

DOI:10.19651/j.cnki.emt.2518169

无刷直流电机角域数据混合域泛化故障诊断^{*}

陈银超 王涛 王凯 梁兆鑫 王睿

(中国航空工业集团公司成都飞机设计研究所 成都 610041)

摘要: 无刷直流电机(BLDC)在众多工业领域被广泛应用, BLDC在重要的应用场景中发生故障容易造成重大经济损失甚至人员伤亡, 因此对其开展故障诊断研究具有重要意义。BLDC常处于变工况服役环境中, 用于数据驱动模型训练的源域和目标域通常具有分布差异, 现有众多学者利用域自适应迁移学习方法解决该问题。但是域自适应方法需要在训练过程中访问目标域, 这给模型的部署应用带来了不便。因此本文提出了角域数据混合域泛化网络解决此问题, 所提方法能够利用BLDC不同工况的多个源域进行学习, 挖掘域泛化知识, 从而在未见过的目标域上具有较好泛化性能, 具备一次训练, 多应用场景部署能力。所提方法利用角域电流重采样方法将BLDC的时域电流转换为角域电流以缓解工况影响, 基于卷积神经网络架构模型搭建故障诊断网络, 并利用先进的数据增强方法 Mixup 对训练数据进行处理, 改善模型泛化性能。最后基于丰富的BLDC故障实验数据将所提方法与其他先进方法相比, 对比结果证明所提方法具备优异的域泛化故障诊断性能。

关键词: 无刷直流电机; 故障诊断; 域自适应; 域泛化; 角域重采样

中图分类号: TM30; TN710 **文献标识码:** A **国家标准学科分类代码:** 470.4024

Angular domain data mixed domain generalization for fault diagnosis of brushless DC motor

Chen Yinchao Wang Tao Wang Kai Liang Zhaoxin Wang Rui

(AVIC Chengdu Aircraft Design & Research Institute, Chengdu 610041, China)

Abstract: Brushless dc motors (BLDCs) are widely used in various industrial fields. Failures in critical applications can lead to significant economic losses or even casualties, highlighting the importance of fault diagnosis research. BLDCs often operate under varying conditions, leading to the differences between the source and target domains used in data-driven models. While domain adaptation methods are commonly used to address this problem, they require access to the target domain during training, complicating model deployment. To overcome this, we propose the angular domain data mixed domain generalization network (ADMDG). This method leverages multiple source domains from different BLDC operating conditions to learn domain-generalized knowledge, enabling effective generalization to unseen target domains and allowing for a single training process to support multiple deployment scenarios. ADMDG employs an angular domain current resampling technique to convert time-domain currents into angular-domain currents, mitigating the impact of varying conditions. A convolutional neural network-based fault diagnosis model is constructed, and advanced data augmentation techniques, Mixup, are used to enhance model generalization. Extensive BLDC fault experiments demonstrate the superior domain generalization performance of the proposed method compared to other state-of-the-art approaches.

Keywords: brushless DC motor; fault diagnosis; domain adaptation; domain generalization; angular domain resampling

0 引言

无刷直流电机 (brushless DC motor, BLDC) 具有功率密度高, 控制简单, 运行稳定可靠等一系列优点, 已在工业界得到广泛应用。但 BLDC 若长期运行在恶劣工况和环境

下缺少有效监测维护, 则容易产生各类故障使得 BLDC 运行质量降低, 设备非计划停机, 甚至带来人员伤亡等严重事故^[1]。对 BLDC 开展故障诊断研究, 可以在故障萌发初期及时发现故障征兆, 及时开展有效维护检修避免后续事故发生, 因此对 BLDC 开展故障诊断研究具有重要意义^[2]。

收稿日期: 2025-02-25

* 基金项目: 科工局项目 (JCKY2022205A003) 资助

BLDC 常见故障可分为电气故障、永磁体故障和机械故障^[3]。这些故障发生后,可以在电机的电流、振动、声音等信号中采用合适的信号处理方法提取到相应的故障特征^[4]。如电机电流特征分析(motor current signature analysis, MCSA)则是一种常用方法,其主要采用电机定子电流进行频域分析,识别电力频谱中的特定故障谐波进行故障检测和识别^[5]。但是定子电流谐波容易受到其他噪声影响或者是其他故障谐波叠加,为故障识别和分类带来困难^[6]。此外 BLDC 在变工况下,非平稳电流信号的频谱中各谱线会相互交叠至模糊,进一步的增大故障诊断难度^[7]。

近年来深度学习方法快速发展,其在电机故障诊断领域也得到了广泛应用。如 Zimmnickas 等^[8]用短时傅里叶变换处理 BLDC 振动信号提取时频谱的谱熵和瞬时频率作为特征,用双向长短时记忆网络对特征进行学习分类,从而实施数据分类故障诊断。Shifat 等^[9]利用完全集成经验模态分解方法分解 BLDC 振动信号,再提取子振动信号与 BLDC 电流信号的均值,均方根值,熵等统计指标为数据特征,并用主成分分析方法对特征进行降维后再用人工神经网络进行训练分类,从而实现故障诊断。常玉燕^[10]用小波包提取 BLDC 电机电流,扭矩,速度信号的能量特征,并将这些特征输入径向基函数神经网络中进行训练和测试,并采用了粒子群和遗传优化算法改善了网络的参数收敛速度和性能。类似的,覃仕明等^[11]融合 CNN 方法和蚁群优化算法方法改进的双向长短时记忆网络提出了一种可以适应复杂环境的 BLDC 故障诊断方法。吴振宇等^[12]利用多路漏磁传感器检测 BLDC 匝间短路时的漏磁变化,并将多路传感器信号输入反向传播神经网络中进行训练后进行故障诊断。武智超等^[13]则利用漏磁阵列信号的时域特征实现高阻故障的检测和定位,再结合神经网络模型实现高阻故障的定量评估。

这些方法都在 BLDC 故障实验数据中得到了很好的验证,但其训练数据和测试数据都是来之于平稳工况,且数据分布一致,这较难满足电机的实际应用场景。BLDC 具有控制性能简单优异,常被应用于变速变载等多变工况场合中,这会使得监测数据具有非平稳特性。此外 BLDC 故障发生具有随机性,实际应用场景中的故障样本通常难以收集,故障所涵盖的电机工况更为稀缺,因此这必然会导致机器学习模型的训练数据与测试数据出现分布差异问题,使其泛化性变差,诊断准确率降低。

近年来来众多学者采用域自适应迁移学习方法解决这一问题,域自适应方法是利用带标签的源域数据和无标签的目标域数据对模型进行训练,使得机器学习模型在目标域上具有较好的泛化性能。如 Xiao 等^[14]利用 1 D-CNN (1-dimension convolutional neural network) 提取感应电机振动信号特征,用最大均值差异(maximum mean discrepancy, MMD) 对齐源域和目标域数据特征实现域自适应学习。Shi 等^[15]基于域对抗神经网络思想和 1 D-CNN

结构,构建针对感应电机振动信号和声音信号的多源数据子域自适应模型,该模型在特征提取器和域鉴别器之间进行域对抗训练,学习得到子域不变特征,再将其送入分类器中进行分类预测实现感应电机跨工况故障诊断。Luo 等^[16]提出一种阶次跟踪方法提取电机定子电流阶次特征,并将其输入全连接神经网络构成阶次神经网络后再用局部 MMD 对齐源域和目标域特征改进模型泛化性能,实现 BLDC 的跨工况故障诊断。

上述域自适应方法都取得了一定效果,但域自适应方法在训练时要求目标域数据可访问,在针对不一致的新目标域数据时再次进行训练才可达到较好诊断效果,这为模型的实际应用部署带来了不便。近年来新提出的域泛化方法^[17]可以解决这一问题,其主要是采用多个源域数据对模型进行训练,使得神经网络能够学习到域不变特征,从而使模型在面对不同分布的目标域数据时也可具有较好泛化性能,达到较好诊断效果。如 2018 年 Zhang 等^[18]提出了 Mixup 数据增强方法,其主要采用样本随机线性插值增强数据后对模型进行训练,提升泛化性能,其方法简单有效,已在学术界和工业界得到广泛重视和利用,但在电机故障诊断领域的应用还十分有限,有待进一步探索。

为解决 BLDC 故障诊断中源域目标域分布不一致以及目标域难访问问题,本文将提出一种针对 BLDC 的角域数据混合域泛化网络(angular domain data mixed domain generalization network, ADMDG)故障诊断方法。该方法使用角域重采样方法得到 BLDC 定子角域电流缓解电机工况影响,构建 CNN 网络并用 Mixup 增强角域电流样本后训练 CNN,使其在未见过的目标域上具有更好的泛化性。

1 理论基础

1.1 BLDC 电流角域重采样

根据文献^[16]的研究结果可知,在 BLDC 变工况情况下,使用角域电流重采样方法对电流进行处理后再对神经网络进行训练,可以显著提高模型诊断效果。BLDC 属于同步电机,其在运行时电流相位与电机转子旋转相位严格一致,因此可使用电机电流相位对 BLDC 定子电流进行角域重采样^[19]。图 1 所示为一段采用六步换向法控制的 BLDC 三相电流,运行时三相电流两两之间会以 1/6 电周期间隔形成交叉点,采用差分检测方法,可以得到 a 与 b 两相电流中这些交叉点的坐标 T_s^{ab} ^[16]:

$$T_s^{ab} = \{x \mid x = n + (i_n^a - i_n^b)/(k_n^b - k_n^a), i_n^{ab} \cdot i_{n+1}^{ab} \leq 0, n = 0, 1, \dots, N-2\} \quad (1)$$

式中: i_n^a 表示 a 相电流, k_n^b 表示 b 相电流前向差分, i_n^{ab} 表示 a 和 b 两相电流差值。

再将三相电流两两之间的交叉点坐标进行拼接,并按坐标序号大小排列转换为数列,即可得到三相电流 1/6 间隔的交汇点坐标序列 T_m^{abc} ^[16]:

$$T_m^{abc} = \text{sort}(T_s^{ab} \oplus T_s^{bc} \oplus T_s^{ca}) \quad (2)$$




图 1 BLDC 三相电流^[16]

Fig.1 BLDC three phase current^[16]

式中: $m = 0, 1, 2, \dots, M - 1$ 。⊕ 表示序列拼接符号, m 可代表间隔为 $1/6$ 电周期的离散角度。最后得到 T_m^{abc} 如图 1 所示。

在得到交汇点坐标序列 T_m^{abc} 后可采用两次插值方法得到某相角域电流, 首先第一次采用立方插值得到的等角度的离散时间序列^[20]:

$$t_j = \text{interpolation}(\{m, T_m^{abc}\}, \alpha_j) \quad (3)$$

其中, 期望的插值点坐标 $\alpha_j = \frac{M}{J} \cdot j, (j = 0, 1, 2, \dots, J - 1)$, j 为离散角度, J 在本文中被设置为 $20M$, 代表 $1/6$ 电周期间隔中插入 20 个点。

第二次根据等角度间隔的时间序列 t_j 采用线性插值即可得到角域电流 i_j^{aa} ^[20]:

$$i_j^{aa} = \text{interpolation}(\{n, i_n^a\}, t_j) \quad (4)$$

1.2 域泛化

域泛化的目标是在 M 个源域 $S = \{S^i | i = 1, 2, \dots, M\}$ 中训练一个神经网络模型 $y = f(x)$ 。

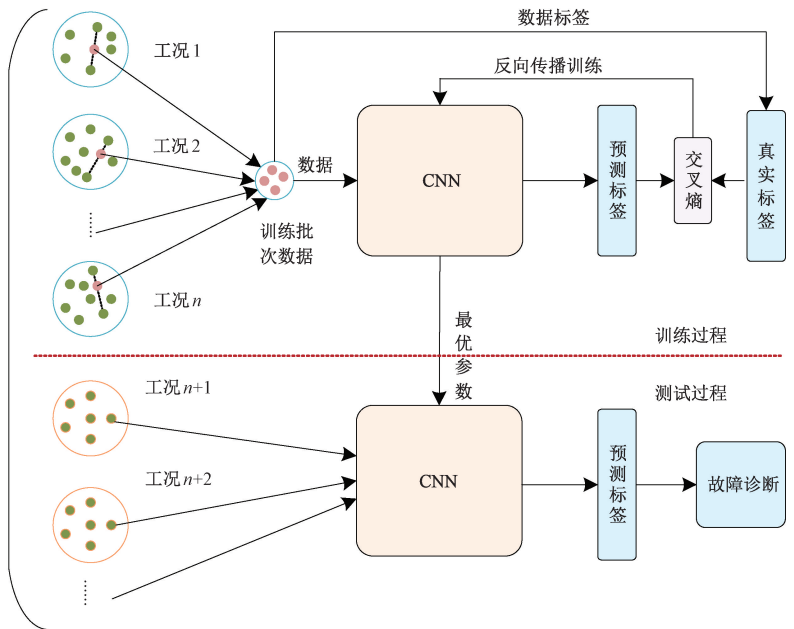



图 2 角域数据混合域泛化网络

Fig.2 Angular domain data mixed domain generalization network

使得模型在未见过的目标域 $S_{test} = (x_j^i, y_j^i)_{j=1}^{n_i}$ 上的预测误差最小, 即期望 $E_{(x,y) \in S_{test}} [L(f(x)), y]$ 最小^[17]。这里 i 表示域标签, n_i 表示样本数量, L 表示损失函数。

1.3 经验风险最小化

在机器学习中, 要训练得到一个最优映射 $f: X \rightarrow Y$ 需要评估模型输出分布与目标域空间 Y 上的差异, 现定义这个差异为风险 R ^[21]:

$$R(h) = E[L(f(x), y)] \quad (5)$$

式中: E 表示数学期望, L 表示用于模型训练的损失函数。

在实际应用中, 因为 X 和 Y 的真实分布不可知, 因此可利用训练集 X 的样本对风险 R 进行估计, 得到经验风险^[21]:

$$R_{emp}(h) = \frac{1}{n} \sum_{i=1}^n L(f(x_i), y_i) \quad (6)$$

具体地, 在本文的模型域泛化训练过程中, 通过每一批训练样本都均匀取自各个域中的方法来实现经验风险最小化 (empirical risk minimization, ERM) 的训练目标。

1.4 Mixup 数据增强方法

Mixup 是一种简单的数据增强方法, 其采用样本之间的随机线性插值对数据样本进行增强, 以丰富机器学习方法的训练资料, 使其达到较好泛化性能。具体公式表达如下^[18]:

$$\tilde{x} = \lambda x_i + (1 - \lambda)x_j, \tilde{y} = \lambda y_i + (1 - \lambda)y_j \quad (7)$$

式中: 样本 x 和 y 是在样本集中随机选择的特征和标签对, y 是 one-hot 标签, λ 服从 $0 \sim 1$ 的 Beta 分布。

2 角域数据混合域泛化网络

本文所提方法 ADMDG 故障诊断方法如图 2 所示, 其

主要可以分为数据预处理、模型训练和模型测试环节。

首先在数据预处理部分,采集得到的时域电流经过 1.1 节的角域重采样处理,得到对应的角域电流。紧接着采用滑窗处理,将角域电流序列阶段为适合模型输入的样本,并按不同 BLDC 不同的工况分为不同的工况域,一部分作为用于训练的源域,另一部分作为用于测试的目标域。

在模型训练环节,在一个前向传播过程中,均匀地从 n 个源域中各自随机取样,并对取得的样本进行随机插值,构成一个训练批次数据。从 n 个工况域中均匀采样是为了实现 ERM 目标,再对采样的样本进行线性随机插值是为了实现 Mixup 的效果。

得到批次训练数据后再利用交叉熵损失函数对模型展开训练,目标函数收敛后即可得到最优训练模型,CNN 模型的主要参数如表 1 所示,该网络包括 8 层卷积层,以及卷积层之后的 2 层全连接层。全连接层输入输出数据长度分别为 256~96 和 96~15。该 CNN 的结构形式参考了文献[22]。

表 1 CNN 参数

Table 1 CNN parameter

卷积层 序号	输入 通道	输出 通道	卷积核 长度	最大池化层 核长度
1	1	2	256	3
2	2	4	128	3
3	4	8	64	3
4	8	16	32	2
5	16	32	16	2
6	32	64	8	2
7	64	128	4	2
8	128	256	2	2

在得到最优训练模型后,即可对目标域样本进行预测,利用预测得到的数据标签即可对电机健康状态进行估计,从而实现故障诊断目标。

3 案例验证

3.1 数据介绍

本文所用数据为文献[16]中经过故障实验得到的星接 BLDC 的单相电流,采样频率为 12.8 kHz,单段数据为约 11.72 s,不包括电机启动和停止阶段。数据集中的故障包括 5 种程度的匝间短路、3 种程度的转子退磁故障、3 种程度的高阻故障和 3 种程度的驱动器故障共计 15 种健康状态。电机运行工况包括 6 种波形和 2 种扭矩,各类波形和扭矩组合共计 12 种工况,具体如表 2 所示。因此本文所用数据集为 $15 \times 12 = 180$ 段电流时序数据,每段 11.72 s。在后续实验中采用滑窗窗口为 6 400,步长为 1 067 的滑窗方法对每段数据进行数据扩充,详细数据介绍读者可参考文献[16]。

表 2 实验 BLDC 工况^[16]Table 2 Experimental BLDC operating condition^[16]

速度波形	波形频率/Hz	转速范围	负载扭矩/Nm
正弦	1	1 330~3 560	
方波	0.5	1 020~4 000	
随机	50	2 650~3 560	0.2 和
三角波	0.05	1 550~4 040	0.4
恒值 1	0	2 400	
恒值 2	0	3 900	

现定义不同速度波形和负载扭矩工况为不同的数据域,域定义如表 3 所示。

表 3 数据域定义^[16]Table 3 Definition of data domain^[16]

扭矩/Nm	正弦	方波	随机	三角	恒值 1	恒值 2
0.2	1	2	3	4	5	6
0.4	7	8	9	10	11	12

将这些不同的域按不同规则分为目标域和源域,构成不同的迁移任务以检测算法性能,具体的迁移任务如表 4 所示。表中呈现了各个任务的目标域,其域源为 12 个工况域除掉目标域后剩下的域。如表 3 中的 Ts7 的目标域为 1,2,3,源域为 4~12。

表 4 迁移任务定义

Table 4 Definition of transfer task

代号	目标域	代号	目标域
Ts1	1,2	Ts7	1,2,3
Ts2	3,4	Ts8	3,4,5
Ts3	5,6	Ts9	5,6,7
Ts4	7,8	Ts10	7,8,9
Ts5	9,10	Ts11	9,10,11
Ts6	11,12	Ts12	11,12,1

3.2 对比方法

为验证所提方法性能,现额外引入 6 种方法与所提方法进行对比,所有方法包括 CNN-time, CNN-ang, 所提方法 ADMDG 和先进的域泛化方法 RSC^[23], GroupDRO^[24], CORAL^[25], ANDMask^[26]。其中 CNN-time 为以时域电流数据为输入的 CNN, CNN 参数结构与所提方法一致,其训练过程采用了 ERM 方法。CNN-ang 则是输入变为角域电流数据,其他参数与 CNN-time 相同。ADMDG 为所提方法。RSC, GroupDRO, CORAL, ANDMask 为在 1 D-CNN-ang 基础之上,训练过程使用了对应的域泛化策略。为确保对比方法的公平性,所有方法的训练迭代次数,学习率,优化器等训练参数均一致。

3.3 对比结果

利用表 4 中定义的 12 个迁移任务对各方法进行对比分析,将各方法在源域中进行充分训练,再在目标域上进行故障诊断对比分析,整理得到各故障诊断准确率结果如图 3 和表 5 所示。图 3 中的横轴代表各迁移任务,纵轴代表各方法在相应目标域上测试得到的准确率。为避免模型训练过程中的随机性,所有准确率测试结果都是 6 次训练与测试之后得到的平均值。表 5 则是对应各方法的测试平均准确率。

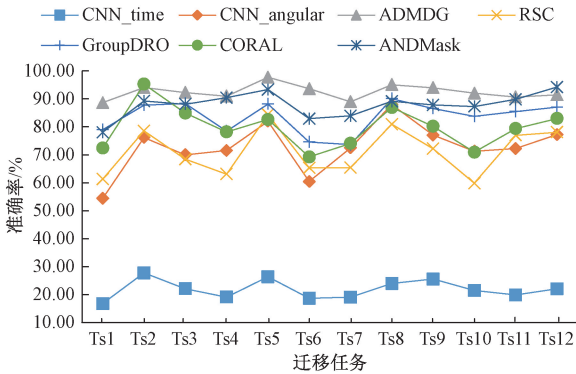


图 3 各方法的迁移任务准确率

Fig. 3 Accuracy of transfer task of each method

表 5 各方法的平均准确率和标准差

Table 5 Mean accuracy and standard deviation of each method

方法名称	平均准确率/%	标准差/%
CNN-time	21.84	3.27
CNN-angular	72.68	8.40
ADMDG	92.41	2.48
RSC	71.16	8.02
GroupDRO	83.54	5.43
CORAL	79.71	7.16
ANDMask	87.82	4.29

从图 3 中可以看出,所提方法 ADMDG,即图中的灰色三角标曲线,在多个迁移任务上都处于最高位置,只有在 Ts2 任务上被 CORAL 方法轻微超越;且所提方法的测试结果准确率曲线相对平稳,波动较小,多数准确率点都在 90% 以上。从表 5 则可以更为明显看出所提方法的平均准确率最高,标准差最小,测试结果最为稳定。此外,从图 3 和表 5 中都可以明显发现 CNN_angular 的诊断准确率明显超越 CNN_time,这证明了对 BLDC 定子电流进行角域重采样处理可以明显减少工况影响,提高机器学习方法的诊断性能。

总之,上述对比分析显示所提方法 ADMDG 的故障诊断准确率明显超越其他方法,这证明其是一个有效的 BLDC 故障诊断方法。

4 结 论

本文提出了一个针对 BLDC 的域泛化故障诊断方法 ADMDG,所提方法利用角域重采样方法对 BLDC 定子电流进行处理以缓解转速波动在数据上的影响。并设计了一个 CNN 网络架构,采用 Mixup 方法使得 CNN 在多个 BLDC 的工况源域中挖掘域泛化知识,使得模型在未见过的目标域上达到较好泛化效果,实现域泛化故障诊断。利用丰富的 BLDC 故障实验数据,将 ADMDG 域多个先进方法相比,对比结果证明所提方法具有较高故障诊断准确率且多次测试结果准确率都极具稳定性,因此所提方法 ADMDG 是一个有效的 BLDC 故障诊断方法。

参考文献

- [1] 吴国沛,余银犬,涂文兵. 永磁同步电机故障诊断研究综述[J]. 工程设计学报, 2021, 28(5): 548-558.
WU G P, YU Y Q, TU W B. Review of research on fault diagnosis of permanent magnet synchronous motor[J]. Chinese Journal of Engineering Design, 2021, 28(5): 548-558.
- [2] SOLÍS R, TORRES L, PÉREZ P. Review of methods for diagnosing faults in the stators of BLDC motors[J]. Processes, 2023, 11(1): 82.
- [3] 徐政. 基于高频信号注入的永磁同步电机故障诊断方法研究[D]. 南京:东南大学, 2024.
XU ZH. Fault diagnosis of permanent magnet synchronous machine with high frequency signal injection[D]. Nanjing: Southeast University, 2024.
- [4] LUO C, WANG J, MIAO Q. Transient current ratio dendrite net for high-resistance connection diagnosis in BLDCM [J]. IEEE Transactions on Power Electronics, 2024, 39(4): 4746-4757.
- [5] NIU G, DONG X, CHEN Y. Motor fault diagnostics based on current signatures: A review [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-19.
- [6] HANG J, ZHANG J, CHENG M, et al. Online interturn fault diagnosis of permanent magnet synchronous machine using zero-sequence components[J]. IEEE Transactions on Power Electronics, 2015, 30(12): 6731-6741.
- [7] XIA K, YE Y, NI J, et al. Model predictive control method of torque ripple reduction for BLDC motor[J]. IEEE Transactions on Magnetics, 2020, 56(1): 1-6.
- [8] ZIMNICKAS T, VANAGAS J, DAMBRAUSKAS K, et al. Application of advanced vibration monitoring systems and long short-term memory networks for brushless DC motor stator fault monitoring and classification[J]. Energies, 2020, 13(4): 820.

- [9] SHIFAT T A, HUR J W. ANN assisted multi sensor information fusion for BLDC motor fault diagnosis[J]. IEEE Access, 2021, 9: 9429-9441.
- [10] 常玉燕. 基于径向基函数神经网络的无刷直流电机多机电故障处理方法[J]. 科技资讯, 2024, 22(12): 66-70,77.
CHANG Y Y. Treatment methods for the multiple electromechanical faults of brushless dc motors based on the radial basis function neural network[J]. Science & Technology Information, 2024, 22(12): 66-70,77.
- [11] 覃仕明, 马鹏. 基于CNN-A-BiLSTM的无刷直流电机故障诊断方法研究[J]. 计算机测量与控制, 2024, 32(9): 118-124,148.
QIN SH M, MA P. Research on diagnosis method of brushless DC motor based on CNN-A-BiLSTM[J]. Computer Measurement & Control, 2024, 32(9): 118-124,148.
- [12] 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. Turn-to-turn short circuit fault diagnosis of brushless DC motor based on multiple magnetic flux leakage signal arrays [J]. Transactions of China Electrotechnical Society 2025, 40(4): 1105-1116.
- [13] 武智超, 王慧, 王吉亮, 等. 基于阵列漏磁信号分析的无刷直流电机高阻接触故障诊断研究[J]. 电子测量与仪器学报, 2021, 35(11): 108-114.
WU ZH CH, WANG H, WANG J L, et al. Fault diagnosis of high resistance connection in brushless DC motor based on analysis of array leakage flux signals[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(11): 108-114.
- [14] XIAO D, HUANG Y, ZHAO L, et al. Domain adaptive motor fault diagnosis using deep transfer learning[J]. IEEE Access, 2019, 7: 80937-80949.
- [15] SHI J, WANG X, LU S, et al. An adversarial multisource data subdomain adaptation model: A promising tool for fault diagnosis of induction motor under cross-operating conditions [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-14.
- [16] LUO C, WANG J, ZIO E, et al. Subdomain adaptation order network for fault diagnosis of brushless DC motors [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-10.
- [17] WANG J, LAN C, LIU C, et al. Generalizing to unseen domains: A survey on domain generalization[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 35(8): 8052-8072.
- [18] ZHANG H, CISSE M, DAUPHIN Y N, et al. Mixup: Beyond empirical risk minimization[J]. ArXiv preprint arXiv:1710.09412,2017.
- [19] LU S, YAN R, LIU Y, et al. Tacholes speed estimation in order tracking: A review with application to rotating machine fault diagnosis [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(7): 2315-2332.
- [20] FYFE K R, MUNCK E D S. Analysis of computed order tracking [J]. Mechanical Systems and Signal Processing, 1997, 11(2): 187-205.
- [21] DONINI M, ONETO L, BEN-DAVID S, et al. Empirical risk minimization under fairness constraints[C]. Advances in Neural Information Processing Systems, 2018, 31: 1-11.
- [22] KAO I H, WANG W J, LAI Y H, et al. Analysis of permanent magnet synchronous motor fault diagnosis based on learning [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(2): 310-324.
- [23] HUANG Z, WANG H, XING E P, et al. Self-challenging improves cross-domain generalization[C]. Computer Vision-ECCV 2020: 16th European Conference, Springer International Publishing, 2020: 124-140.
- [24] SAGAWA S, KOH P W, HASHIMOTO T B, et al. Distributionally robust neural networks for group shifts: On the importance of regularization for worst-case generalization [J]. ArXiv preprint arXiv:1911.08731,2019.
- [25] SUN B, SAENKO K. Deep CORAL: Correlation alignment for deep domain adaptation[C]. Computer Vision-ECCV 2016 Workshops: Amsterdam, the Netherlands, Springer International Publishing, 2016: 443-450.
- [26] PARASCANDOLO G, NEITZ A, ORVIETO A, et al. Learning explanations that are hard to vary[J]. ArXiv preprint arXiv:2009.00329,2020.

作者简介

王凯(通信作者), 硕士, 工程师, 主要研究方向为飞机管理与飞行控制、飞机系统设计与研究。

E-mail:1969548265@qq.com