准确率达 100%。为进一步检验模型在其他工况下的泛化表现,在 1.5 kW 阻性负载、3 kW 阻性负载以及混合负载下进行测试,具体结果如表 3 所示。

表 3　仿真中不同负载下的故障诊断准确率

Tab. 3　Fault diagnosis accuracy under different load conditions in simulation

负载条件	准确率/%
1.5 kW 负载	99.6
3 kW 负载	100
混合负载	100

由表 3 可知,该模型在 1.5 kW 阻性负载、3 kW 阻性负载和混合负载条件下的故障诊断准确率均接近 100%,在故障诊断中表现出优异的泛化性能与稳定性。

为验证改进 SBOA-VMD-S4D 模型在试验中的诊断效果,通过试验平台采集空载、1.5 kW 阻性负载和 3 kW 阻性负载下的励磁电流,如图 9~13 所示。

由图 9~13 可知,在正常工作、单管开路以及不同桥臂同侧双管开路故障下,不同负载下的励磁电流幅值差异明显;而在同桥臂双管、不同桥臂不同侧双管开路故障下,空载和 1.5 kW 阻性负载

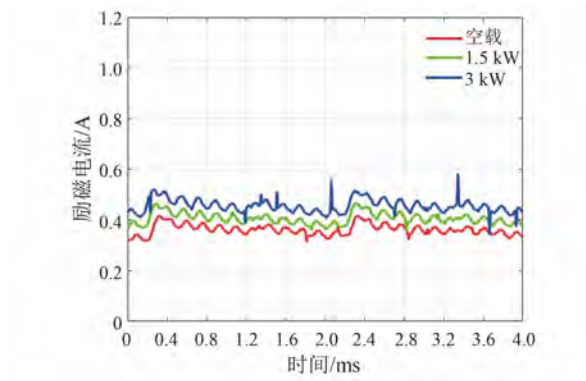


图 9　正常工作时励磁电流波形

Fig. 9　Excitation current waveforms under normal operating

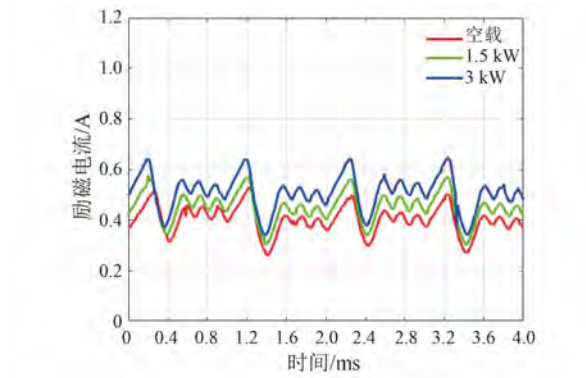


图 10　单管开路时励磁电流波形

Fig. 10　Excitation current waveforms under single-switch open-circuit

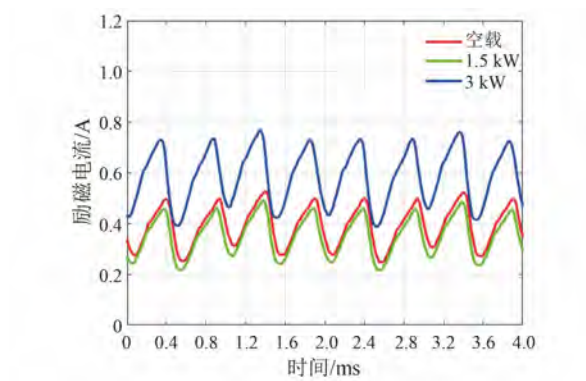


图 11　同桥臂双管开路时励磁电流波形

Fig. 11　Excitation current waveforms under dual-switch open-circuit of switches on the same bridge leg

的励磁电流幅值和形状几乎一样,很难分辨。

采用 t-分布随机邻域嵌入(t-distributed Stochastic Neighbor Embedding, t-SNE)算法对经 VMD 的信号特征进行降维可视化,如图 14 所示。

由图 14 可知,五种工况对应的数据点均形成

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

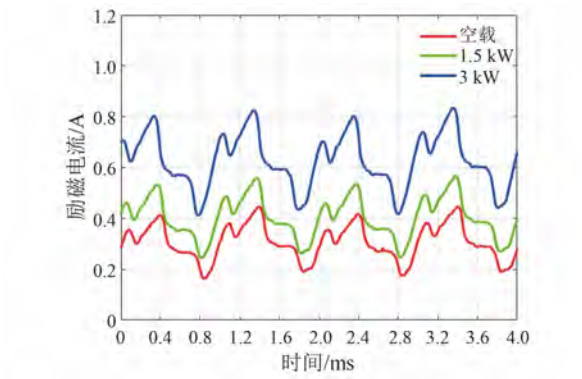


图 12　不同桥臂同侧双管开路时励磁电流波形

Fig. 12　Excitation current waveforms under dual-switch open-circuit of switches on the same side of different bridge legs

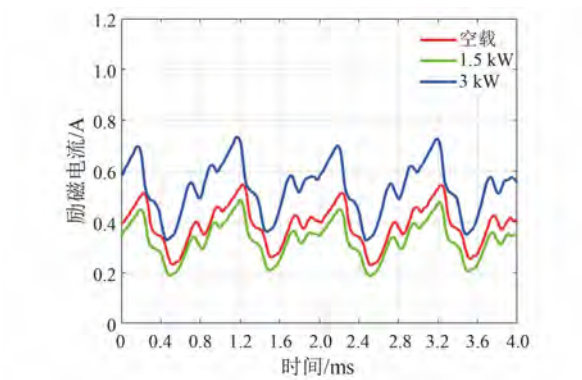


图 13　不同桥臂不同侧双管开路时励磁电流波形

Fig. 13　Excitation current waveforms under dual-switch open-circuit of switches on the different side of different bridge legs

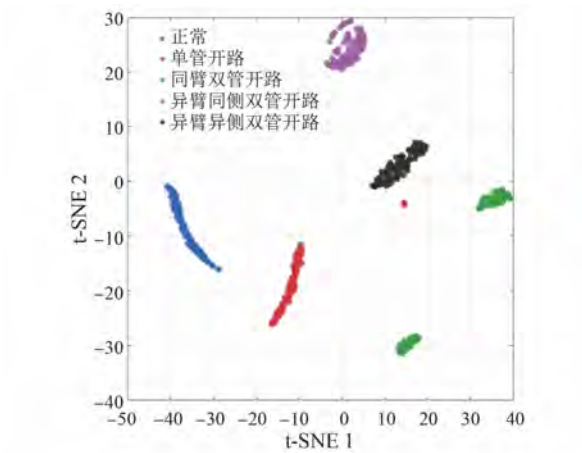


图 14　t-SNE 可视化图

Fig. 14　t-SNE visualization plot

了各自独立且紧凑的簇团，簇与簇之间边界清晰，几乎没有重叠或混淆。绿色簇虽然分成了两部分，但是与其他簇有明显边界，所以不影响诊断。黑色簇下方的孤立红点推测是由于信号采集过程中的瞬时噪声干扰所致，属于正常的随机误差，对整体结果影响较小。试验结果表明，所提方法能够精准、清晰地识别五种不同的故障类型，为后续的神经网络故障诊断与分类提供了很好的特征信号。

试验中不同负载下的故障诊断准确率如表 4 所示。

表 4　试验中不同负载下的故障诊断准确率

Tab. 4　Fault diagnosis accuracy under different load conditions in experiments

负载条件	准确率/%
空载	98.7
1.5 kW 负载	100
3 kW 负载	100
混合负载	99.6

由表 4 可知，相比仿真，空载工况下的试验故障准确率略有下降，其原因在于试验环境难以完全避免噪声干扰。整体而言，模型在各负载下的准确率均超过 98.5%，进一步验证了所提方法由仿真向试验的迁移能力，以及面向真实工程应用场景的实用价值。

综上所述，本文所提基于改进 SBOA-VMD-S4D 的故障诊断方法在仿真与试验两类数据上均展现出高准确率与强泛化性，各工况下的综合诊断性能验证了该方法的有效性与工程可靠性。

3.3　对比试验

为验证所提 SBOA-VMD-S4D 方法的有效性，将其与其他 6 种故障诊断方法进行对比。对比方法包括：VMD-S4D、S4D、SBOA-VMD-CNN、SBOA-VMD-LSTM、FFT-S4D 和 SVM。其中改进 SBOA 模块、VMD 模块、S4D 模块的结构均相同，固定参数的 VMD 模态分量数 K 设置为 4，带宽惩罚系数 α 设置为 2 000。在仿真和试验数据中的诊断结果如表 5、表 6 所示。

总体来看，由于仿真数据具有信号干净、噪声低等特点，各方法间差异相对集中；而试验中由于噪声和负载波动的影响，信号会出现一定扰动，各方法的性能呈现出明显分化，跨负载迁移能力的差异也随之凸显。

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

结合表 5 与表 6 可知,所提 SBOA-VMD-S4D 的诊断准确率最高。与 VMD-S4D 相比,SBOA-VMD-S4D 在 1.5 kW、3 kW 和混合负载下的准确率均显著提升,仅在试验空载时略低;且测试时间大幅缩短,表明 SBOA 不仅提升了 VMD 的分解质量,还有效减少了参数搜索带来的计算冗余。与 S4D 相比,所提方法通过引入 SBOA-VMD 模块对输入信号完成自适应时频分解,为后续 S4D 模型提供了判别能力更强的输入特征,从而使各负载条件下的准确率得到提升,可见 SBOA-VMD 模块对最终诊断性能具有重要影响。

表 5 仿真中各方法故障诊断准确率

Tab. 5 Fault diagnosis accuracy of each method in simulation

方法名称	准确率/%				测试时间/s
	空载	1.5 kW 负载	3 kW 负载	混合负载	
SBOA-VMD-S4D	100	99.6	100	100	3.26
VMD-S4D	95.3	95.8	95.4	95.4	11.41
S4D	98.6	98.2	98.6	98.8	0.42
SBOA-VMD-CNN	98.8	98.2	97.8	98.4	2.83
SBOA-VMD-LSTM	99.0	99.0	98.2	98.2	3.36
FFT-S4D	98.0	97.8	95.6	94.4	0.35
SVM	100	20.0	20.0	47.2	0.11

表 6 试验中各方法故障诊断准确率

Tab. 6 Fault diagnosis accuracy of each method in experiments

方法名称	准确率/%				测试时间/s
	空载	1.5 kW 负载	3 kW 负载	混合负载	
SBOA-VMD-S4D	98.7	100	100	99.6	2.44
VMD-S4D	99.2	80.0	80.0	85.6	9.72
S4D	100	100	88.6	94.8	0.32
SBOA-VMD-CNN	100	100	80.0	92.2	1.98
SBOA-VMD-LSTM	100	100	76.8	91.6	2.41
FFT-S4D	100	100	80.0	93.0	0.35
SVM	100	20.0	20.0	47.2	0.11

SVM 在空载下准确率达 100%,但切换至 1.5 kW 及 3 kW 负载后,准确率降至 20%,反映出传统机器学习方法对训练域分布的严重依赖,泛化能力严重不足。FFT-S4D 在仿真数据上表现较好,但是在试验数据上随负载增大呈现明显的性能衰退趋势,从空载的 100% 降至 3 kW 的 80%,表明 FFT 的特征提取能力在变工况下的不如 VMD。随负载增大,SBOA-VMD-CNN 和 SBOA-VMD-LSTM 的诊断准确率均下降;相比之下,本文方法在所有负载下的准确率均达到或接近 100%,表明 S4D 模型在跨负载迁移场景下相较 CNN 与 LSTM 具有更强的稳定性。

在测试时间方面,FFT-S4D 和 VMD 虽然推理速度较快,但其跨负载场景下的准确率存在明显短板。SBOA-VMD-CNN、SBOA-VMD-LSTM 与 SBOA-VMD-S4D 的测试时间相近,但 SBOA-VMD-S4D 的准确率更高,表明所提方法在保持推理效率的同时实现了更优的分类性能。

综合准确率与测试时间,本文所提 SBOA-VMD-S4D 相较于其他 6 种方法具有优势明显,在诊断精度、跨负载迁移能力及推理效率上实现了较好的综合平衡。

3.4 不同阻感配比试验

考虑到实际应用场景除了常见的阻性负载外还存在感性负载,为充分验证所提方法在真实工况下的鲁棒性,避免因负载单一而导致模型过拟合或评估片面,本节通过三相阻感可调负载箱配置不同阻感配比进行试验。选择 380 W、360 VA 和 640 W、680 VA 两种负载,在正常、单管开路和双管开路(D1D3)工况下进行验证,对应的电流波形如图 15~17 所示。

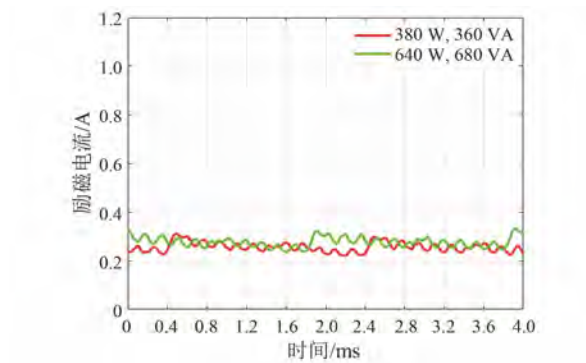


图 15 阻感性负载下正常工作时励磁电流波形

Fig. 15 Excitation current waveforms under normal operation with resistive-inductive load

由图 15~17 可知,在阻感性负载下,正常、单管开路和双管开路的励磁电流波形与阻性负载下的波形类似,但均出现了延时。这是因为感性负

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

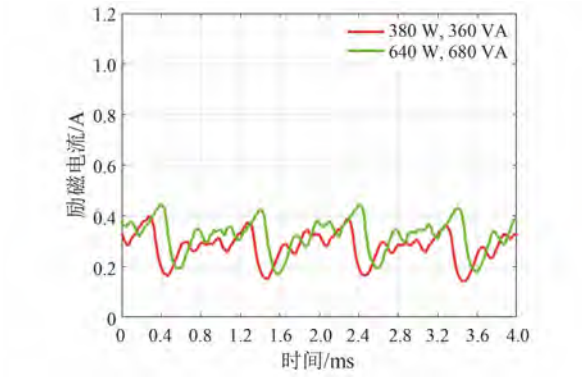


图 16　阻感性负载下单管开路时励磁电流波形

Fig. 16　Excitation current waveforms under single-switch open-circuit with resistive-inductive load

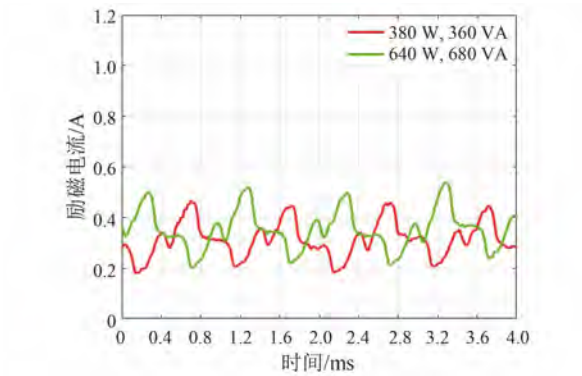


图 17　阻感性负载下双管开路时励磁电流波形

Fig. 17　Excitation current waveforms under dual-switch open-circuit with resistive-inductive load

载自感电动势会产生感抗，导致电流滞后，从而产生延时。

阻感性负载下的故障诊断准确率如表 7 所示，混淆矩阵如图 18 所示。

表 7　阻感性负载下的故障诊断准确率

Tab. 7　Fault diagnosis accuracy under resistive-inductive load

负载条件	准确率/%
380 W、360 VA	98.9
640 W、680 VA	97.8

由表 7 可知，SBOA-VMD-S4D 在 380 W、360 VA 和 640 W、680 VA 负载下的诊断准确率分别为 98.9% 和 97.8%，仅有极少数样本出现误判，验证了 SBOA-VMD-S4D 在面对不同阻感性负载条件时具备较好的泛化能力。

在两种阻感性负载下与其他六种方法进行对比试验，结果如表 8 所示。

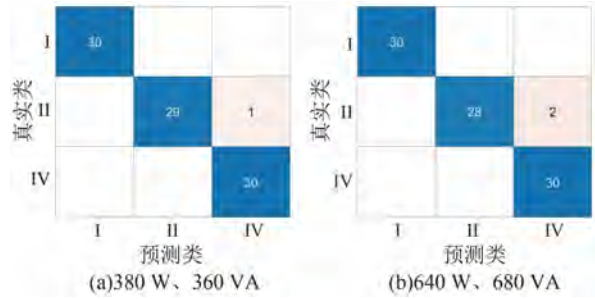


图 18　阻感性负载下诊断结果混淆矩阵

Fig. 18　Confusion matrix of diagnosis results under resistive-inductive load

表 8　阻感性负载下各方法故障诊断准确率

Tab. 8　Fault diagnosis accuracy of each method under resistive-inductive load

方法名称	准确率/%		测试时间/s
	380 W、360 VA	640 W、680 VA	
SBOA-VMD-S4D	98.9	97.8	1.67
VMD-S4D	92.2	90	5.38
S4D	96.7	94.7	0.26
SBOA-VMD-CNN	95.7	83.3	1.38
SBOA-VMD-LSTM	90.3	81.2	1.78
FFT-S4D	94.4	81.7	0.14
SVM	75.7	59	0.04

由表 8 可知，在两种阻感性负载下，所提 SBOA-VMD-S4D 的诊断准确率均高于其他六种方法。从 380 W、360 VA 到 640 W、680 VA，负载功率和视在功率显著增加，所有方法准确率均下降，但 SBOA-VMD-S4D 降幅最小，仅下降 1.1%。

3.5　方法通用性验证

为验证本文方法在其他额定功率电机上的通用性，采集了某型航空发电机正常运行和单管开路时的励磁电流，如图 19、20 所示。采用本文方法进行故障诊断，结果如图 21 所示。

实际航空发电机运行环境通常伴有较强的噪声，导致采集的励磁电流波形存在一定程度的畸变与波动，但同种故障模式下的励磁电流波形特征仍与民用发电机具有较高的一致性。经统计，某型航空发电机的诊断准确率为 92.5%，虽略低于民用发电机试验结果，但仍在合理范围内。表明噪声干扰对特征提取造成一定影响，但所提方

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

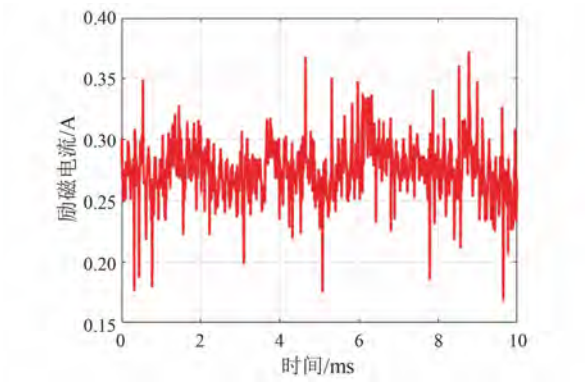


图 19　某型航空发电机正常运行时励磁电流波形

Fig. 19　Excitation current waveform of a certain type of aviation generator under normal operation

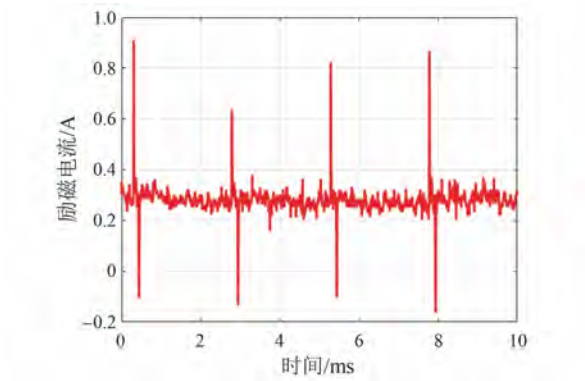


图 20　某型航空发电机单管开路时励磁电流波形

Fig. 20　Excitation current waveform of a certain type of aviation generator with single-switch open-circuit

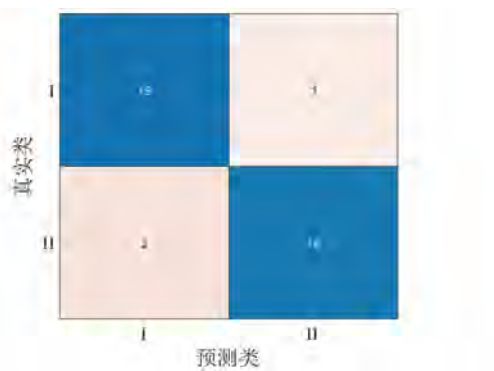


图 21　某型航空发电机诊断结果混淆矩阵

Fig. 21　Confusion matrix of diagnosis results for a certain type of aviation generator

法依然保持较好的故障识别性能,验证了所提方法在不同额定功率电机上的通用性。

4　结语

本文提出一种基于改进 SBOA-VMD-S4D 的航空三级式发电机旋转整流器开路故障诊断方法,通过搭建 Simulink 模型开展仿真,并结合试验对该方法的有效性进行验证。

仿真结果表明,本文方法在 1.5 kW、3 kW 及混合负载下的诊断准确率均达到或接近 100%,验证了该方法在仿真数据上的跨负载迁移能力;试验结果表明,在 1.5 kW、3 kW 及混合负载下的诊断准确率均高于 98.5%,充分验证了该方法由仿真向真实工程场景迁移的可靠性。

本文的局限性在于试验工况未涵盖负载突变、非线性干扰等复杂场景。未来将致力于构建更完善的试验平台,以全面评估算法在各类干扰下的特征区分能力与泛化性能。

利益冲突声明

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

作者贡献

陈启源进行了模型仿真、数据采集、信号处理、算法编写和论文撰写,崔江参与了理论指导和论文审核与修改。所有作者均阅读并同意了最终稿件的提交。

Chen Qiyuan conducted model simulation, data acquisition, signal processing, algorithm coding and paper writing. Cui Jiang participated in theoretical guidance as well as paper review and revision. All authors have read and approved the final version of the manuscript for submission.

参 考 文 献

[1] 王莉, 殷子涵, 杨善水, 等. 多电/全电飞机供电系统架构发展及关键技术[J]. 中国电机工程学报, 2026, 46(7): 2779-2795.
Wang L, Yin Z H, Yang S S, et al. Advancements in power architectures and enabling technologies for more electric/all-electric aircraft [J]. Proceedings of the CSEE, 2026, 46(7): 2779-2795.

[2] Xu Y W, Zhang Z R. Generator rectificationin more electric aircraft high-voltage dc electric power systems: A review [J]. IEEE Transactions on Transportation Electrification, 2025, 11(4): 9350-

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

9362.

[3] Aliprantis D C，Sudhoff S D，Kuhn B T. A brushless exciter model incorporating multiplerectifier modes and preisach ' s hysteresis theory [J]. IEEE Transactions on Energy Conversion，2006，21(1)：136-147.

[4] Batzel T D，Swanson D C. Prognostic health management of aircraft power generator [J]. IEEE Transactions on Aerospaceand Electronic Systems，2009，45(2)：473-483.

[5] Frank P M，Seliger R. Fault detection and isolation in automatic processes [J]. Control and Dynamic Systems，2012，49：241-287.

[6] Bojar A，Vahedi A，Rahnama M，et al. Rotating rectifier fault detection using exciter modelling in a brushless synchronous generator [C]//5th International Conference on Engineering Sciences，AIP Conference Proceedings，Karbala，Iraq，2021：1-12.

[7] Du H R，Liu Y Z，Li T X，et al. A high-fidelity and computationally efficient model for an electrically excited synchronous generator based on current-flux linkage neural networks [J]. Journal of Electrical Engineering & Technology，2024，19(5)：2903-2918.

[8] 梁波，李玉忍，薛梦娇. 飞机三级式发电系统建模与仿真[J]. 计算机仿真，2013，30(2)：71-75.
Liang B，Li Y R，Xue M J. Modeling and simulation of three-stage aircraft synchronous generator system [J]. Computer Simulation，2013，30(2)：71-75.

[9] Zhang Y Q，Cramer A M. Numerical average-value modeling of rotating rectifiers in brushless excitation systems [J]. IEEE Transactions on Energy Conversion，2017，32(4)：1592-1601.

[10] 张超，夏立. 基于谐波分析的旋转整流器故障检测[J]. 电机与控制应用，2008，35(11)：51-54.
Zhang C，Xia L. Fault detection of rotary rectifier based on harmonic analysis [J]. Electric Machines & Control Application，2008，35(11)：51-54.

[11] Zhang S，Wang F，Sun D，et al. Fault analysis and feature extraction of rotary rectifier of aviation three-stage generator [C]//International Conference on Clean Energy and Electrical Systems，Tokyo，Japan，2023：79-94.

[12] 刘繁，崔江，林华. 一种航空发电机旋转整流器故障在线诊断技术[J]. 电机与控制应用，2022，49(2)：104-108.
Liu F，Cui J，Lin H. An online diagnosis technology of aero generator rotating rectifier fault [J]. Electric Machines & Control Application，2022，49(2)：104-108.

[13] Zhang Z，Shi L H，Yang L，et al. Identification methods for rotating diode rectifier open circuit failures without rotor position information in brushless exciter systems of wound field synchronous machines [J]. IEEE Transactions on Industrial Electronics，2025，72(9)：9727-9738.

[14] Jiao N F，Han X，Wei Z H. Online fault diagnosis for rotating rectifier in wound-rotor synchronous starter-generator based on geometric features of current trajectory [J]. IEEE Transactions on Industrial Electronics，2021，68(4)：2952-2963.

[15] Jiao N F，Shen H，Wang K，et al. Secondary-fault diagnosis of rotating rectifier in brushless wound-rotor synchronous starter-generator based on estimated rotor currents [J]. IEEE Transactions on Power Electronics，2025，40(1)：1813-1825.

[16] Jiao N F，Li Z J，Mao S，et al. Aircraft brushless wound-rotor synchronous starter-generator：A technology review [J]. IEEE Transactions on Power Electronics，2023，38(6)：7558-7574.

[17] Wang K，Jiao N F，Shen H，et al. Fault diagnosis method for the rotating components of aircraft multi-stage brushless synchronous starter-generator [C]// IEEE Transportation Electrification Conference and Expo，Asia-Pacific，2024：824-835.

[18] Li X Y，Liu W G，Jiao N F，et al. Fault diagnosis of rotating rectifier in aircraft wound-rotor synchronous starter generator based on stator currents under all operational processes [J]. IEEE Transactions on Power Electronics，2023，38(12)：16072-16084.

[19] 党忆涵，徐传芳，王绍祖. 牵引整流器单管 IGBT 开路故障诊断[J]. 电机与控制应用，2025，52(3)：294-304.
Dang Y H，Xu C F，Wang S Z. Open circuit fault diagnosis of single-tube IGBT in traction rectifier [J]. Electric Machines & Control Application，2025，52(3)：294-304.

[20] 杨静，崔江，周凡. 基于电流位置关系的 DSEG 整流器开路故障诊断算法[J]. 电机与控制应用，2024，51(6)：44-56.
Yang J，Cui J，Zhou F. Open-circuit fault diagnosis algorithm of DSEG rectifier based on current position

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.

relation [J]. Electric Machines & Control Application, 2024, 51(6): 44-56.

[21] Mahtani K, Decroix J, Pascual R, et al. Automatic classification of rotating rectifier faults in brushless synchronous machines [J]. Electronics, 2024, 13(23): 1-26.

[22] 朱佩荣, 刘勇智, 刘棕成. 基于 CEEMD 与改进的 ELM 旋转整流器故障诊断[J]. 北京航空航天大学学报, 2023, 49(5): 1166-1175.
Zhu P R, Liu Y Z, Liu Z C. Fault diagnosis of synchronous generator rotating rectifier based on CEEMD and improved ELM [J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(5): 1166-1175.

[23] 陈文杰, 崔江. 基于 LSTM 的航空发电机整流电路诊断技术[J]. 电机与控制应用, 2023, 50(4): 85-90.
Chen W J, Cui J. Diagnosis technology of aero-generator rectifier circuit based on LSTM [J]. Electric Machines & Control Application, 2023, 50(4): 85-90.

[24] 崔江, 周凡, 陈永凡, 等. 一种基于 GAMF-CNN 的航空发电机整流器故障诊断技术[J]. 航空学报, 2024, 45(24): 231-242.
Cui J, Zhou F, Chen Y F, et al. A technique for aerospace generator rectifier fault diagnosis based on GAMF-CNN [J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(24): 231-242.

[25] 王瑾, 严仰光. 旋转整流器式无刷交、直流发电机谐波电枢反应研究[J]. 南京航空航天大学学报, 2000, 32(3): 257-262.
Wang J, Yan Y G. Study on harmonic armature reaction of brushless AC & DC generator [J]. Journal of Nanjing University of Aeronautics & Astronautics, 2000, 32(3): 257-262.

[26] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.

[27] Fu Y F, Liu D, Chen J D, et al. Secretary bird optimization algorithm: A new metaheuristic for solving global optimization problems [J]. Artificial Intelligence Review, 2024, 57(123): 1-102.

[28] Gu A, Goel K, Ré C. Efficiently modeling long sequences with structured state spaces [C]// International Conference on Learning Representations, Online, 2022: 1-32.

[29] Gu A, Gupta A, Goel K, et al. On the parameterization and initialization of diagonal state space models [C]//36th International Conference on Neural Information Processing Systems, New Orleans, USA, 2022: 35971-35983.

收稿日期:2026-07-31
收到修改稿日期:2026-08-24

作者简介:

陈启源(1999—),男,硕士研究生,研究方向为航空发电机故障诊断,cqy7120@163.com;

*通信作者:崔 江(1977—),男,博士,副教授,研究方向为航空发电机故障诊断与检测,cuijiang@nuaa.edu.cn。

© Editorial Office of Electric Machines & Control Application. This is an open access article under the CC BY-NC-ND 4.0 license.