第 53 卷 第 11 期 电机与控制应用 Vol. 53 No. 11, November, 25, 2026
2026 年 11 月 25 日 Electric Machines & Control Application CCBY-NC-ND 4.0 License
DOI:10.12177/emca.2026.244 文章编号:1673-6540(2026)11-1156-10 中图分类号:TM 713 文献标志码:A

基于离散小波变换和自注意力机制的阀冷系统主泵电机匝间短路故障诊断方法

冷 超[1], 王超帆[2], 赵海森[2*]
(1.国网上海市电力公司直流分公司,上海 200336;
2.华北电力大学 电气与电子工程学院,北京 102206)

A Self-Attention-Based Fault Diagnosis Method with Discrete Wavelet Transform for Inter-Turn Short Circuit Faults in Valve Cooling System Main Pump Motors

Leng Chao[1], Wang Chaofan[2], Zhao Haisen[2*]
(1. Direct Current Branch, State Grid Shanghai Municipal Electric Power Company, Shanghai 200336, China;
2. School of Electrical and Electronic Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: **[Objective]** The main pump motor of the valve cooling system generally adopts a squirrel-cage asynchronous motor, which is prone to inter-turn short circuit faults during long-term operation. Traditional time-frequency analysis methods struggle to effectively extract and distinguish feature information corresponding to different severity levels of inter-turn short-circuit faults. **[Methods]** To address this issue, this paper proposed a fault diagnosis method that integrated the discrete wavelet transform (DWT) with the self-attention mechanism. Firstly, inter-phase differentiation was applied to stator three-phase current signals. The channel number was expanded to 6 to incorporate inter-phase unbalance characteristics. Then, the DWT was employed to perform multi-scale frequency-band decomposition on the signals, and linear interpolation was adopted to unify all sub-bands into equal-length Token sequences. Finally, the Token sequences were fed into a Transformer encoder, in which global feature interaction was realized through the multi-head self-attention mechanism, and the classification Token was fused with global average pooling to complete the classification task. Compared with traditional time-frequency analysis methods, the proposed method directly took the 1D frequency bands as input, thereby avoiding the information compression and distortion incurred during 2D image transformation. During the model training and evaluation stages, a 5-fold cross-validation was adopted to eliminate the randomness caused by a single data split and rigorously validate the generalization capability of the proposed method. **[Results]** To verify the effectiveness of the proposed DWT-Transformer model, it was compared with two models that combine the continuous wavelet transform (CWT) with the vision Transformer (ViT). The experimental results showed that under 5-fold cross-validation, the average test accuracy of the proposed DWT-Transformer model reached 97.57%, which was superior to the two CWT-ViT models. **[Conclusion]** The combination of DWT multi-scale frequency band decomposition and self-attention mechanism has certain feasibility and effectiveness in the fault diagnosis of motor inter-turn short circuit.

Key words: valve cooling system; discrete wavelet transform; Transformer; fault diagnosis

摘 要:**【目的】**阀冷系统主泵电机通常采用鼠笼式异步电机,其在长期运行中易发生匝间短路故障。传统时频分析法难以有效提取并区分表征匝间短路故障严重程度的特征信息。**【方法】**针对上述问题,本文提出一种结合离散小波变换(DWT)与自注意力机制的故障诊断方法。首先,将定子三相电流信号进行相间差分,将通道数扩充至6,以引入相间不平衡特征;然后,通过 DWT 对信号进行多尺度频带分解,并采用线性插值法将所有子频带统

基金项目:国网上海市电力公司科技项目(SGSHTGOOYW2500215)
State Grid Shanghai Municipal Electric Power Company Technology Project (SGSHTGOOYW2500215)

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

一为等长 Token 序列;最后,将 Token 序列输入 Transformer 编码器,通过多头自注意力机制实现全局特征交互,并将分类标记与全局平均池化结合以完成分类任务。与传统时频分析法相比,本文方法直接以一维频带为输入,避免了图像化过程中的信息压缩与失真。在模型训练与评估阶段,采用五折交叉验证以消除单次随机划分的偶然性,严格验证模型的泛化能力。【结果】为验证所提 DWT-Transformer 模型的有效性,将其与两种连续小波变换(CWT)与可视化 Transformer(ViT)模型进行对比。试验结果表明,在五折交叉验证下,所提 DWT-Transformer 模型的平均测试准确率达 97.57%,优于两种 CWT-ViT 模型。【结论】DWT 多尺度频带分解结合自注意力机制在电机匝间短路故障诊断中具有一定的可行性和有效性。

关键词:阀冷系统;离散小波变换;Transformer;故障诊断

0 引言

高压直流输电系统中,换流阀具有重要作用。在运行过程中,换流阀的关键部件晶闸管会产生大量热量,因此必须配备冷却系统[1]。主循环泵是冷却系统的核心部件,其运行状态决定了冷却系统的可靠性。如果主循环泵的驱动电机发生匝间短路故障,将导致冷却系统停运,使换流阀过热损坏,造成严重的经济损失。因此,针对主泵电机开展匝间短路故障诊断研究,对保障直流输电系统的安全稳定运行具有重要意义。

在电机故障诊断领域,随着人工智能技术的快速发展和广泛应用,小波变换等信号处理方法与深度学习的融合模型快速发展。针对缺相故障,文献[2]通过改进经验小波变换抑制模态混叠,并采用 CatBoost 算法进行故障分类,试验结果表明该方法的泛化能力更强。针对永磁同步电机高阻连接状态感知问题,文献[3]提出一种基于小波变换与前向反馈神经网络的方法,该方法可以在高阻故障发生前发出预警信号。针对传统诊断依赖人工经验的问题,文献[4]通过短时傅里叶变换和小波变换将一维信号变成二维时频图,并利用卷积神经网络(Convolutional Neural Network, CNN)进行分类。为了缓解计算注意力时的平滑效应,文献[5]在 Swin Transformer 网络加入局部敏感哈希注意力机制,并用 Gumbel Softmax 进行离散采样。文献[6]提出一种基于多源信息融合的新型分层视觉 Transformer 与小波时频的方法,试验结果表明,在机械部件多源数据集上,所提方法的性能优于现有方法。文献[7]提出一种基于反向传播神经网络和小波包能量分析的异步电动机故障诊断系统。文献[8]采用离散小波变换(Discrete Wavelet Transform, DWT)提取故障相电流的平均值与标准差的比值作为故障特征量,并通过仿真和试验验证了该方法的可行性。文献[9]提出一种基于峭度、小波降噪和共振解调法相结合的异步电机故障诊断方法,对原始信号进行峭度分析,并采用小波降噪和共振解调法提取信号频域特征量。针对转子断条故障,文献[10]提出一种 DWT 结合 CNN 的方法,通过 DWT 系数进行频谱分析来获取频域图像,然后通过 CNN 进行分类。文献[11]提出一种融合 DWT、空洞 CNN 以及模型无关元学习的模型,试验结果表明,该模型在仿真数据及实际相量测量单元数据上均展现出卓越的性能。上述文献在利用小波变换进行故障特征提取时,普遍将二维时频图像输入深度学习模型,这种图像化处理不可避免地造成信息压缩与插值失真,且增加了计算量。

Transformer 模型由 Vaswani 等人于 2017 年提出,最初用于自然语言领域[12]。与传统循环神经网络依赖时序递归不同,Transformer 基于注意力机制学习序列间的全局依赖关系[13-15],具有较强的并行计算能力,可以更好地提取故障特征。文献[16]提出一种基于 CNN 与 Transformer 多尺度分布对齐网络模型,试验结果表明,相对于常见算法该算法准确率更高。文献[17]提出一种基于多传感器信号的 CNN-Transformer 深度神经网络模型,通过卷积模块和 Transformer 模块,对多传感器信号的特征进行提取和融合,从而实现故障判别。针对不同负载下故障数据特征不同的问题,文献[18]通过一维 CNN 和 Transformer 层提高了特征提取能力,并将故障数据送入域对抗神经网络中进行分类。文献[19]提出一种多维度 Transformer 与电磁暂态建模融合的故障诊断方法,通过 PSCAD 平台进行多工况仿真,然后用多维度 Transformer 编码器进行故障分类。文献[20]提出一种基于 CNN-Transformer-双向长短期

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

记忆网络的故障诊断方法,试验结果表明该方法在噪声干扰的情况下仍有较高的诊断准确率。文献[21-22]针对高噪声工况设计了可视化 Transformer 网络,通过注意力机制捕捉全局信息。文献[23]结合改进时频 Transformer 和自注意力机制,实现滚动轴承故障诊断。上述文献在将 Transformer 应用于电机故障诊断时,均以二维时频图像作为输入,使得 Transformer 的自注意力机制无法在频带层面直接识别不同频率之间的关系。

传统时频分析方法诊断阀冷系统主泵电机匝间短路故障时,对非平稳信号的时频特征提取不充分、难以有效区分表征匝间短路故障严重程度的特征信息。针对此问题,本文提出一种基于 DWT 和自注意力机制的电机故障诊断方法。首先,对定子三相电流信号进行相间差分,将通道数扩充到 6,以引入相间不平衡特征;然后,采用 DWT 对信号进行多尺度频带分解,并通过线性插值将各频带统一为等长的 Token 序列;最后,将 Token 序列输入 Transformer 编码器,利用多头自注意力机制实现跨频带的全局特征交互,并采用分类标记(Classification Token,CLS Token)与全局平均池化(Global Average Pooling,GAP)进行分类。与传统连续小波变换(Continuous Wavelet Transform,CWT)生成二维时频图的方式相比,本文直接以一维频带作为输入,避免了图像化过程中的信息失真。为验证所提方法的有效性,设计了两组基于 CWT 与可视化 Transformer(Vision Transformer,ViT)的对比试验。在模型训练与评估阶段,为彻底消除单次数据随机划分带来的偶然性偏差,本文采用五折交叉验证,使所有试验样本均轮流作为独立测试集。试验结果验证了 DWT 结合自注意力机制在电机匝间短路故障诊断中的可行性和有效性。

1　基于 DWT 和自注意力机制的匝间短路故障诊断方法

DWT 是一种信号分析工具,其基本思想是利用滤波器将信号逐层分解到不同频率尺度上[24-25]。DWT 将 CWT 中的尺度因子与平移因子离散化,通过一组由低通滤波器 $h(n)$ 和高通滤波器 $g(n)$ 构成的滤波器组对信号进行多层分解。对于离散信号 $x(n)$,单层 DWT 分解可表示为

$$cA_j(k) = \sum_n x(n) \cdot h(n - 2k) \tag{1}$$

$$cD_j(k) = \sum_n x(n) \cdot g(n - 2k) \tag{2}$$

式中:$cA_j(k)$、$cD_j(k)$ 分别为第 j 层的低频分量、高频分量,k 为平移步长。

每层分解后通过下采样将数据长度减半,低频分量可继续分解。经 J 层分解后,原始信号被分解为 1 个最低频分量 cA_J 和 J 个高频分量 $\{cD_1, cD_2, \cdots, cD_J\}$,共 J+1 个频带子带。

目前 Transformer 模型主要有三类,分别为仅编码器结构、仅解码器结构和编码器—解码器结构[26-28]。本文采用仅编码器结构,编码器由多个编码器层堆叠而成,每个编码器层由自注意力层和前馈层构成。编码器结构如图 1 所示。

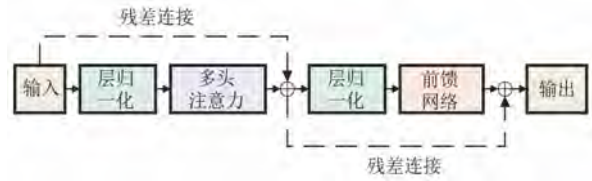


图 1　编码器结构

Fig. 1　Encoder architecture

匝间短路会破坏定子绕组的对称性,导致三相电流不平衡,使用原始三相电流信号很难识别不平衡信息[29-30]。针对此问题,本文通过计算三相定子电流信号间的差值,将差分信号和原始信号拼接,从而将输入通道数扩充到 6,以便模型更易学到故障特征。

现有方法大多用 CWT 将一维信号变成二维时频图像,再输入模型进行分类,但图像化过程会导致信息失真。本文通过 DWT 把信号分解成一维频带序列,对扩充后的 6 通道信号分别做 6 层 db4 DWT,每个通道得到 7 个频带,6 个通道一共 42 个频带。由于各层频带的长度不一样,本文采用线性插值将所有频带统一到固定长度。

标准 Transformer 所采用的位置编码仅能建模 Token 在序列中的相对或绝对位置顺序,而无法区分 Token 所属的通道或其对应的频段特征。针对此问题,本文采用通道嵌入和频段嵌入。通道嵌入用来标记每个 Token 所属的电流通道,频段嵌入用来标记每个 Token 所属的频率层级。

标准的 Transformer 采用 CLS Token 的输出作

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

为全局特征。本文采用 CLS Token 和 GAP 拼接融合作为全局输出。CLS Token 通过自注意力机制关注局部特征，并对所有频带 Token 的输出进行 GAP，将这两路特征拼接起来，经过层归一化和 Dropout 后送入线性层。DWT+Transformer 模型架构如图 2 所示，其整体数学模型为

$$\boldsymbol{y}=f_{\mathrm{s}}[\boldsymbol{W}_{\mathrm{c}}\boldsymbol{f}_{\mathrm{LN}}(Concat[\boldsymbol{f}_{\mathrm{t}}\{\boldsymbol{f}_{\mathrm{l}}[\boldsymbol{f}_{D}(\boldsymbol{x})]\}_{\mathrm{cls}},GAP\{\boldsymbol{f}_{\mathrm{t}}\{\boldsymbol{f}_{\mathrm{l}}[\boldsymbol{f}_{D}(\boldsymbol{x})]\}\}])+\boldsymbol{b}] \tag{3}$$

式中：$\boldsymbol{y}$ 为输出；$\boldsymbol{x}$ 为输入信号；$\boldsymbol{f}_{D}$ 为 DWT；$\boldsymbol{f}_{\mathrm{l}}$ 为线性投影；$\boldsymbol{f}_{\mathrm{t}}$ 为 Transformer 编码；$\boldsymbol{W}_{\mathrm{c}}$ 为分类头权重矩阵；$\boldsymbol{f}_{\mathrm{LN}}$ 为层归一化；$\boldsymbol{b}$ 为偏置；下标 cls 为 CLS Token 输出；*Concat* 为拼接操作；f_{s} 为 Softmax 激活函数。

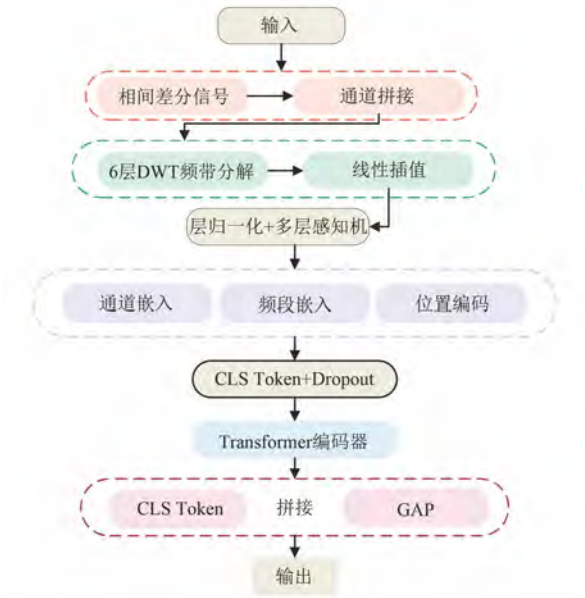


图 2 DWT+Transformer 模型架构

Fig. 2 DWT+Transformer model architecture

2 故障诊断流程

本文所提基于 DWT 与自注意力机制的异步电机匝间短路故障诊断方法整体流程如图 3 所示，具体步骤如下。

(1)利用电流传感器采集异步电机的三相定子电流信号，计算相间差分信号并与原始信号拼接；

(2)对增强后的 6 通道信号分别进行多层 DWT，通过线性插值将各个频带统一为等长 Token 序列，构建频带 Token 矩阵；

(3)为每个 Token 加上位置编码，附加 CLS Token 后输入 Transformer 编码器进行多层自注意力特征提取；

(4)将 Transformer 输出的 CLS Token 特征与 GAP 特征拼接融合，经分类头输出故障诊断结果；

(5)将训练样本输入模型进行训练，采用 AdamW 优化器与余弦退火学习率调度策略，通过 Dropout 和随机深度正则化防止过拟合；

(6)将测试样本输入训练完成的模型，进行模型测试与综合评估；

(7)输出最终诊断结果。

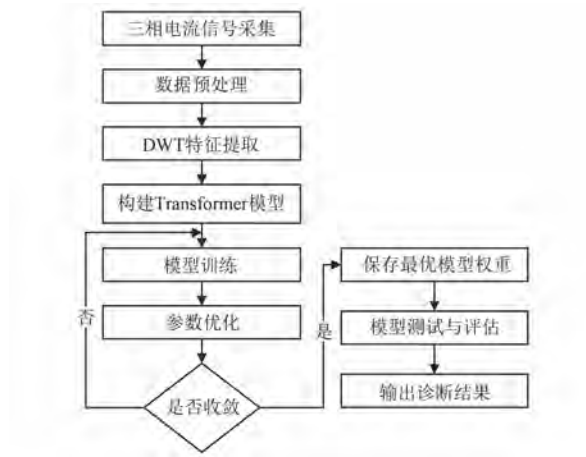


图 3 基于 DWT-Transformer 的异步电机故障诊断流程

Fig. 3 Flowchart of the DWT-Transformer-based asynchronous motor fault diagnosis

3 实例验证

3.1 数据预处理

为验证所提故障诊断模型的性能，搭建如图 4 所示的电机匝间短路故障试验平台。需要指出的是，阀冷系统主泵电机通常采用鼠笼式异步电机作为驱动设备，其主要作用是保证冷却介质持续循环，为换流阀提供稳定散热条件。由于匝间短路故障产生的电磁不平衡特征主要由绕组结构和故障程度决定，与电机容量等级无直接关系，因此该试验平台能够有效验证所提方法对该类故障特征提取和诊断的有效性。为模拟定子绕组匝间短路故障，本文试制一台 380 V/5.5 kW 的鼠笼式异步电机作为测试对象，在 C 相绕组靠近进线端的第一组线圈上实施匝间短路故障模拟，通过外接可调电阻连接相应端子构建所需故障工况。试验设置了三种负载工况(空载、1 kW 和 2 kW)和

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

两种电压不平衡条件(0、0.02),在上述工况组合下,采集正常运行、两匝短路、四匝短路和六匝短路的三相电流信号,每次采样持续 5 s,采样频率为 34 kHz。由于连续采集信号需要进一步转换为适用于深度学习模型训练的固定长度样本,采用滑窗方式对原始电流序列进行分割。滑窗处理并非用于弥补采样时间不足,而是用于提高时间序列数据的利用率,使不同时间位置包含的故障特征能够参与模型训练。经滑窗处理后,每种工况截取 50 个样本数据,单个样本的长度为 3 413 个数据点,最终获得包含 1 200 个样本的数据集。图 5 为 2 kW 负载且电压不平衡为 0 时的原始 A 相电流信号时域图。

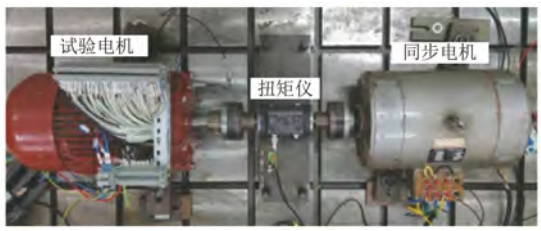


图 4　试验平台

Fig. 4　Experimental platform

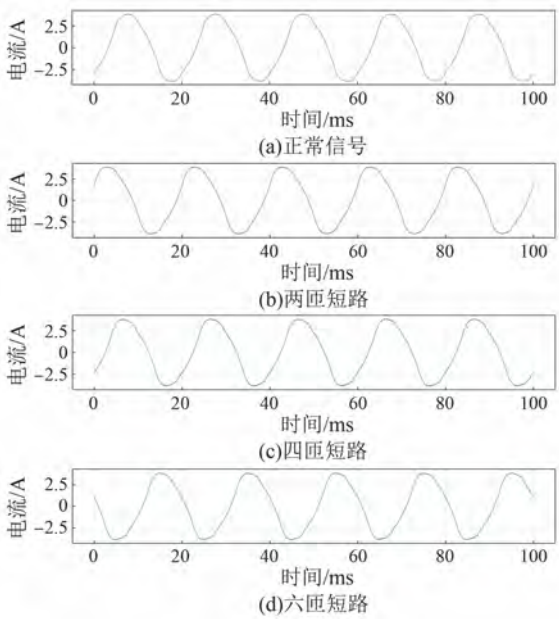


图 5　原始 A 相电流信号时域图

Fig. 5　Time-domain diagram of the original phase A current signal

由图 5 可知,不同程度匝间短路故障下定子 A 相电流整体波形与正常状态下电流波形较为接近,尤其是在故障初期,电流幅值变化并不明显。这是由于匝间短路导致绕组局部磁场不对称,引起负序电流和局部谐波分量增加,而基波电流幅值变化较小。因此,仅依靠传统时域波形难以有效区分不同短路匝数状态,因此有必要开展深层特征提取和智能诊断方法的研究。

为评估所提模型的故障判别能力,本文采用五折交叉验证进行试验。具体而言,以处理后的单个样本为基本划分单位,按照各类别样本的标签分布,将全部样本随机划分为五个互斥子集。每次试验,选取其中四个子集作为训练集,剩余一个子集作为测试集,依次轮换五次,使每个子集均有一次作为测试集。为保证试验过程的一致性,采用固定随机种子进行样本划分。最终,以五次试验所得评价指标的平均值作为模型性能的主要评价依据。

在数据预处理阶段,针对 DWT-Transformer 模型,为增强三相电流之间的不平衡特征表达能力,在原始三相电流信号的基础上构造三组相间差分信号。设三相电流为 i_a、i_b、i_c,分别计算 i_a-i_b、i_b-i_c 和 i_c-i_a,并与原始三相电流共同组成 6 通道输入信号,增强故障的可辨识性。然后,采用 DWT 进行频带分解,选用 db4 小波基,分别对原始信号和差分信号进行 6 层 DWT 分解,每个通道产生 1 个低频分量和 6 个高频分量,共 7 个频带。图 6 为 2 kW 负载且电压不平衡为 0 时 A 相电流的 7 个频带图。

图 6 中不同尺度对应不同频率分量。正常状态下,各频带能量分布较稳定;发生匝间短路后,由于绕组不对称导致电流谐波增加,部分高频细节分量能量明显提高。随着短路匝数增加,故障严重程度增强,使得细节层系数幅值进一步增大。因此,DWT 能够有效提取传统时域波形中难以观察的故障特征。由于低频和高频的频带长度不同,因此采用线性插值将每个频带调整至固定长度 384,最终形成 42×384 的二维 Token 矩阵,作为 Transformer 编码器的输入。

3.2　试验结果分析

在模型训练过程中,批量大小设置为 32,训练周期设置为 100。在优化算法选择方面,采用 AdamW 优化器,该算法在 Adam 的基础上加上解耦权重衰减,可以有效控制正则化强度,防止过拟合。学习率设置为 5×10^{-4},并使用余弦退火学习

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

率调度策略，使学习率在训练过程中从初始值平滑衰减至最小值。针对多分类任务的特点，选择交叉熵损失函数作为优化目标，并引入标签平滑系数以增强模型的泛化能力。

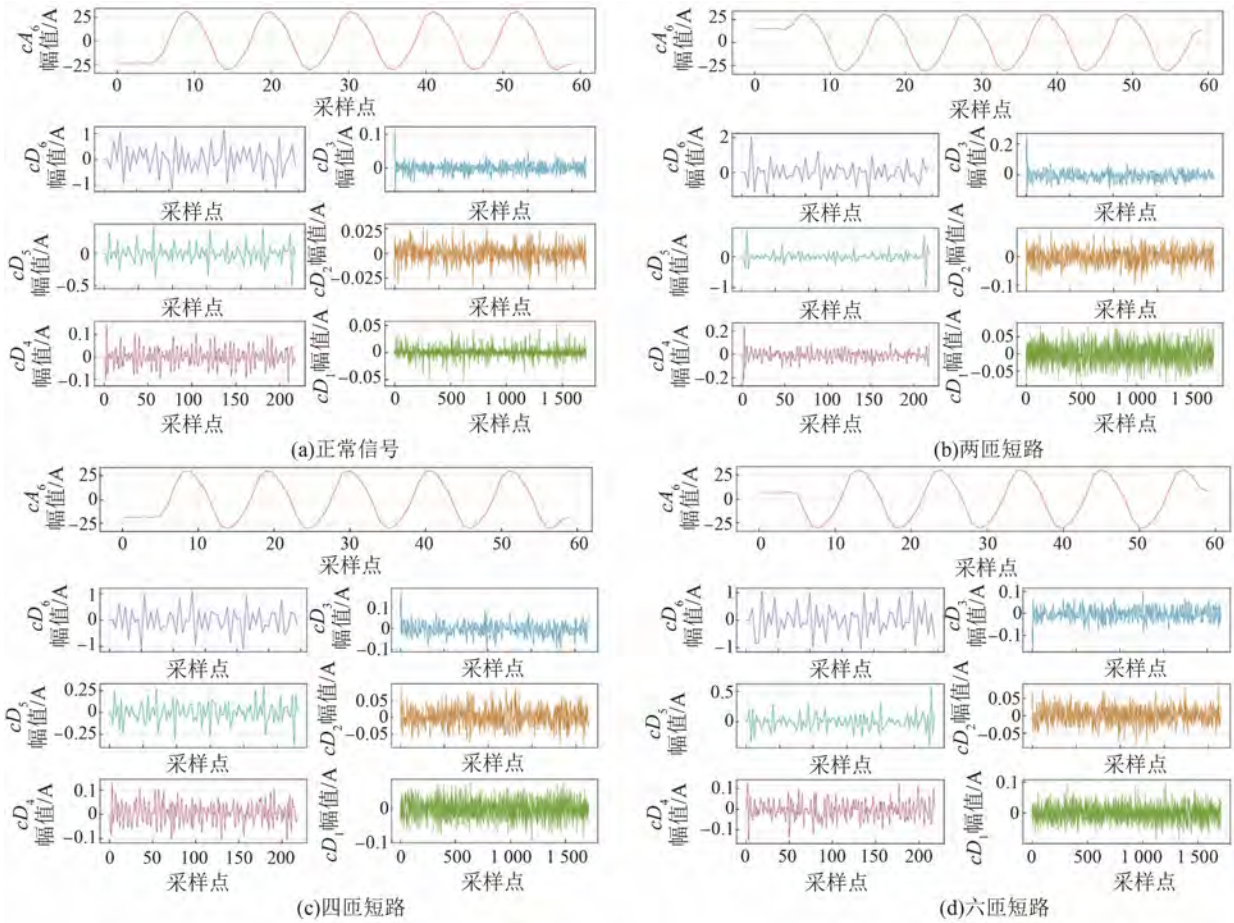


图 6　经 DWT 分解后的 A 相电流频带图

Fig. 6　Frequency band diagram of phase A current after DWT decomposition

采用经过预处理后的数据对模型进行五折交叉验证训练，并与 CWT-ViT（正方形 patch）和 CWT-ViT（长方形 patch）模型对比。以最后一折（Fold-5）为例，各模型在训练集和测试集上的准确率及损失变化曲线如图 7 和 8 所示。

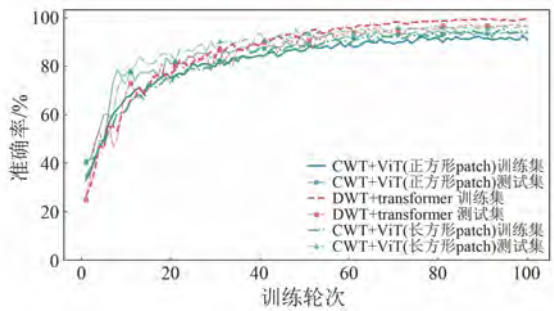


图 7　训练集与测试集准确率曲线

Fig. 7　Accuracy curves of training set and test set

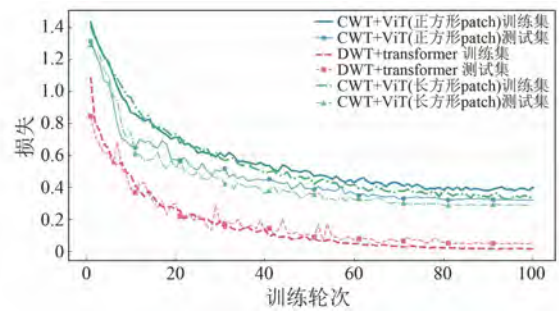


图 8　训练集与测试集损失曲线

Fig. 8　Loss curves of training set and test set

由图 7 和 8 可知，在五折交叉验证下，CWT-ViT（正方形 patch）、CWT-ViT（长方形 patch）和本文所提 DWT+Transformer 模型在五次独立测试集上的平均准确率分别为 96.21%、96.86% 和 97.57%，本文模型准确率最高。从准确率曲线可

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

知,DWT+Transformer 模型的收敛速度更快,泛化能力更强。虽然 DWT+Transformer 模型有轻微的过拟合现象,但其高准确率和低损失验证了该模型在本任务上的分类能力优于 CWT 时频图方案。

为分析各模型的特征提取能力,采用 t 分布随机邻域嵌入(t-distributed Stochastic Neighbor Embedding,t-SNE)算法对测试集样本进行降维可视化,结果如图 9 所示。

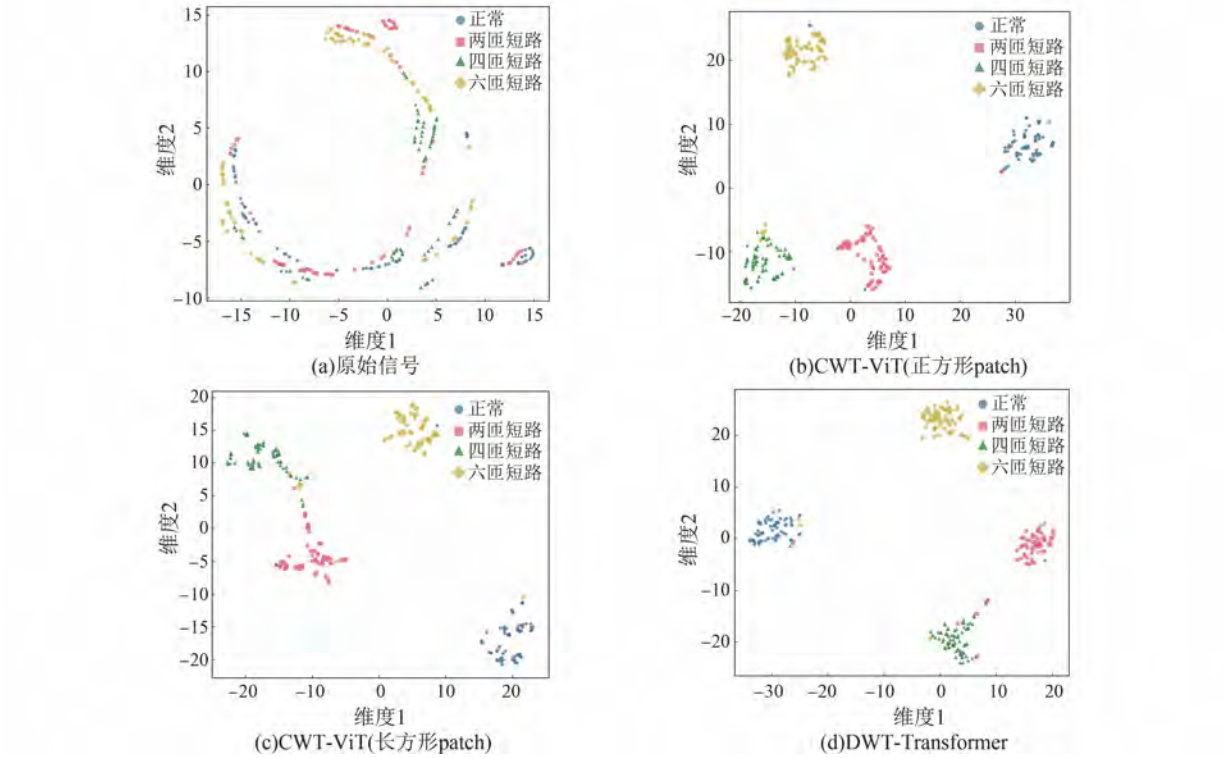


图 9　三种模型 t-SNE 可视化结果

Fig. 9　t-SNE visualization results of three models

从原始信号的 t-SNE 可视化结果可以看出,四类样本在二维投影中呈现严重的类别混叠现象。经 DWT+Transformer 模型处理后,四类样本呈现出清晰的类别边界,四类样本在特征空间中形成四个独立簇,几乎没有交叉现象。经另外两种 CWT-ViT 模型处理后,四类样本虽然在特征空间中形成四个独立簇,但没有清晰的类别边界,聚类边缘存在少量样本混叠。

综上所述,DWT+Transformer 模型在收敛速度、分类准确率和特征判别性方面均优于两种 CWT 时频图方案,验证了 DWT 多尺度频带分解结合全局注意力机制在电机匝间短路故障诊断中的有效性和优越性。

4　结语

针对阀冷系统主泵电机匝间短路故障时频特征微弱、耦合严重的问题,本文提出一种基于 DWT 与 Transformer 的故障诊断方法,主要结论如下。

(1)相间差分增强能够有效放大匝间短路故障的微弱特征。对比试验中,将三相电流差分信号与原始信号拼接后,模型对匝间短路故障严重程度的区分能力明显提升,说明相间不平衡信息是识别匝间短路故障的关键特征。

(2)Transformer 的多头自注意力机制可以对多频带信号进行全局特征交互。t-SNE 可视化结果显示,自注意力机制能够有效捕获不同频带之间的关系,提升故障特征的判别性。

(3)DWT+Transformer 模型的平均测试准确率为 97.57%,优于另外两种 CWT 时频图输入方案,验证了 DWT-Transformer 模型在电机匝间短路故障诊断中的可行性和有效性。

利益冲突声明

所有作者声明不存在利益冲突。

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

All authors disclose no relevant conflict of interests.

作者贡献

冷超进行了方案设计，王超帆进行了试验研究与论文撰写，赵海森进行了论文的审核与修改。所有作者均阅读并同意了最终稿件的提交。

Leng Chao carried out the scheme design. Wang Chaofan carried out the experimental research and paper writing. Zhao Haisen performed the review and revision of the paper. All authors have read the last version of the paper and consented for submission.

参 考 文 献

[1] 耿要强，姚睿，付兵非，等. 阀冷主泵状态监测与故障诊断技术研究[J]. 自动化仪表，2024，45(6)：99-103+110.
Geng Y Q，Yao R，Fu B F，et al. Study of condition monitoring and fault diagnosis technology of valve cooled main pump [J]. Process Automation Instrumentation，2024，45(6)：99-103+110.

[2] 钱轶群，张孜乐，杨依林，等. 基于改进经验小波变换的永磁同步电机故障诊断策略[J]. 电机与控制应用，2025，52(1)：12-21.
Qian Y Q，Zhang Z L，Yang Y L，et al. Fault diagnosis strategy for permanent magnet synchronous motors based on improved empirical wavelet transform [J]. Electric Machines & Control Application，2025，52(1)：12-21.

[3] 陈少霞，高卓，姚钢，等. 基于小波神经网络的六相永磁同步电机高阻连接状态感知策略[J]. 电机与控制应用，2024，51(6)：1-11.
Chen S X，Gao Z，Yao G，et al. Sensing strategy for high resistance connection state of six-phase PMSM based on wavelet neural network [J]. Electric Machines & Control Application，2024，51(6)：1-11.

[4] Ventricci L，Ribeiro Junior R F，Gomes G F. Motor fault classification using hybrid short-time Fourier transform and wavelet transform with vibration signal and convolutional neural network [J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering，2024，46(6)：337.

[5] Zeng F，Ren X T，Wu Q. A fault diagnosis method for motor vibration signals incorporating Swin transformer with locally sensitive hash attention [J]. Measurement Science and Technology，2024，35(4)：046121.

[6] Gong C F，Peng R R. A novel hierarchical vision transformer and wavelet time-frequency based on multi-source information fusion for Intelligent fault diagnosis [J]. Sensors，2024，24(6)：1799.

[7] 郭昱君，王爱元，姚晓东. 基于 BP 神经网络和小波包能量熵的异步电动机故障诊断[J]. 电机与控制应用，2022，49(10)：53-59.
Guo Y J，Wang A Y，Yao X D. Fault diagnosis of asynchronous motor based on BP neural network and wavelet packet energy analysis [J]. Electric Machines & Control Application，2022，49(10)：53-59.

[8] 唐琛，杨剑，任兴，等. 基于小波变换的开关磁阻电机系统功率变换器故障诊断[J]. 电机与控制应用，2018，45(9)：125-131.
Tang C，Yang J，Ren X，et al. Fault diagnosis of power converter for switched reluctance motor system based on wavelet transform [J]. Electric Machines & Control Application，2018，45(9)：125-131.

[9] 丁小健，周健，梁超，等. 基于小波降噪和共振解调法的异步电机故障诊断方法[J]. 电机与控制应用，2020，47(9)：106-110.
Ding X J，Zhou J，Liang C，et al. A fault diagnosis method of asynchronous motor based on wavelet de-noising and resonance demodulation analysis [J]. Electric Machines & Control Application，2020，47(9)：106-110.

[10] Chauhan P，Dewangan K，Kumar R，et al. Enhanced diagnosis of broken rotor bar faults using discrete wavelet transform and convolutional neural network [J]. Engineering Applications of Artificial Intelligence，2026，167：113784.

[11] Yang X，Huang X，Li J，et al. Forced oscillation detection via a discrete wavelet Transform-dilated convolutional neural network with MAML [J]. Electric Power Systems Research，2026，251：112336.

[12] Vaswani A，Shazeer N，Parmar N，et al. Attention is all you need [C]//31st Conference on Neural Information Processing Systems，Long Beach，CA，USA，2017：1-15.

[13] 许伯强，王彪，孙丽玲，等. 基于改进集合经验模

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

态分解和强化视觉 Transformer 模型的风电机组故障预警[J]. 电工技术学报, 2025, 40(20): 6537-6551.
Xu B Q, Wang B, Sun L L, et al. Fault warning of wind turbine based on improved ensemble empirical mode decomposition and enhanced visual transformer model [J]. Transactions of China Electrotechnical Society, 2025, 40(20): 6537-6551.

[14] 昌千琳, 罗永捷, 王强钢, 等. 基于Ⅰ-Ⅴ曲线全局特征提取的光伏组串 Swin-Transformer 故障诊断方法[J]. 电工技术学报, 2025, 40(23): 7664-7676.
Chang Q L, Luo Y J, Wang Q G, et al. Fault diagnosis method for photovoltaic string based on global I-V curve feature extraction using Swin Transformer [J]. Transactions of China Electrotechnical Society, 2025, 40(23): 7664-7676.

[15] 唐玉涛, 束洪春, 刘皓铭, 等. 基于 CABFAM-Transformer 的输电线路在线测距实测行波预分类方法[J]. 电工技术学报, 2025, 40(5): 1455-1470.
Tang Y T, Shu H C, Liu H M, et al. Pre-Identification method of measured traveling wave data for online fault location of transmission line based on CABFAM-Transformer [J]. Transactions of China Electrotechnical Society, 2025, 40(5): 1455-1470.

[16] Zhu Q X, Qian Y S, Zhang N, et al. Multi-scale transformer-CNN domain adaptation network for complex processes fault diagnosis [J]. Journal of Process Control, 2023, 130: 103069.

[17] Yu M J, Han H H, Lu S L. Fault diagnosis of switched reluctance motor based on deep feature fusion of multisensor signals [C]//2024 36th Chinese Control and Decision Conference, Xi'an, China, 2024: 3265-3269.

[18] 王嘉铭, 蔡浩原, 柳雅倩, 等. 变负载条件下电机故障的 Transformer-DANN 诊断方法研究[J]. 控制与决策, 2025, 40(10): 3096-3105.
Wang J M, Cai H Y, Liu Y Q, et al. Research on motor faults under variable load conditions based on Transformer-DANN model [J]. Control and Decision, 2025, 40(10): 3096-3105.

[19] 许建中, 田昭璇, 祝怡阳, 等. 多维度 Transformer 算法与电磁暂态建模融合驱动的 PMSG 故障辨识方法[J]. 中国电机工程学报, 2026, 46(16): 6062-6073.
Xu J Z, Tian Z X, Zhu Y Y, et al. The fault identification method for PMSG driven by the integration of multi-dimensional transformer algorithm and electromagnetic transient modeling [J]. Proceedings of the CSEE, 2026, 46(16): 6062-6073.

[20] 李龙飞, 刘雨, 张巧芬, 等. 基于 CNN-Transformer-BiLSTM 模型的异步电机故障诊断方法研究[J]. 制造业自动化, 2025, 47(9): 101-107.
Li L F, Liu Y, Zhang Q F, et al. Research on asynchronous motor fault diagnosis method based on CNN-Transformer-BiLSTM model [J]. Manufacturing Automation, 2025, 47(9): 101-107.

[21] Wang J Y, Zhao Y, Wang W Y, et al. Improving bearing fault diagnosis method based on the fusion of time-frequency diagram and a novel vision transformer [J]. The Journal of Supercomputing, 2024, 81(1): 262.

[22] 杨瑞, 刘云鹏, 张耀中, 等. 基于时频双维增强和 Transformer 网络的饱和电抗器紧固件松动声纹辨识方法[J]. 中国电机工程学报, 2026, 46(21): 8306-8317.
Yang R, Liu Y P, Zhang Y Z, et al. Saturation reactor fastener loosening identification using time-frequency dual-domain enhancement and Transformer network [J]. Proceedings of the CSEE, 2026, 46(21): 8306-8317.

[23] Hou Y D, Wang J J, Chen Z Q, et al. Diagnosisformer: An efficient rolling bearing fault diagnosis method based on improved Transformer [J]. Engineering Applications of Artificial Intelligence, 2023, 124: 106507.

[24] Zhou Y, Shang Q M, Guan C. Three-phase asynchronous motor fault diagnosis using attention mechanism and hybrid CNN-MLP by multi-sensor information [J]. IEEE Access, 2023, 11: 98402-98414.

[25] Xiong R B, Yang Y C, He D, et al. Supplementary material: On layer normalization in the transformer architecture [C]// Proceedings of the 37th International Conference on Machine Learning, Online, 2020: 10524-10533.

[26] Zhou K Y, Lu N Y, Jiang B, et al. FEV-Swin: Multisource heterogeneous information fusion under a variant swin transformer framework for intelligent

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

cross-domain fault diagnosis [J]. Knowledge-Based Systems，2025，310：112982.

[27] Wu Z H，Zhang H，Wang P H，et al. RTIDS：A robust transformer-based approach for intrusion detection system [J]. IEEE Access，2022，10：64375-64387.

[28] Chen D Q，Hong W C，Zhou X Z. Transformer network for remaining useful life prediction of lithium-ion batteries [J]. IEEE Access，2022，10：19621-19628.

[29] Chen R X，Lin S J. Digital-twin-driven PMSM inter-turn short-circuit fault diagnosis method [J]. Energies，2026，19(5)：1152.

[30] Huang Y J，Huang W T，Ru K Y，et al. Parameter-free model predictive control of five-phase PMSM under healthy and inter-turn short-circuit fault conditions [J]. Energies，2025，18(17)：4549.

收稿日期：2026-05-19
收到修改稿日期：2026-08-31

作者简介：

冷 超(1978—)，女，硕士，高级工程师，研究方向为电力电子、直流输电技术，eleanorleng@163.com；

*通信作者：赵海森(1982—)，男，博士，教授，研究方向为电能转换与高效利用、新能源电力系统分析与控制，zhaohisen@163.com。

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