

DOI: 10.19650/j.cnki.cjsi.J2514078

基于电磁场特征蒸馏的无刷直流 电机匝间短路智能辨识*

吴振宇¹, 屈先锋¹, 王 慧², 刘永斌¹, 陆思良¹

(1. 安徽大学电气工程与自动化学院 合肥 230601; 2. 中国电力科学研究院有限公司 北京 100192)

摘要:无刷直流电机作为工业驱动系统的关键动力单元,精准的状态评估是保障电机安全稳定运行的关键。但是其定子绕组相邻线圈间的绝缘劣化会导致匝间短路发生,而早期匝间短路存在特征信息空间分布零散、冗余信息过多等问题,又给设备的状态评估带来了全新挑战。为此,提出了一种基于电磁场特征蒸馏的无刷直流电机匝间短路智能辨识方法。首先,通过建立电磁等效模型解析了漏磁信号与绕组状态的物理关联,揭示了短路匝数与漏磁通量重分布的非线性规律。其次,结合递归相空间重构技术融合了多源空间的漏磁信号,构建了高信息密度的电磁场特征图谱,突破了传统单维度分析的限制。进一步设计了一种轻量化的 MobileViT-CBAM 混合模型,利用其内置的特征蒸馏机制实现故障特征的自适应筛选与增强,在保证高精度的同时大幅降低了模型复杂度。最后,通过构建覆盖多种噪声场景的增强训练集,显著提升了模型在复杂工业环境中的鲁棒性。实验结果表明:差异化负载工况下诊断模型对 16 类匝间短路分类准确率达 99.4%,模型参数量与计算速度较主流模型提升超 50%。针对另一台不同型号的无刷直流电机开展独立验证,模型准确率为 92.3% 证明了其优异的泛化能力。该模型通过多源特征融合、轻量化架构与抗干扰策略的协同优化,为工业场景中高可靠性的电机在线监测提供了创新解决方案。

关键词:无刷直流电机;匝间短路;电磁场信号融合;特征蒸馏;智能辨识

中图分类号: TM307 TH165+.3 **文献标识码:** A **国家标准学科分类代码:** 470.40

Intelligent identification of inter-turn short circuits in brushless DC motor based on feature distillation of multi-source electromagnetic field signals

Wu Zhenyu¹, Qu Xianfeng¹, Wang Hui², Liu Yongbin¹, Lu Siliang¹

(1. School of Electrical Engineering and Automation, Anhui University, Hefei 230601, China;

2. China Electric Power Research Institute, Beijing 100192, China)

Abstract: Precise condition assessment of brushless direct current motors (BLDCM), as critical power units in industrial drive systems, is essential for ensuring their safe and stable operation. However, insulation degradation between adjacent stator windings can lead to inter-turn short circuit (ITSC). Early-stage ITSC present significant challenges, including spatially scattered and highly redundant characteristic information, posing new difficulties for equipment evaluation. To address these issues, this paper proposes an intelligent ITSC identification method for BLDCM based on electromagnetic field feature distillation. Firstly, an electromagnetic equivalent model is established to analyze the physical relationship between leakage flux signals and winding states, revealing the nonlinear law governing the spatial redistribution of leakage flux relative to the number of shorted turns. Secondly, multi-source spatial leakage flux signals are fused using recursive phase space reconstruction techniques to construct high-information-density electromagnetic field feature maps, overcoming the limitations of traditional single-dimension analysis. Finally, an augmented training set covering diverse noise scenarios is constructed to significantly improve the model's robustness in complex industrial environments. Through the synergistic optimization of multi-source feature fusion, lightweight architecture, and anti-interference strategies, this research provides an innovative solution for highly reliable online monitoring of motors in industrial settings.

Keywords: brushless DC motor; interturn short circuit; electromagnetic field signal fusion; feature distillation; intelligent identification

0 引言

无刷直流电机 (brushless direct current motor, BLDCM) 因其高效率、高可靠性及优异的调速性能,被广泛应用于工业驱动领域^[1]。然而,受特殊工况下负载特性的影响,BLDCM 长期面临过电压与大负荷的频繁冲击,导致定子绕组局部过热现象频发。据统计,匝间短路占其电气故障的 21%~37%,且在高功率密度或频繁启停场景中发生率显著升高^[2-3]。此过程将加速绝缘材料的电气与机械性能劣化,显著增加匝间短路 (inter-turn short circuit, ITSC) 风险。若未能及时检测,局部过热可能引发绕组接地故障、相间短路甚至设备烧毁^[4-5]。

由于匝间短路故障会引发定子绕组电流畸变、空间电磁场非对称分布及机械振动频谱偏移等多维物理特性异常^[6-7],其“电-磁-力-热”多物理场耦合效应又加剧了故障演化的非线性。但上述多维特征参数中存在的关联性变化规律,可为匝间短路辨识提供重要诊断依据^[8-11]。然而,现有诊断方法对早期微弱特征的灵敏度不足,且依赖高精度传感器,难以满足工业在线监测需求。如若能够精准识别早期匝间短路,及时采取适当相关措施,会极大提高 BLDCM 系统的运行可靠性。

目前,电机故障诊断方法主要包括解析模型法、信号分析法和人工智能诊断法,各自具备不同的优势,但针对无刷直流电机匝间短路这一高发故障的早期诊断仍存在显著局限性。解析模型法在描述电机全寿命周期特性方面效果显著^[12];张健等^[13]通过扩展卡尔曼滤波融合热应力与监测数据,显著提升了绝缘寿命预测精度;陆格野等^[14]构建 YN/yn 绕组数学模型,创新性定义压比/阻抗双频响应指标,实现了主绝缘状态监测。然而,上述模型参数与负荷电流强耦合,对 ITSC 特有的漏磁信号非线性畸变敏感性不足,且难以适应动态工况。

信号分析法通过高频特征提取提升鲁棒性^[15-16];李豪团队^[17]利用 300~400 kHz 频段瞬态响应曲线评估绝缘状态,但其对 ITSC 引发的低频漏磁异常缺乏针对性特征,且依赖高精度传感器。深度学习虽能减少人工干预^[18],如李政等^[19]通过时频图像融合实现多源故障识别,但其输入维度高达 $512 \times 512 \times 3$,导致模型复杂度激增,难以实时处理漏磁信号的空间分布零散性。上述挑战凸显了现有方法在 ITSC 早期诊断中的不足,急需一种能自适应融合多物理场特征的新型智能诊断方案。

目前基于深度学习的电机故障诊断研究仍存在两大主要问题:1)特征信息的空间分布较为零散^[20]。电机差异化状态下,诸如电流和漏磁等物理特征均会发生变化,虽然这些变化为状态评估提供了参考,但其分布较为分散,若针对每一项特征进行独立分析,则深度学习模型的输入

维度会呈指数增长^[21-23];2)信号变换方法往往将多组特征信号融合至高维空间,虽然可以丰富输入信息,但也引入了大量冗余数据,增加了从中提取关键特征的难度^[24-26]。综合上述分析可知:融合多源电磁场特征并通过蒸馏机制提取关键故障信息有望成为 BLDCM 故障诊断的核心。

为此,本研究提出了一种基于电磁场特征蒸馏的匝间短路智能辨识方法,其整体思路主要包括:首先,通过建立电机绕组的电磁等效模型,解析漏磁信号与绕组状态之间的内在关联;其次,提出电磁场特征图谱的构建方法及相应的信息蒸馏提取技术;最后,通过搭建试验平台,对方法的有效性进行验证。

1 匝间短路故障下空间电磁特性分析

为了解析匝间短路下 BLDCM 电磁特性演变规律,从绕组物理结构变化对磁路参数的直接影响出发,结合等效磁路模型与电磁耦合理论,建立短路匝数与漏磁信号的定量关联。如图 1 所示为匝间短路下电磁空间传导模型和等效磁路模型。




图 1 匝间短路下电磁空间传导模型和等效磁路模型
Fig. 1 Electromagnetic space conduction model and equivalent magnetic circuit model under turn-to-turn short circuit

图 1 中 Φ 是永磁体产生的总磁通, 主要由气隙磁通 Φ_g 和磁极间漏磁通 Φ_l 组成; Φ_g 包含了定子铁心磁通 Φ_s 和外部漏磁通 Φ_{st} ; Φ_r 是转子磁通; R_g 是气隙磁阻; R_l 是磁极间漏磁磁阻; R_r 和 R_{sf} 分别代表转子磁阻和定子磁阻; R_{sl} 是电机外部漏磁场磁阻。根据等效磁路可以将气隙磁通分为定子和电机外部漏磁两个路径。

1.1 绕组短路对电感与磁阻的定量影响

定子绕组的电感 L 与磁阻 R_m 满足的关系为:

$$L = \frac{N^2}{R_m} \quad (1)$$

当发生匝间短路时, 有效匝数减少为 $N_{fault} = N - n$, 其中 n 为短路匝数, 导致故障相电感下降, 即:

$$L_{fault} = \frac{(N - n)^2}{R_m} \quad (2)$$

磁阻 R_m 由铁芯磁阻 R_{core} 和气隙磁阻 R_g 组成, 即:

$$R_m = R_{core} + R_g = \frac{l_{core}}{\mu_{core} A_{core}} + \frac{l_g}{\mu_0 A_g} \quad (3)$$

其中, l_{core} 和 l_g 分别代表磁路中铁芯部分的长度和气隙(空气间隙)的长度, A_{core} 是铁芯截面积, A_g 是气隙截面积, μ_0 是真空磁导率, μ_{core} 是铁芯材料的相对磁导率。

短路匝数增加会引发局部铁芯饱和, 内部的短路环电流导致铁芯磁导率 μ_{core} 下降, R_{core} 增大; 且使得气隙磁场畸变, 漏磁路径等效面积 A_g 减小, R_g 上升。

所以, R_m 随 n 非线性增长, 漏磁通 Φ_l 需重新分配以满足磁路平衡。

1.2 电枢反应磁动势的重分布机制

短环路电流 I_{sc} 的分流效应改变了电枢反应磁动势 F_a 。设负载电流为 I_{load} , V_{ind} 是导致短路电流产生的电势, 源短路电流为 R_{sc} , 则:

$$\begin{cases} F_a = (N - n)I_{load} + nI_{sc} \\ I_{sc} = \frac{V_{ind}}{R_{sc}} \end{cases} \quad (4)$$

结合磁路欧姆定律, 总磁通 Φ 为:

$$\Phi = \frac{F_{PM} + F_a}{R_m} \quad (5)$$

其中, F_{PM} 代表永磁体的磁动势, 而随着 n 增加, R_m 上升速度超过 F_a 增幅, 导致气隙磁通 Φ_g 下降, 外部磁通 Φ_{st} 显著增大, 理论推导表明, Φ_{st} 与短路匝数满足的条件为:

$$\Phi_{st} \propto \frac{n}{N - n} \cdot \frac{1}{R_m} \quad (6)$$

定量分析表明, 短路匝数增加导致铁芯磁导率下降及气隙磁阻上升, 驱动漏磁通随短路比例 n/N 呈非线性增长。而作为三维空间矢量, 漏磁通各分量在不同短路

工况下呈现显著差异: 定子齿部因局部磁饱和引发漏磁畸变, 而电枢反应磁动势的动态变化进一步导致漏磁路径非对称分布。上述电磁特性差异为故障特征提取提供了物理依据。

2 基于电磁场特征蒸馏的匝间短路智能辨识方法

基于匝间短路下 BLDCM 空间电磁特性演变机理, 提出一种基于电磁场特征蒸馏的匝间短路智能辨识方法。该方法通过多源数据融合技术将离散漏磁信号整合为全局特征图谱, 继而采用轻量化视觉 Transformer (mobile vision Transformer, Mobile-ViT) 与卷积注意力模块 (convolutional block attention module, CBAM) 协同工作, 实现故障敏感特征的自适应筛选与增强, 最终通过卷积神经网络建立磁场异常模式与绝缘损伤程度的定量关联, 其技术流程如图 2 所示。

2.1 电磁场特征图谱构建

上述理论推导表明: 短路匝数的增加驱动气隙磁阻 R_g 上升及漏磁通 Φ_{st} 非线性增长, 其空间磁场畸变特性为故障特征提取提供了物理依据。为统一分析多路漏磁信号的空间分布与时变特性, 并解决特征零散和冗余问题, 设计了一种基于递归相空间重构 (recursive phase space reconstruction, RPSR) 的电磁场特征图谱构建方法。

递归相空间重构的核心思想是将一维时间序列嵌入到更高维度的相空间中, 以揭示其潜在的动力学特性。对于单路漏磁信号的时域序列 $\{x_{t1}, x_{t2}, \dots, x_{tm}\}$, 首先通过时间延迟法重构相空间, 得到状态向量序列:

$$\mathbf{X}_i = [x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}]^T, \quad i = 1, 2, \dots, N; \quad N = N - (M - 1)\tau \quad (7)$$

其中, m 为嵌入维数, T 为时间延迟, N 为相空间轨迹总点数, τ 代表的是相空间轨迹点数目。递归性体现在进一步分析相空间轨迹点 \mathbf{X}_i 和 \mathbf{X}_j 的临近关系: 若系统在时刻 j 的状态接近其在时刻 i 的状态 (即 \mathbf{X}_i 落入 \mathbf{X}_j 的领域内), 则称状态在 j 时刻递归到 i 时刻。

递归图 (recurrence plot, RP) 是刻画上述递归关系的可视化工具, 其数学定义为:

$$R_{i,j} = \Theta_r(\varepsilon_r - \|\mathbf{X}_i - \mathbf{X}_j\|) \quad (8)$$

其中, $\Theta_r(\cdot)$ 是 Heaviside 阶跃函数 (当自变量 ≥ 0 时输出 1, 否则输出 0); ε_r 是预设的距离阈值, 用于定义“邻近”的判定半径; $\|\cdot\|$ 为欧几里得范数。

式(8)通过遍历所有 (i, j) 组合 ($i, j = 1, 2, \dots, N$) 计算递归关系: 若 \mathbf{X}_j 落在以 \mathbf{X}_i 为中心, ε_r 为半径的邻域内 (即 $\|\mathbf{X}_i - \mathbf{X}_j\| \leq \varepsilon_r$), 则 $R_{i,j} = 1$, 表示在位置 (i, j) 发生递归; 否则 $R_{i,j} = 0$ 。此计算过程本质上是递归性的: 对每

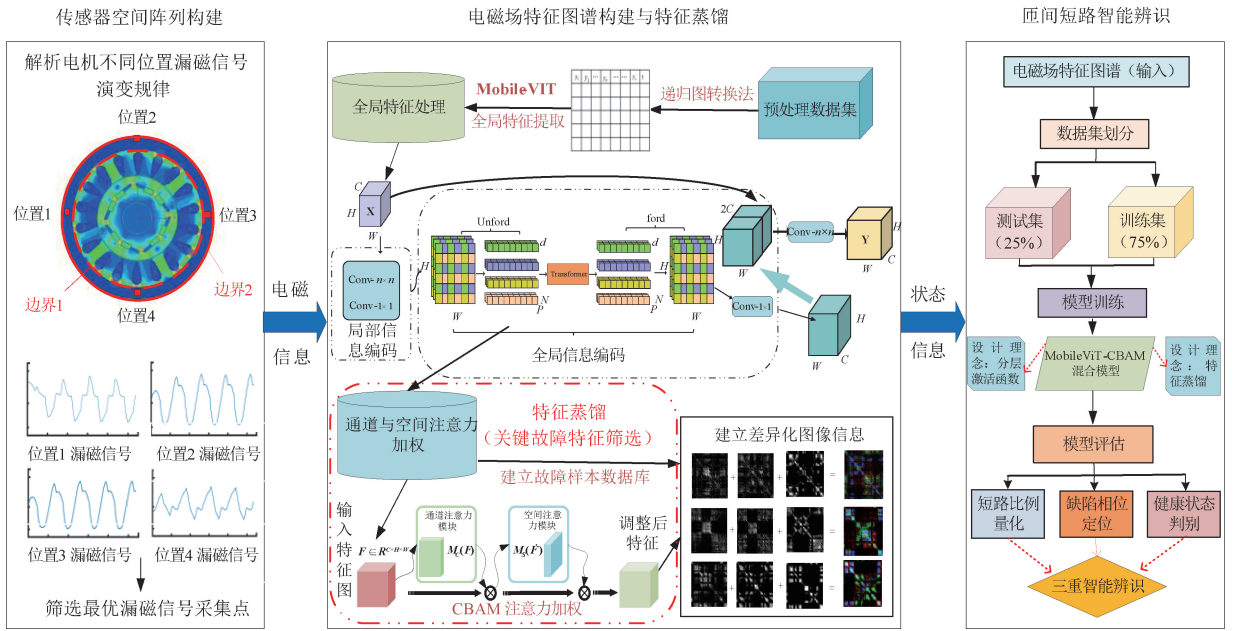


图2 智能算法流程
Fig. 2 Flowchart of intelligent algorithm

个参考点 X_i , 系统地检查所有目标点 X_j 是否递归到其邻域。

基于递归相空间重构技术, 三轴漏磁信号经各自独立转换为二维递归图后, 进一步融合为电磁场特征图谱。该方法通过多通道映射集成空间位置(传感器布局)、时域递

归特性及信号动力学信息, 显著提升单图特征密度。如图3所示, 不同短路状态下图谱的纹理结构(如对角线连续、斑块分布)呈现显著差异, 为特征蒸馏提供物理依据; 通过筛选与短路程度强相关的递归模式变异区域(如对角线断裂、亮斑聚集), 可蒸馏出关键故障特征。

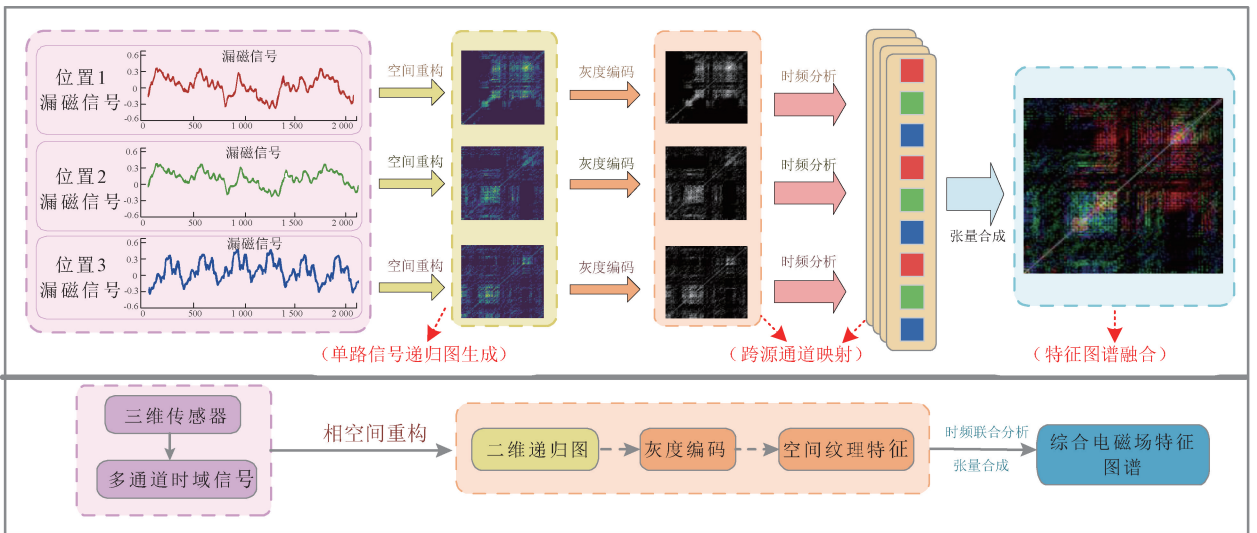


图3 多源信息融合递归场特征图谱融合流程
Fig. 3 Multimodal recursive field fingerprint fusion process

2.2 特征蒸馏机制设计

针对电磁场特征图谱中多维信息冗余与关键特征分散的问题, 该研究提出特征蒸馏机制(技术流程如图2所

示), 通过三级处理实现故障敏感特征的提纯, 即:

1) 局部特征提取(空间-通道联合编码): 输入特征图谱 $X \in \mathbf{R}^{H \times W \times C}$ (H 为高度, W 为宽度, C 为通道数), 首先

经过双阶段卷积操作:

$$\mathbf{X}_L^{(1)} = \text{Conv}_{3 \times 3}(\mathbf{X}), \quad \text{局部感受野捕获} \quad (9)$$

$$\mathbf{X}_L = \text{Conv}_{1 \times 1}(\mathbf{X}_L^{(1)}), \quad \text{通道维度压缩} \quad (10)$$

式中:输出降维特征 $\mathbf{X}_L \in \mathbf{R}^{H \times W \times d}$ ($d < C$), d 代表新的通道数,此操作保留空间细节,同时初步压缩冗余通道。

2) 全局特征蒸馏(跨区域关联建模):将 \mathbf{X}_L 重塑为图像块 $\mathbf{X}_U \in \mathbf{R}^{P \times N \times d}$ ($P = H \times W / \text{patch-size}^2$ 为块数, $N = \text{patch-size}^2$ 为每块像素数)。通过轻量化 Transformer 编码器建立全局分布关联:

$$\mathbf{X}_c(p) = \text{Transformer}(\text{LayerNorm}(\mathbf{X}_U)) \quad (11)$$

重组输出为 $\mathbf{X}_F \in \mathbf{R}^{H \times W \times d}$ 。Transformer 的自注意力机制实现:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right) \mathbf{V} \quad (12)$$

其中, $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别由 \mathbf{X}_U 线性投影生成, $\sqrt{d_k}$ 为缩放因子。

3) 多尺度特征融合(故障敏感特征增强):融合原始图谱 \mathbf{X} 与蒸馏特征 \mathbf{X}_F :

$$\mathbf{X}'_F = \text{Conv}_{1 \times 1}(\mathbf{X}_F) \quad (\text{通道对齐}) \quad (13)$$

$$\mathbf{X}_Y = \text{Concat}(\mathbf{X}, \mathbf{X}'_F) \quad (\text{残差连接}) \quad (14)$$

$$\mathbf{Y} = \text{Conv}_{3 \times 3}(\mathbf{X}_Y) \quad (\text{特征压缩}) \quad (15)$$

输出蒸馏后特征 $\mathbf{Y} \in \mathbf{R}^{H \times W \times C}$ 。此过程通过通道加权(如图 4 所示)实现,即:

通道蒸馏:生成权重 $\mathbf{M}_c(F) \in \mathbf{R}^{C \times 1 \times 1}$, 增强短路敏感频带:

$$\mathbf{M}_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F) + \text{MLP}(\text{MaxPool}(F)))) \quad (16)$$

空间蒸馏:生成权重 $\mathbf{M}_s(F') \in \mathbf{R}^{1 \times H \times W}$, 聚焦磁通畸变区域:

$$\mathbf{M}_s(F') = \sigma(\text{Conv}_{7 \times 7}([\text{AvgPool}(F'); \text{MaxPool}(F')])) \quad (17)$$

所以特征蒸馏全流程数据表征为:

$$\mathbf{Y} = \mathbf{M}_s(\mathbf{M}_c(F_{in}) \odot \mathbf{F}_{in}) \odot (\mathbf{M}_c(F_{in}) \odot \mathbf{F}_{in}) \quad (18)$$

其中,融合输入特征 F_{in} 定义为:

$$\mathbf{F}_{in} = \text{Conv}_{3 \times 3}(\text{Concat}(\mathbf{X}, \text{Conv}_{1 \times 1}(\mathbf{X}_F))) \quad (19)$$

2.3 匝间短路智能辨识

为实现对匝间短路故障的高精度、低复杂度辨识,设计了一种融合特征蒸馏机制的 MobileViT-CBAM 混合模型,其网络结构如图 4 所示,具体参数配置见表 1。该模型的核心思想是通过一个三级处理流程实现对关键故障信息的逐层提纯与增强:首先,通道蒸馏层通过加权增强故障敏感的频带特征;其次,空间蒸馏层用于聚焦定位故障下磁通畸变区域;最后,轻量化压缩层有效减少约 80% 的冗余特征参数,最终输出高纯度的故障特征。

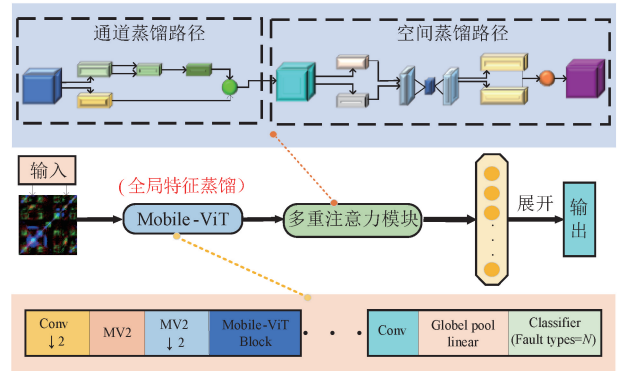


图 4 特征蒸馏网络结构 (MobileViT-CBAM)

Fig. 4 Characteristic distillation network structure (MobileViT-CBAM)

表 1 MobileViT-CBAM 网络结构参数

Table 1 MobileViT-CBAM network architecture parameters

模块类型	输出尺寸	参数
[Conv-3×3]×1	128×128	[3, 16, stride=2]
[MV2]×1		[16, 16, stride=1]
[MV2, ↓2]×1	64×64	[16, 24, stride=2]
[MV2]×2		[24, 24, stride=1]
[MV2, ↓2]×1	32×32	[24, 48, stride=2]
[MobileViT-block]×2		[48, 48, stride=1]
[MV2, ↓2]×1	16×16	[48, 64, stride=2]
[MobileViT-block]×4		[64, 64, stride=1]
[MV2, ↓2]×1	8×8	[64, 80, stride=2]
[MobileViT-block]×3		[80, 80, stride=1]
[CBAM block]×1		[80, 80, stride=1]
[Conv-1×1]×1		[80, 320, stride=1]
Global pool	1×1	[320, num_classes]
Classifier (Linear) ×1		

为精准适配漏磁信号固有的正负交变物理特性,模型在激活函数的选择上采用了创新的分层策略。在处理高分辨率(128×128)特征图的浅层网络中,采用带泄露的修正线性单元(LeakyReLU, $\alpha = 0.1$),以保留关键的负值波动信息。而在处理低分辨率($\leq 64 \times 64$)特征图的深层网络中,则采用指数线性单元(ELU, $\alpha = 1.0$),以增强模型对噪声的鲁棒性并加速收敛^[27]。消融实验表明,与采用单一 ReLU 激活函数的基线模型(Baseline Model)相比,该分层策略是实现高精度辨识的关键。而在模型训练阶段,采用 Nadam 优化器(初始学习率 5×10^{-4}),并结合 L2 正则化与早停机制防止过拟合。

为确保该研究框架在处理可能包含物理阈值判断等复杂逻辑时的扩展性,设计了可导的平滑函数来逼近不可导的阶跃操作,即:

$$f(\Phi_{st}) = \frac{1}{1 + e^{-k(\Phi_{st} - \Phi_{th})}} \quad (20)$$

其中, Φ_{st} 为实测漏磁通量, Φ_{th} 预设的物理阈值, k 为平滑系数(该研究中设为 100),控制函数过渡带的陡峭程度。该函数在反向传播中处处可导,且当 k 值较大时,能以极小的误差模拟理想阶跃函数的特性。在训练中,此方法配合梯度裁剪策略,可有效保障模型训练的稳定性(阈值=1.0)^[28]。该方法的有效性已通过对比实验验证,具体结果如表 2 所示。

表 2 误差函数逼近验证

Table 2 Error function approximation verification

(%)

阈值函数类型	健康状态误判率	短路状态误判率
理论阶跃函数	0.21	0.89
分段平滑函数	0.24	0.92

3 实验与结果分析

为了验证前文提出的匝间短路智能辨识方法的有效性,搭建了电机试验平台采集空间电磁信号,完成电磁场特征图谱的构建,实现匝间短路的精准诊断。

3.1 电机试验平台构建

如图 5 所示为该研究搭建的 BLDCM 试验平台,该平台由 2 台同型号无刷直流电机通过联轴器对拖组成,其中一台作为测试样机,另一台作为可编程负载机。




图 5 无刷直流电机试验平台

Fig. 5 Testing rig of BLDCM

平台配备了三维霍尔传感器、NI 多通道数据采集卡、电机控制器及相关电源。该平台能够精确模拟多种负载工况下的匝间短路故障。为了验证文章所提方法的

泛化能力,该研究在原有平台基础上又增加一台不同功率的 BLDCM。针对两台不同电机分开展开独立试验研究,证明所提方法的普适性。

依据团队前期仿真优化结果^[3],实验在电机壳体 3、9、12 点钟方向部署传感器阵列,这 3 个传感器的输出端与 NI 数据采集系统相连接,以实现针对不同位置径向漏磁信号的同步采集,采样频率同样设定为 20 kHz。该布局可有效捕获关键漏磁特征。通过同步采集多维度空间漏磁信号,构建表征绕组绝缘劣化的电磁特征集。

为了精确模拟不同的匝间短路状态,依据图 6 所示的无刷直流电机绕组结构进行故障设置,参考故障组别将电机状态分为 4 大类:健康状态(h)、a 相故障状态(a)、b 相故障状态(b)和 c 相故障状态(c)。

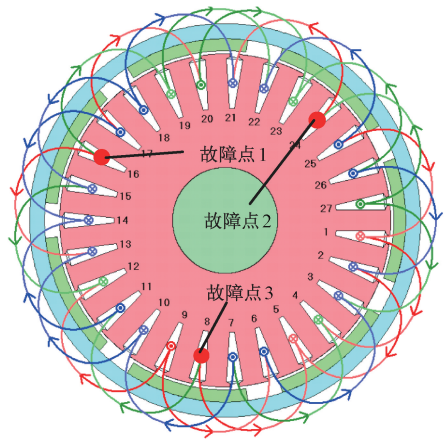


图 6 电机故障设置

Fig. 6 Motor fault setting

该电机定子分为三相,每相有 9 个槽,总计 27 个槽,同时每个槽独立绕制 13 圈线匝,总计 351 匝。通过连接相邻插槽的导线模拟绕组匝间短路的故障。如表 3 所示,电机每相绕组可以设置 5 种不同的故障程度, μ 分别为 0.11、0.22、0.33、0.44 和 0.55。其中短路程度为 $n/9$ 是 9 个槽中有 n 个被短路。同一相绕组内部模拟 3 个不同的故障位置,各个位置彼此间隔 120° 。三相绕组共计包含有 9 个故障位置。为了能够获得足够数据信息用于进一步的智能诊断,相同状态的试验数据重复试验多次。

3.2 电磁场特征图谱构建

如图 7 所示,针对无刷直流电机不同运行状态的漏磁信号时域特性分析,可观测到的规律为:在健康状态下,3 个传感通道的漏磁信号呈现准周期振荡特性,其波形周期与幅值具有空间分布非均匀性。当 a 相绕组发生 $2/9$ 匝短路时,各通道信号幅值仅产生微弱波动,波形形态仍保持基准特征;当 a 相短路程度增至 $4/9$ 匝时,其对应传感器通道信号幅值呈现显著递增趋势,且波形相位

表 3 BLDCM 匝间短路故障设置

Table 3 BLDCM turn-to-turn short circuit setup

标签	故障类型	标签	故障类型
1	健康	9	b 相短路 0.33
2	a 相短路 0.11	10	b 相短路 0.44
3	a 相短路 0.22	11	b 相短路 0.55
4	a 相短路 0.33	12	c 相短路 0.11
5	a 相短路 0.44	13	c 相短路 0.22
6	a 相短路 0.55	14	c 相短路 0.33
7	b 相短路 0.11	15	c 相短路 0.44
8	b 相短路 0.22	16	c 相短路 0.55

发生显著偏离。值得注意的是,当 b 相发生同等程度短路时,其关联传感通道的响应特性与 a 相缺陷演变规律呈现高度一致性。这种跨相位的差异化响应特征为故障定位提供了关键判据。

针对表 2 所列工况的时域电磁信号数据集,该研究对每个空间位置传感器(3、9、12 点)的信号采用 2.1 节的 RPSR 算法生成二维递归图谱。以 200 采样点为单位片段生成 128 pixels×128 pixels 的递归图像,每组工况构建 500 张样本库。如图 8 所示,将三轴传感器(对应 3 个空间位置)生成的 RP 图分别映射到 RGB 彩色图像的

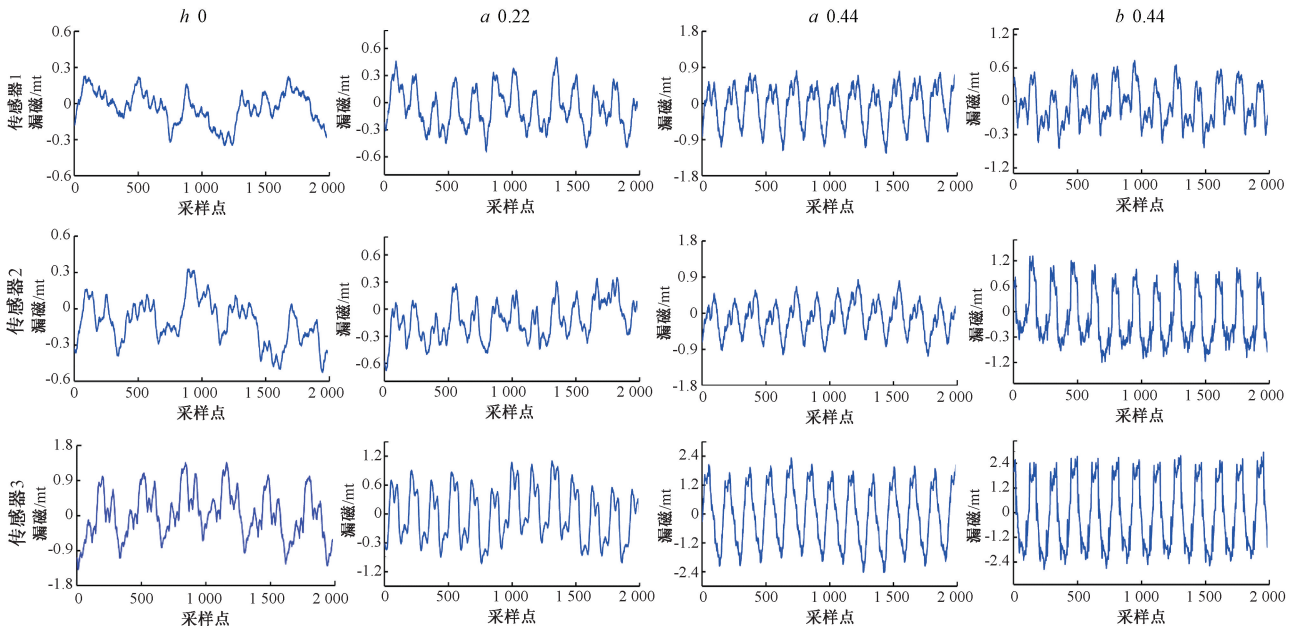


图 7 空间漏磁信号采集

Fig. 7 Magnetic leakage signal acquisition

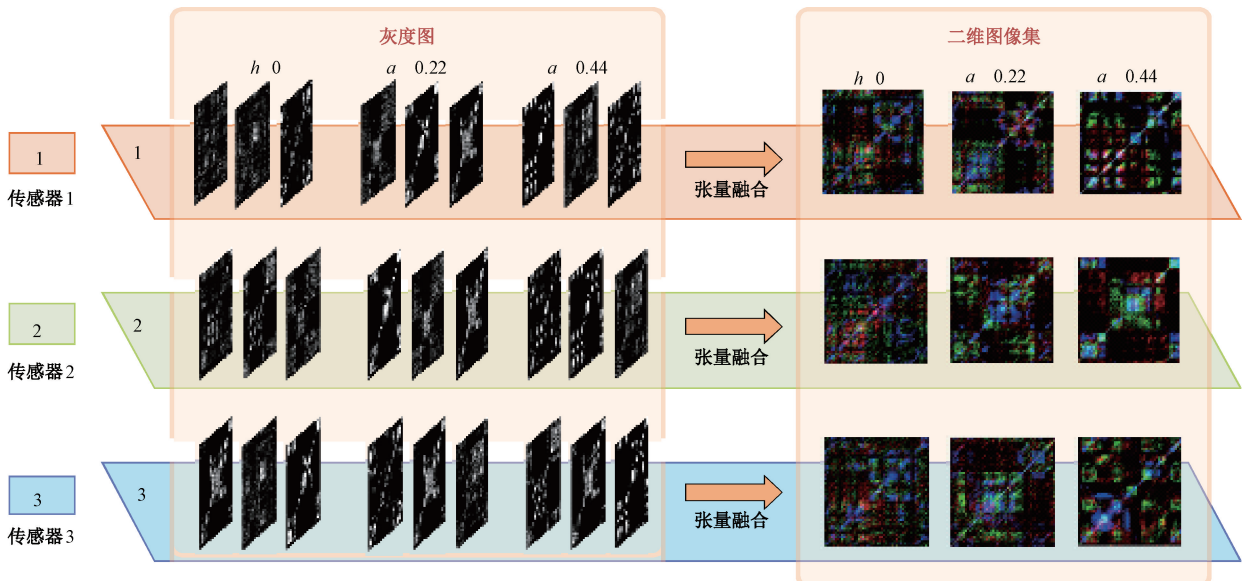


图 8 多通道递归场特征融合图谱

Fig. 8 Multi-channel recursive field feature fusion map





3个通道,将48组基础图谱经张量融合压缩为16组特征增强图谱,并标注对应故障等级。

对比分析表明:健康状态图谱呈现均匀的颜色混合与规则纹理(如均匀对角线),而随着短路程度加剧,图谱中特定通道(对应故障相附近传感器)的亮度显著升高,颜色分布失衡,且纹理复杂度(如斑块、对角线断裂)与漏磁信号畸变率呈正相关。这验证了提出的多源信息融合方法所生成的特征图谱,能够有效表征物理状态的演化,并具备高度的空间敏感性。

3.3 模型性能的综合评估与验证

1) 多工况短路状态分类性能

针对无刷直流电机多工况诊断的泛化能力验证,该研究通过空载与负载工况下16类电磁场特征图谱构建完备测试集。采用分层随机抽样策略将每组500张图谱划分为400张训练样本与100张测试样本,输入混合诊断模型进行端到端优化。训练过程中(如图9(a)~(d)所示),模型损失函数随迭代次数增加呈现指数衰减趋势,最终测试集分类准确率达99.4%(损失值0.017)。混淆矩阵可视化结果(如图9(e)~(f)所示)表明,除0.6%边界工况样本因信号重叠产生误判外,其余故障状态识别准确率均为100%,证实该方法在宽域工况下的稳定诊断能力与缺陷表征敏感性。



16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	98		
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	98	1	
14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0
12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0
11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0
10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0
1	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

真实标签

预测标签

(e) 辨识结果(负载状态): 混淆矩阵
(e) Training results (load condition): Confusion matrix

16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100						
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0					
14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0					
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0					
12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	98	0	0	0		
11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	3	92	1	2	0	0
10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	0	0	0	0	0	0
1	100	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

真实标签

预测标签

(f) 辨识结果(空载状态): 混淆矩阵
(f) Training results (no-load condition): Confusion matrix

图9 不同状态下辨识结果分类迭代过程

Fig. 9 Classification iteration process of training results under different conditions

2) 故障空间位置辨识能力

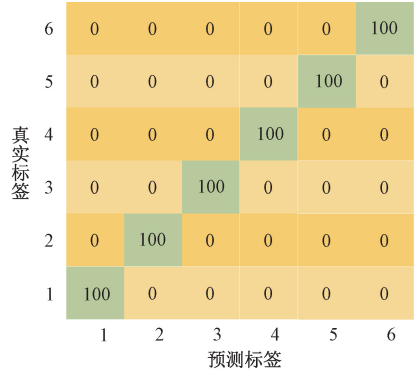
为分析漏磁信号与故障空间位置的关联性,该研究在 a 和 b 相绕组分别设置 3 个机械间隔 120° 的故障点(如图 6 所示),所有故障点短路程度均为 0.11。以 a 相为例,其绕组周向也均布 3 个独立故障点,每个故障点对应唯一标签(如表 4 所示)。

表 4 BLDCM 匝间短路故障设置

Table 4 BLDCM inter-turn short-circuit fault settings

标签	状态
1	a 相短路 0.11,故障点 1
2	a 相短路 0.11,故障点 2
3	a 相短路 0.11,故障点 3
4	b 相短路 0.11,故障点 1
5	b 相短路 0.11,故障点 2
6	b 相短路 0.11,故障点 3

通过可控短路测试模型同步采集 6 组实验数据(a 相 3 组+b 相 3 组),每组数据的采样规范、图谱尺寸及生成流程均与检测实验一致。实验结果表明:经迭代优化后,诊断准确率达 100% (如图 10(a)~(b)所示),且混淆矩阵(如图 10(c)所示)显示所有样本预测位置与实际故障点完全匹配,验证了空间位置特征的精准辨识能力。



(c) 辨识结果(故障情况): 混淆矩阵

(c) Training results (fault condition): Confusion matrix

图 10 辨识结果:故障定位

Fig. 10 Training results: Fault localization

3) 多模型对比验证诊断效能

为全面评估所提方法的有效性与先进性,进行了 2 组关键的对比实验。首先,将文章方法与包括 ResNet、Swin Transformer 在内的 4 类主流深度学习架构进行性能比较。其次,为验证该研究核心创新点(即分层激活函数与特征蒸馏机制)的有效性,还构建了一个与此文方法骨干网络相同、但使用单一 ReLU 且移除特征蒸馏模块的基线模型进行消融对比。

所有实验均在统一的硬件配置(如表 5 所示)和训练策略下进行,结果如表 6 所示。

表 5 模型训练平台配置

Table 5 Model training platform configuration


GPU	NVIDIA RTX 3060
CPU	Intel i9-10900F
操作系统	Windows 10
深度学习框架	Keras 2.6.0

表 6 不同深度学习方法的结果精度比较

Table 6 Comparison of result accuracy of different deep learning methods


模型	准确率/%	参数量/M	推理时间/ms
基线模型	96.8	1.2	2.6
ResNet	99.2	6.5	3.1
RegeNet	98.3	4.8	4.2
SwinTransformer	97.6	12.3	5.6
ConvNext	98.6	8.7	3.8
本文方法	99.4	1.2	2.8

跨模对比分析表明,文章方法取得了 99.4% 的测试准确率,不仅显著优于基线模型(96.8%),也超越了所有



(a) 辨识结果(故障状态): 准确率

(a) Training results (fault condition): Accuracy



(b) 辨识结果(故障状态): 训练误差

(b) Training results (fault condition): Training error

主流对比模型,包括次优的 ResNet (99.2%)。这一结果有力地证明,文章提出的分层激活函数对于精确捕捉漏磁信号特性至关重要,而独特的特征蒸馏机制则有效提升了对微弱故障缺陷的辨识灵敏度。

此外,在计算效率方面,本方法的优势同样显著:其模型参数量仅为 1.2 M (为 ResNet 的 18.5%),单样本推理速度达到 2.8 ms,较 Swin Transformer 等更复杂的模型提升了近 50%。综上所述,该方法在诊断精度和工程适用性上均实现了对主流方法的超越,展现了其在复杂工况下的综合优势。

3.4 抗干扰策略设计与验证

为评估该方法在实际复杂电磁环境中的抗干扰鲁棒性,文章对使用原始数据训练好的最终模型进行了一系列严格的含噪测试。实验中通过向原始的、干净的测试集中注入不同类型的工业噪声,构建了 3 个模拟真实干扰的测试场景,并与无噪声场景下的性能进行对比。

测试场景包括:无噪声(基准)、轻度高斯白噪声 ($SNR=20$ dB)、重度高斯白噪声 ($SNR=10$ dB) 以及工频干扰(含 50 Hz 基频)。

实验结果如表 7 所示。结果表明,本研究提出的模型表现出强大的抗干扰能力。即使在 $SNR=10$ dB 的重度噪声干扰下,模型准确率依然保持在 94.1%;在面对工频干扰时,准确率也高达 96.3%。研究结果表明,该模型学习到的特征模式具有鲁棒性和物理意义,从而证明了其在工业应用中的可靠性。

表 7 不同干扰条件下模型鲁棒性表现

Table 7 Robustness performance of the model under different interference conditions

测试集干扰条件	诊断准确率/%
无噪声	99.4
高斯白噪声 ($SNR=20$ dB)	97.8
高斯白噪声 ($SNR=10$ dB)	94.1
工频干扰 (50 Hz)	96.3

3.5 跨型号电机诊断性能验证

为进一步评估所提方法在面对不同电机模型时的泛化能力,该研究引入了一台与电机 A 型号不同的电机 B,并重复了完整的实验流程:包括数据采集、模型训练与测试。该跨型号验证旨在检验本方法所提取特征的普适性。

图 11 为相同故障下在电机 B 上生成的典型工况多源电磁场特征图谱。通过与图 8(电机 A 的图谱)进行对比可以发现,尽管两台电机生成的图谱在局部纹理和颜色分布上存在明显不同,但其整体的演化趋势与故障状

态高度相关。这种故障模式在视觉表征上的相似性,为跨型号的适应性提供了直观的物理基础。

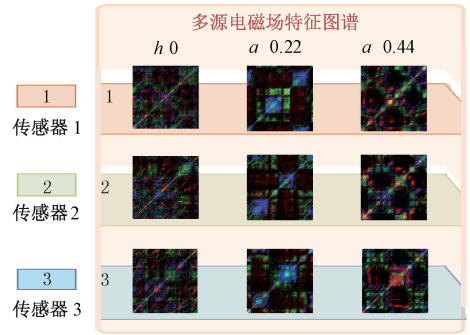


图 11 电机 B 典型工况下的多源电磁场特征图谱

Fig. 11 Multi-source electromagnetic field characteristic map of motor B under typical operating conditions

为定量评估该适应性,文章采用与前述实验完全相同的模型架构和训练策略,在电机 B 的数据集上进行独立的模型训练与测试,最终性能对比如表 8 所示。

表 8 不同型号电机在训练模型上的性能对比

Table 8 Performance comparison of different motor models on the training model

测试样机	电机 A	电机 B
模型	本文方法	本文方法
训练集规模	16×350	16×350
测试集规模	16×150	16×150
准确率/%	99.4	92.3
参数量/M	1.2	1.2
推理时间(ms/样本)	2.8	2.8

实验结果表明,尽管由于电机物理模型的差异导致电机 B 的准确率相较于电机 A 有所下降,但其依然维持了较高的诊断精度。这一结果客观地反映了两个方面:该方法所提取的多源电磁特征在不同电机模型之间具有良好的跨型号适应能力;但是性能下降也揭示了不同电机型号间差异性的固有挑战,为未来的研究提供了明确的方向,即结合迁移学习等策略对模型进行优化。

4 结论

本研究提出了一种基于多源电磁场特征蒸馏的无刷直流电机匝间短路智能辨识方法。该方法通过融合多源空间信息并设计轻量化的 MobileViT-CBAM 架构,实现了对故障特征的高效提纯与高精度辨识。

实验结果表明,该方法在多种负载工况及强噪声环境下均表现出优异的鲁棒性,在测试电机 A 上的诊断准

确率达 99.4%,且在另一台不同型号的电机 B 上进行的独立重复性验证中,该模型同样取得了 92.3%的准确率。这一跨型号验证,证明了该模型具有良好的普适性和工程应用潜力,为实现通用性、高精度的电机故障诊断提供了新的思路与有效途径。

参考文献

- [1] HUANG ZH R, LIN CH, XING J L. A parameter-independent optimal field-weakening control strategy of IPMSM for electric vehicles over full speed range [J]. IEEE Transactions on Power Electronics, 2021, 36(4): 4659-4671.
- [2] 尹诗荀, 郑志安, 朱俊杰. 基于延迟补偿的永磁同步电机并行自抗扰控制 [J]. 仪器仪表学报, 2024, 45(3): 275-285.
- YIN SH X, ZHENG ZH AN, ZHU J J. Parallel active disturbance rejection control for permanent magnet synchronous motor based on delay compensation [J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 275-285.
- [3] 吴振宇, 王慧, 胡存刚, 等. 基于多路漏磁信号阵列的无刷直流电机匝间短路故障诊断 [J]. 电工技术学报, 2025, 40(4): 1105-1116.
- WU ZH Y, WANG H, HU C G, et al. Inter-turn short circuit fault diagnosis of brushless DC motor based on multi-channel magnetic flux leakage signal array [J]. Transactions of China Electrotechnical Society, 2025, 40(4): 1105-1116.
- [4] MOUSMI A, ABBOU A, EL HOUM Y. Binary diagnosis of hall effect sensors in brushless DC motor drives [J]. IEEE Transactions on Power Electronics, 2020, 35(4): 3859-3868.
- [5] 殷晓康, 杨丽强, 王伟, 等. 外穿式集中绕组激励旋转电磁场涡流无损检测系统 [J]. 仪器仪表学报, 2021, 42(10): 239-250.
- YIN X K, YANG L Q, WANG W, et al. Eddy current non-destructive testing system based on external penetration-type concentrated winding excited rotating electromagnetic field [J]. Chinese Journal of Scientific Instrument, 2021, 42(10): 239-250.
- [6] MOON S, JEONG H, LEE H, et al. Interturn short fault diagnosis in a PMSM by voltage and current residual analysis with the faulty winding model [J]. IEEE Transactions on Energy Conversion, 2018, 33(1): 190-198.
- [7] 吴振宇, 王慧, 胡存刚, 等. 基于零序电压特性的无刷直流电机匝间短路在线检测 [J]. 中国电机工程学报, 2025, 45(9): 3685-3697.
- WU ZH Y, WANG H, HU C G, et al. Online detection of inter-turn short circuits in brushless DC motors based on zero-sequence voltage characteristics [J]. Proceedings of the CSEE, 2025, 45(9): 3685-3697.
- [8] ZIA U, JIN H. Analysis of inter-turn-short fault in an FSCW IPM type brushless motor considering effect of control drive [J]. IEEE Transactions on Industry Applications, 2020, 56(2): 1356-1367.
- [9] JAFARI A, FAIZ J, JARRAHI M A. A simple and efficient current-based method for interturn fault detection in BLDC motors [J]. IEEE Transactions on Industrial Informatics, 2021, 17(4): 2707-2715.
- [10] 崔征山, 周扬忠, 张竞, 等. 基于滑模和扩张状态观测器的双绕组无轴承磁通切换电机转子悬浮控制策略研究 [J]. 仪器仪表学报, 2022, 43(6): 269-279.
- CUI ZH SH, ZHOU Y ZH, ZHANG J, et al. Research on rotor suspension control strategy for dual-winding bearingless flux-switching motor based on sliding mode and extended state observer [J]. Chinese Journal of Scientific Instrument, 2022, 43(6): 269-279.
- [11] 万援, 张续, 郭健, 等. 背绕式绕组高速永磁发电机的抗匝间短路特性分析 [J/OL]. 中国电机工程学报, 2025: 1-12 [2025-05-14].
- WAN Y, ZHANG X, GUO J, et al. Analysis of inter-turn short circuit resistance characteristics of high speed permanent magnet generator with backwinding [J/OL]. Proceedings of the CSEE, 2025: 1-12 [2025-05-14].
- [12] 张菀, 张泰瑀, 贾民平, 等. 多传感器融合和 MHA-LSTM 的电机轴承剩余寿命预测 [J]. 仪器仪表学报, 2024, 45(3): 84-93.
- ZHANG W, ZHANG T Y, JIA M P, et al. Remaining useful life prediction of motor bearings based on multi-sensor fusion and MHA-LSTM [J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 84-93.
- [13] 张健, 张钦, 黄晓艳, 等. 基于加速退化数据和现场实测退化数据的电机绝缘剩余寿命预测模型 [J]. 电工技术学报, 2023, 38(3): 599-609.
- ZHANG J, ZHANG Q, HUANG X Y, et al. Residual life prediction model of motor insulation based on accelerated degradation data and field measured degradation data [J]. Transactions of China Electrotechnical Society, 2023, 38(3): 599-609.
- [14] 陆格野, 张品佳. VSC 系统换流变压器共模模型及主

- 绝缘在线监测方法[J]. 中国电机工程学报, 2021, 41(11): 3885-3896.
- LU G Y, ZHANG P J. VSC system converter transformer common mode model and main insulation on-line monitoring method[J]. Proceedings of the CSEE, 2021, 41(11): 3885-3896.
- [15] ALAM F R, ABBASZADEH K. Magnetic field analysis in eccentric surface-mounted permanent-magnet motors using an improved conformal mapping method[J]. IEEE Transactions on Energy Conversion, 2016, 31(1): 333-344.
- [16] 潘超, 陈祥, 蔡国伟, 等. 基于小波包尺度-能量占比的变压器三相不平衡绕组振动特征辨识[J]. 仪器仪表学报, 2020, 41(4): 129-137.
- PAN CH, CHEN X, CAI G W, et al. Vibration feature identification of three-phase unbalanced transformer windings based on wavelet packet scale-energy ratio[J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 129-137.
- [17] 李豪, 赵孟, 向大为, 等. 基于开关瞬态频率响应的伺服电机早期匝绝缘劣化在线监测[J]. 中国电机工程学报, 2020, 40(10): 3359-3368.
- LI H, ZHAO M, XIANG D W, et al. On-line monitoring of early turn insulation deterioration of servo motors based on switching transient frequency response [J]. Proceedings of the CSEE, 2020, 40(10): 3359-3368.
- [18] ZAMUDIO-RAMIREZ I, RAMIREZ-NUNEZ J A, ANTONINO-DAVIU J, et al. Automatic diagnosis of electromechanical faults in induction motors based on the transient analysis of the stray flux via MUSIC methods[J]. IEEE Transactions on Industry Applications, 2020, 56(4): 3604-3613.
- [19] 李政, 汪凤翔, 张品佳. 基于图像融合与迁移学习的永磁同步电机驱动器强泛化性故障诊断研究[J]. 中国电机工程学报, 2024, 44(12): 4933-4945.
- LI ZH, WANG F X, ZHANG P J. Research on strong generalization fault diagnosis of permanent magnet synchronous motor driver based on image fusion and transfer learning[J]. Proceedings of the CSEE, 2024, 44(12): 4933-4945.
- [20] CAO W P, HUANG R Q, WANG H, et al. Analysis of inter-turn short-circuit faults in brushless DC motors based on magnetic leakage flux and back propagation neural network [J]. IEEE Transactions on Energy Conversion, 2023, 38(4): 2273-2281.
- [21] 王璐, 程勇, 尹伟, 等. 基于 Sage-Husa 预测算法的直流无刷电机 Hall 传感器位置信息校正[J]. 仪器仪表学报, 2023, 44(10): 90-99.
- WANG L, CHENG Y, YIN W, et al. Hall sensor position information correction for brushless DC motor based on Sage-Husa prediction algorithm [J]. Chinese Journal of Scientific Instrument, 2023, 44(10): 90-99.
- [22] 刘铄, 宋俊材, 陆思良, 等. 基于灰度纹理特征提取和 CS-SNN 的双初级永磁同步直线电机退磁故障诊断研究[J]. 中国电机工程学报, 2023, 43(16): 6464-6474.
- LIU SH, SONG J C, LU S L, et al. Research on demagnetization fault diagnosis of dual primary permanent magnet synchronous linear motor based on gray texture feature extraction and CS-SNN [J]. Proceedings of the CSEE, 2023, 43(16): 6464-6474.
- [23] SHI ZH, SUN X D, CAI Y F, et al. Robust design optimization of a five-phase pm hub motor for fault-tolerant operation based on Taguchi method [J]. IEEE Transactions on Energy Conversion, 2020, 35(4): 2036-2044.
- [24] 刘行谋, 何明朗, 肖遥, 等. 新能源汽车油泵电机电磁力建模及其匝间故障监测方法研究[J]. 仪器仪表学报, 2023, 44(9): 302-312.
- LIU X M, HE M L, XIAO Y, et al. Electromagnetic force modeling and inter-turn fault monitoring method for oil pump motor in new energy vehicles [J]. Chinese Journal of Scientific Instrument, 2023, 44(9): 302-312.
- [25] 蒋婷婷, 张庆, 张钧深, 等. 变分非线性单分量 Chirp 模态提取及其在电机轴承诊断中的应用[J]. 仪器仪表学报, 2023, 44(2): 266-277.
- JIANG T T, ZHANG Q, ZHANG J SH, et al. Variational nonlinear single-component Chirp mode extraction and its application in motor bearing diagnosis [J]. Chinese Journal of Scientific Instrument, 2023, 44(2): 266-277.
- [26] YANG L, ZHAO J, LIU X D, et al. Effects of manufacturing imperfections on the circulating current in ironless brushless dc motors [J]. IEEE Transactions on Industrial Electronics, 2019, 66(1): 338-348.
- [27] CLEVERT D A, UNTERTHINER T, HOCHREITER S. Fast and accurate deep network learning by exponential linear units (elus) [J]. ArXiv preprint arXiv: 1511.07289, 2015.

- [28] PASCANU R, MIKOLOV T, BENGIO Y. On the difficulty of training recurrent neural networks[C]. 30th International Conference on Machine Learning, 2013: 2347-2355.

作者简介



吴振宇, 2022 年于西南交通大学获得博士学位, 现为安徽大学电气工程与自动化学院讲师, 主要研究方向为机电设备的故障演化、状态感知、智能诊断。

E-mail: zhenyu-wu@ahu.edu.cn

Wu Zhenyu received his Ph. D. degree from Southwest Jiaotong University in 2022. Now he is a lecturer at the School of Electrical Engineering and Automation of Anhui University. His main research interests include fault evolution, condition monitoring, and intelligent diagnosis of electromechanical equipment.



屈先锋, 2024 年于安徽工业大学获得学士学位, 现为安徽大学硕士研究生, 主要研究方向为电机故障诊断。

E-mail: qxf@stu.ahu.edu.cn

Qu Xianfeng received his B. Sc. degree from Anhui University of Technology in 2024.

Now he is a master's student at Anhui University. His main research interest includes motor fault diagnosis.



王慧, 2024 年于安徽大学获得博士学位, 现为中国电力科学研究院有限公司工程师, 主要研究方向为基于信号处理的电力设备故障诊断。

E-mail: whui7023@163.com

Wang Hui received her Ph. D. degree from Anhui University in 2024. Now she is an engineer at China

Electric Power Research Institute. Her main research interest includes machine fault diagnosis based on signal processing.



刘永斌, 1999 年于合肥工业大学获得学士学位, 2004 年于中国科学技术大学获得硕士学位, 2011 年于中国科学技术大学获得博士学位, 现为安徽大学教授, 主要研究方向为设备状态监测与智能运维、智能材料驱动与传感。

E-mail: lyb@ustc.edu.cn

Liu Yongbin received his B. Sc. degree from Hefei University of Technology in 1999, and M. Sc. and Ph. D. degrees both from the University of Science and Technology of China in 2004 and 2011, respectively. He is currently a professor with the College of Electrical Engineering and Automation at Anhui University. He is currently a professor with the National Engineering Laboratory of Energy-Saving Motor and Control Technology. His main research interests include smart material actuators and machinery condition monitoring and fault diagnosis.



陆思良 (通信作者), 分别于 2010 年和 2015 年获得中国科学技术大学机械工程学士和博士学位。现为安徽大学电气工程与自动化学院教授, 主要研究方向为机电系统的状态监测和故障诊断、信号处理、物联网和边缘计算。

E-mail: silianglu@ahu.edu.cn

Lu Siliang (Corresponding author) received his B. Sc. and Ph. D. degrees in Mechanical Engineering from the University of Science and Technology of China in 2010 and 2015, respectively. He is currently a professor in the School of Electrical Engineering and Automation at Anhui University. His main research interests include condition monitoring and fault diagnosis of electromechanical systems, signal processing, internet of things and edge computing.