

基于 MTF-Swin Transformer 的风机齿轮箱故障诊断

张彬桥^{1,2}, 雷钧^{1,2}, 万刚³

(1.三峡大学 电气与新能源学院, 湖北 宜昌 443002; 2.梯级水电站运行与控制湖北省重点实验室, 湖北宜昌 443002; 3.中国长江电力股份有限公司, 湖北 宜昌 443002)

摘要: 针对风机齿轮箱实际工况复杂多变及含有强噪声, 传统故障诊断方法对风机齿轮箱故障诊断识别准确率较低的问题, 文章提出了 MTF-Swin Transformer 风机齿轮箱故障诊断模型。首先, 采用马尔科夫变迁场 (MTF) 图形编码方法将原始一维振动时序信号转化为具有关联时间信息的二维特征图谱; 然后, 将特征图谱作为 Swin Transformer 模型的输入, 基于自注意力机制进行自动特征提取; 最后, 实现对不同故障类型的分类。仿真结果表明, 该方法对齿轮箱故障诊断准确率达到 99.48%, 证明了该方法的有效性和优越性。

关键词: 马尔科夫变迁场 (MTF); Swin Transformer; 风机齿轮箱; 故障诊断

中图分类号: TK83 **文献标志码:** A **文章编号:** 1671-5292(2024)05-0627-07

0 引言

近年来, 风力发电技术在全球范围得到广泛应用, 但风力发电机可靠性与安全性不足带来的维修管理费用增大已经成为了制约风电发展的重大问题^[1]。齿轮箱是风机传动系统中的重要部件, 其结构复杂、故障率高, 维修难度大、时间长, 一直是风机故障检测与运行维护的重点^[2], 因此对风机齿轮箱进行故障诊断是十分必要的。

传统故障诊断方法通常采用人工提取故障特征信息, 通过对处理后的故障信息进行模式识别确定故障类别。研究人员通过时域、频域以及时频域结合的方法对原始信号进行处理, 完成对故障信号的特征建立和故障识别。于元杰^[3]通过峭度指标与经验模态分解 (EMD) 方法实现了干扰情况下对故障信号的有效提取。吴秋梅^[4]采用变分模态分解 (VMD) 法一定程度上消除了噪声干扰, 可充分提取振动信号的特征信息。宋玉琴^[5]利用频率分离与功率谱实现信号分解, 将总功率输入优化支持向量机, 实现了故障诊断并取得了较好的效果。在风机齿轮箱振动信号的提取过程中, 傅成豪^[6]通过改进小波去噪方法中所使用的阈值函数实现了良好的去噪效果, 有利于后期的故障诊断和分类工作。在振动信号分析与故障诊断的处理过程中, 上述方法依赖经验, 主观性强, 同时微

弱振动特征信息易被忽略。

随着计算机技术的发展, 基于数据驱动的模式开发以及对振动信号的大数据挖掘方法在故障诊断领域被广泛应用。在早期机器学习领域中, 通过对信号的特征提取与机器学习算法相结合可以有效提高故障诊断的精度, 如人工神经网络^[7]、支持向量机^[8]、随机森林^[9]、XGBoost 算法^[10]、朴素贝叶斯^[11]以及极限学习机^[12]等。随着机器学习逐步向深度学习发展, 李东东^[13]利用卷积神经网络分别构成对抗网络的生成器和判别器, 对风机齿轮箱数据进行数据增强和故障诊断。李兵^[14]通过改进正余弦优化算法优化的堆叠降噪自编码器实现了噪声环境下的电机轴承故障诊断。李俊卿^[15]将 ViT (Vision-Transformer) 模型与 CNN 模型相结合, 将一维信号转化为二维灰度图作为模型输入, 实现了滚动轴承的故障诊断。Swin Transformer 具有比 ViT 更强大的特征提取能力, 杨隽豪^[16]利用这一特性, 将暂态电压时域数据转化为格拉姆角场 (GAF) 图, 输入到 Swin Transformer 模型中, 实现了柔性直流电网单端量的故障诊断。

针对实际运行工况复杂多变, 振动信号采集中常常含有噪音, 导致风机齿轮箱故障诊断效果不佳的问题, 本文提出了基于马尔科夫变迁场 (MTF) 图形编码技术与 Swin Transformer 模型相

收稿日期: 2023-09-18。

基金项目: 国家自然科学基金面上项目 (52077120)。

作者简介: 张彬桥 (1978-), 男, 博士, 副教授, 硕士生导师, 研究方向为电力系统运行与控制及故障诊断。E-mail: zhbq@ctgu.edu.cn

结合的故障诊断方法,提升风机齿轮箱故障诊断精度。首先,通过时序信息计算概率迁移矩阵,将迁移矩阵转化为 MTF 二维特征图谱,实现一维振动信号向二维图像的转化;然后,将 MTF 图谱输入搭建好的 Swin Transformer 网络中进行模型训练;最后,通过改进模型损失函数的计算方法强化了 Swin Transformer 模型对微弱故障特征信息的学习,将故障样本输入训练好的模型,实现了风机齿轮箱故障诊断。

1 基于 MTF-Swin Transformer 的故障诊断方法

1.1 基于 MTF 的图形编码

假设有一维时序振动信号序列 $X=\{x_1, x_2, \dots, x_n\}$, 将该一维时序振动信号分为 L 个区域, 任意区域上的信号可以映射到对应子域上。定义一个矩阵 R , 表示在所有子域中一个子域信号被另一个子域信号跟随的概率。 R 中的概率计算式为

$$r_{i,j}=P(x_i \in l_i \mid x_{i-1} \in l_j) \quad (1)$$

$$\sum_{j=1}^L r_{i,j}=1, r_{i,j} \geq 0 \quad (2)$$

式中: $r_{i,j}$ 为概率跟随矩阵中 i 点被 j 点跟随的概率值; i 点被其他点跟随的概率的和为 1。

通过计算每个元素的跟随概率值就可以进一步得出 $L \times L$ 加权邻接的迁移概率矩阵 R 。

$$R = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1L} \\ r_{21} & r_{22} & \dots & r_{2L} \\ \vdots & \vdots & \ddots & \vdots \\ r_{L1} & r_{L2} & \dots & r_{LL} \end{bmatrix} \quad (3)$$

引入时间信息来关联振动信号幅值信息, 定义 MTF 矩阵 M [式(4)], 其包含了振动信号序列

的时间信息。

$$M = \begin{bmatrix} m_{11} & m_{12} & \dots & m_{1L} \\ m_{21} & m_{22} & \dots & m_{2L} \\ \vdots & \vdots & \ddots & \vdots \\ m_{L1} & m_{L2} & \dots & m_{LL} \end{bmatrix} \quad (4)$$

$$m_{ij} = P\{r_{ij} \mid x_i \in l_i, x_j \in l_j\} \quad (5)$$

式中: m_{ij} 为 l_i 向 l_j 发生状态转变的转移概率。

通过考虑时间位置, 将包含振幅的幅度值轴上的概率迁移矩阵 R 扩展到了包含时间轴(时间戳)的 M 矩阵。

在转化过程中, 由于迁移概率的计算受采样频率的影响, 过大的采样频率与不匹配的子域划分会导致迁移概率值的弥散现象。因此, 本文将多步采样数据平均后再进行迁移概率计算, 有效避免了概率弥散问题, 同时, 采用重采样的方法进行数据增强, 数据增强具体方式如图 1 所示。




图 1 数据重采样
Fig.1 Data resampling

1.2 Swin Transformer 网络模型结构

1.2.1 模型主干网络

Swin Transformer 模型基于 Transformer 架构实现, 其模型主干部分结构如图 2 所示^[5]。

每个层级结构之间均会进入下采样层执行下




图 2 Swin Transformer 主干网络
Fig.2 Swin Transformer backbone network

采样, 使用卷积核将图像下采样降维。下采样操作的具体过程如图 3 所示。

1.2.2 Swin Transformer 模块

Swin Transformer 模块具体结构如图 4 所示。

自注意力机制计算式为

$$Attention(Q, K, V) = Softmax(QK^T / \sqrt{d} + B)V \quad (6)$$




图 3 下采样过程
Fig.3 Downsampling procedure

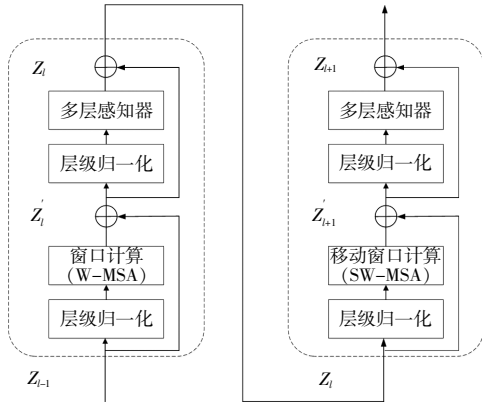


图4 Swin Transformer 模块

Fig.4 Swin Transformer block

式中: $Attention$ 为自注意力值; Q, K, V 分别为 Query 矩阵、Key 矩阵和 Value 矩阵; $Softmax$ 为指数归一化函数; d 为输入通道数; B 为偏置矩阵; QK 对为头的数量, 通过计算 QK 对的相似度即可得到自注意力权重。

自注意力权重与 V 的乘积代表了最终含有自注意力值的输出, 总的输出则由多个头的自注意力输出融合拼接得到。

若 Z 为每层的输出, 其计算过程可由式(7), 式(8)表示。

第一部分:

$$\begin{cases} Z'_l = F_{W-MSA}[F_{LN}(Z_{l-1})] + Z_{l-1} \\ Z_l = F_{MLP}[F_{LN}(Z'_l)] + Z'_l \end{cases} \quad (7)$$

第二部分:

$$\begin{cases} Z'_{l+1} = F_{SW-MSA}[F_{LN}(Z_l)] + Z_l \\ Z_{l+1} = F_{MLP}[F_{LN}(Z'_{l+1})] + Z'_{l+1} \end{cases} \quad (8)$$

式中: F_{MLP} 为多层感知器模块化处理函数; F_{LN} 为层级归一化层模块化处理函数; F_{W-MSA} 为 W-MSA 层模块化处理函数; F_{SW-MSA} 为 SW-MSA 层模块化处理函数。

W-MSA 层的具体实现方法是将输入划分为多个小窗口, 然后基于每个小窗口做自注意力计算, 该方法有效地控制了计算量, 节省了内存。若输入维度为 $H \times W \times C$, 则 MSA 的计算复杂度为

$$\Omega(MSA) = 4HWC^2 + 2(HW)^2C \quad (9)$$

式中: H 为输入图像高度; W 为输入图像宽度; C 为输入图像通道数。

W-MSA 与 SW-MSA 的计算复杂度为

$$\Omega(W-MSA) = \Omega(SW-MSA) = 4HWC^2 + 2M^2HWC \quad (10)$$

式中: M 为小窗口数量。

W-MSA 层与 SW-MSA 层成对使用, 构成了 Swin Transformer 的一个基本计算单元, 实现了对整张输入图像的特征提取。因此, 本文所设计的网络中 Swin Transformer 块的数目均是偶数。

1.3 损失函数

损失函数采用改进的交叉熵损失函数。模型在进入 Softmax 分类层后, 通过 Softmax 函数计算每个类的置信度。

$$p_i = \frac{\exp(z_i)}{\sum_{k=1}^N \exp(z_k)} \quad (11)$$

式中: p_i 为预测该类的置信度, 总和为 1; i 为样本编号; z_i 为模型在全连接层的输出; k 为类别序号, 总共有 N 类类别。

通过计算模型预测标签与真实标签的信息差异化程度可以确定模型的交叉熵损失函数。

$$H(p, q) = - \sum_{i=1}^n p(x_i) \log[q(x_i)] \quad (12)$$

式中: $H(p, q)$ 为交叉熵值; $p(x_i)$ 为样本的真实概率分布; $q(x_i)$ 为样本的预测概率分布。

利用上述公式可计算模型的损失。当一个批量大小为 m 的样本集送入模型进行训练时, 其损失为

$$loss = - \frac{1}{m} \sum_{i=1}^m \sum_{k=1}^n y_i \log p_i \quad (13)$$

式中: y_i 为标签向量。

用期望概率标签向量代替独热标签向量, 标签向量为

$$y_i = y_h(1-\alpha) + \alpha/N \quad (14)$$

式中: y_h 为独热编码后的标签值; α 为平滑因子。

若独热标签编码值采用硬编码形式, 式(14)可转化为

$$y_i = \begin{cases} 1-\alpha, & i=t \\ \alpha/N, & i \neq t \end{cases} \quad (15)$$

式中: t 为样本真实类别。

1.4 故障诊断流程

基于 MTF-Swin Transformer 模型的风机齿轮箱故障诊断方法训练步骤如下:

步骤 1: 利用振动加速度传感器收集一维时

序振动信号;

步骤 2: 采用重叠采样的方法对数据集进行数据增强, 同时将一维时序振动信号转化为二维 MTF 特征图谱;

步骤 3: 将样本数据集按照 6:2:2 的比例随机划分为训练集、测试集和验证集;

步骤 4: 将训练集样本输入到搭建好的 Swin Transformer 模型中训练, 并将训练好的模型保存;

步骤 5: 将验证集输入到训练好的 Swin Transformer 模型中检验分类精度, 最终实现风机齿轮箱故障诊断模型的建立。

图 5 为故障诊断流程。

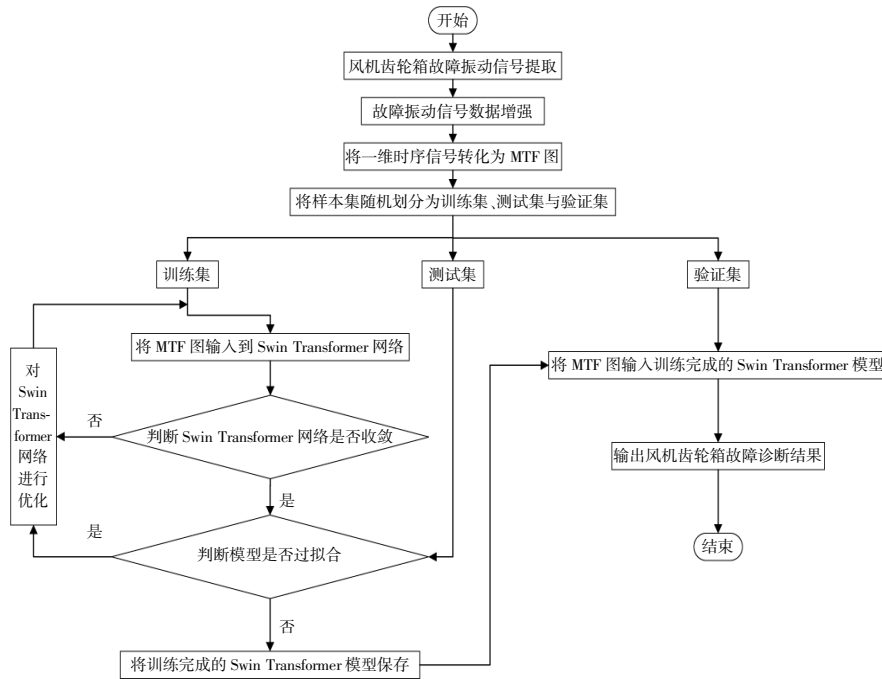


图 5 故障诊断流程

Fig.5 Fault diagnosis process

2 实验分析

2.1 实验数据集

本文所用风机齿轮箱数据集来自东南大学公开齿轮箱数据集^[7]。实验数据由传动系统动态模拟实验平台收集。振动加速度传感器收集了齿轮箱转速为 20 Hz, 负载为 0 v 和转速为 30 Hz, 负载为 2 v 两种工况下的实验数据, 共收集了健康以及 4 种齿轮箱故障状态下的振动信号, 4 种故障状态及其独热编码标签如表 1 所示。

表 1 风机齿轮箱故障

Table 1 Wind turbine gear box faults

| 故障类型 | 故障描述 | 标签 |
|------|-----------|----|
| 正常 | 健康 | 0 |
| 磨损 | 在齿轮表面发生磨损 | 1 |
| 脚裂纹 | 在齿轮脚处出现裂纹 | 2 |
| 根裂纹 | 齿轮齿根处出现裂纹 | 3 |
| 断齿 | 齿轮中缺失一齿 | 4 |

考虑到旋转设备振动信号具有周期性, 本文设置每个数据样本包含 2 048 个采样点, 采样时

间选取为 10 s, 采样频率 2 kHz。在两种不同工况下分别建立数据集, 每个数据集含有 5 种类别的图像, 每类样本数量为 500, 总共为 2 500 个样本。训练集、测试集和验证集按照 6:2:2 的比例随机划分后, 训练集样本数量为 1 500, 测试集样本数量为 500, 验证集样本数量为 500。

MTF 二维特征图像样本采用的图像大小为 64×64, 生成的每类 MTF 图像样本如图 6 所示。由图 6 可知, 生成的各故障类别 MTF 图像中, 既含有概率映射颜色信息, 又具有不同的纹理信息。

2.2 仿真分析

实验运行环境为一台高性能计算机, 硬件配置: 处理器为 AMD Ryzen 5 5600H, 显卡为 NVIDIA GeForce RTX 3050 Laptop GPU。软件环境为 Windows11(64 位), python3.10 编程环境。

将样本数据输入到 Swin Transformer 模型中进行训练, 设置迭代次数为 500 次, 梯度更新学习率采用 adamW 动量调整优化策略进行动态调整,




图 6 不同故障类别的 MTF 特征图谱

Fig.6 MTF coding feature image with different fault types

初始学习率设置为 0.001。为防止模型出现过拟合,采用 Dropout 方法作为正则项,Dropout 率设置为 0.2。考虑到实验设备的并行计算能力,设置批大小为 16,数据加载线程数设置为 4,模型损失函数曲线如图 7 所示。




图 7 损失函数曲线

Fig.7 Loss function curve

在模型训练过程中,模型训练集与测试集的准确率随迭代次数的变化曲线如图 8 所示。




图 8 准确率曲线

Fig.8 Accuracy curve

由图 8 可知,模型训练集与测试集准确率基本保持一致,没有出现过拟合现象。为避免单次实验的偶然性,经重复实验取 10 次平均值,模型故障诊断准确率可达 99.48%。将验证集样本输入到训练好的 Swin Transformer 故障诊断模型,得到的故障分类混淆矩阵如图 9 所示。




图 9 分类混淆矩阵

Fig.9 Classification confusion matrix

混淆矩阵中横坐标为故障诊断模型对 500 个样本的诊断结果,纵坐标为 500 个样本的真实结果,其中颜色越深代表分类结果越准确。由图 9 可知,模型对 0 类、1 类、2 类和 4 类共 400 个样本有 100% 的准确诊断率,仅在 3 类中有 1 例误诊断为 2 类,诊断精度高达 99.8%。

2.3 对比试验

为验证本文提出的 MTF 图像编码方式在故障诊断中的效果,设置故障诊断中常用到的灰度图和 GAF 图的图像编码作为对比实验的对照组。为保持与本文编码方法的一致性,灰度图和 GAF 图图像大小均设置为 64×64,分别输入本文模型进行训练,其故障分类准确率如图 10 所示。

由图 10 可知,MTF 特征图谱编码方式实现的故障诊断方法的故障诊断率最高。与其他图形编码方式相比,本文提出的 MTF 图形编码方式能够较好地反映风机齿轮箱故障震动信号的特征。

2.4 抗噪声性能实验

在实际工程应用中,安装在风机齿轮箱中的




图 10 不同编码方式的故障分类准确率
Fig.10 Fault classification accuracy of different coding methods

振动加速度传感器收集到的数据常常含有较大的噪声,为模拟实际工程环境,为数据集分别添加信噪比为 1,2,3,5,10 dB 的高斯白噪声。同时为验证本文所提出的 Swin Transformer 模型在抗噪方面的性能,选取常用的网络模型作为对照基准模型进行对比实验,结果如表 2 所示。

表 2 抗噪声实验数据
Table 2 Anti-noise experiment data %

| 模型 | 信噪比 | | | | |
|------------------|-------|-------|-------|-------|-------|
| | 1 dB | 2 dB | 3 dB | 5 dB | 10 dB |
| AlexNet | 20.15 | 19.37 | 24.87 | 19.99 | 22.51 |
| GoogLeNet | 50.33 | 58.62 | 54.35 | 61.77 | 66.32 |
| DenseNet | 48.22 | 50.92 | 47.67 | 73.59 | 79.33 |
| 2D-CNN | 62.76 | 65.54 | 77.94 | 79.33 | 84.22 |
| Resnet50 | 65.27 | 73.56 | 86.43 | 90.29 | 92.71 |
| Swin Transformer | 90.68 | 90.32 | 93.21 | 98.43 | 99.65 |

由表 2 可知,本文提出的 Swin Transformer 模型的抗噪声性能优于其他模型。在信噪比为 10 dB 的噪声环境下,基本不影响模型对故障的判断,在信噪比为 1 dB 的强噪声下仍然能保持较高的诊断分类精度。而在噪声越来越大的情况下,其他网络模型的诊断分类精度大幅度下降。

2.5 模型泛化能力实验

考虑到风机齿轮箱经常工作在变工况下,不同负载会导致振动加速度传感器收集的数据产生变化,针对此种变化,故障诊断模型是否依旧能准确判断故障是十分重要的。为验证本文提出的故障诊断模型的泛化能力,采用转速-负载分别为 20 Hz-0 v 和 30 Hz-2 v 两种工况下的数据进行实验,结果如表 3 所示。

由表 3 可知,本文所提模型在变工况下的准确率下降均不超过 7%,而作为对照的其他模型

表 3 变工况下模型故障分类准确率
Table 3 Model fault classification accuracy under varying working conditions %

| 模型 | 变工况 | | | |
|------------------|-----------|-------|-----------|-------|
| | 20-0→30-2 | | 30-2→20-0 | |
| | | | | |
| AlexNet | 17.71 | 21.65 | 23.59 | 19.93 |
| GoogLeNet | 67.24 | 40.30 | 64.31 | 42.29 |
| DenseNet | 78.95 | 51.34 | 79.77 | 55.11 |
| 2D-CNN | 85.77 | 68.67 | 82.22 | 67.29 |
| Resnet50 | 90.26 | 71.56 | 88.43 | 70.68 |
| Swin Transformer | 99.68 | 94.32 | 99.52 | 93.98 |

则下降明显,证明本文模型具有一定的鲁棒性和泛化能力。

3 结论

本文针对传统故障诊断信号分析困难、故障诊断效果不佳的问题,将收集到的故障诊断信号通过 MTF 编码方式从一维时序故障振动信号转化为 MTF 二维特征图谱,随后输入 Swin Transformer 模型中进行故障诊断和分类,通过仿真实验,得出以下结论。

①基于 MTF 的图形编码方式能够将一维时序振动信号的时间相关性反映到 MTF 二位特征图谱中,相比于常用的灰度图,GAF 图具有更好的特征语义信息,将 MTF 图输入到 Swin Transformer 模型中,获得了 99.48%的故障分类精度。相比于常用的 CNN 网络架构,Swin Transformer 模型在抗噪能力以及泛化能力方面均取得了不错的效果。

②在变工况下,Swin Transformer 模型的故障分类准确率均高于 93%,模型具有一定的鲁棒性和泛化能力。

参考文献:

- [1] Neil Odam, Frans P de Vries. Innovation modelling and multi-factor learning in wind energy technology [J]. Energy Economics, 2018, 85(C): 104594.
- [2] 曾军,陈艳峰,杨苹,等.大型风力发电机组故障诊断综述[J].电网技术,2018,42(3): 849-860.
- [3] 于元滢,杨光永,晏婷,等.基于 CEEMD 和 MOMEDA 的滚动轴承故障提取[J].电子测量技术,2021,44(22): 96-101.
- [4] 吴秋梅,李强,于艳.基于变分模态分解的三级行星齿轮箱故障诊断[J].机械设计与研究,2022,38(2): 101-104.
- [5] 宋玉琴,周琪玮,赵攀.基于双树复小波和 AR 谱的滚

- 动轴承故障诊断 [J]. 组合机床与自动化加工技术, 2021(3):31-35.
- [6] 傅成豪,潘庭龙.基于改进阈值的风机齿轮箱故障信号小波去噪方法研究 [J]. 可再生能源,2020,38(9):1197-1202.
- [7] 杨苗蓬,高彦杰.基于 MODWT 和 ANN 的微电网故障诊断[J].电力电子技术,2022,56(2):19-22.
- [8] 邵凯旋,何怡刚,汪磊.基于多尺度熵分析与改进 SVM 的变压器故障识别[J].电子测量与仪器学报,2022,36(6):161-168.
- [9] 曹伟嘉,杨留方,徐天奇,等.基于精英反策略麻雀搜索优化随机森林的变压器故障诊断[J].国外电子测量技术,2022,41(2):138-143.
- [10] 向川,任泽俊,赵晶,等.基于 ISSAE 和 XGBoost 的滚动轴承故障诊断研究[J].机电工程,2021,38(6):704-711.
- [11] 朱保军,咸日常,范慧芳,等.WRSR 与改进朴素贝叶斯融合的变压器故障诊断技术研究[J].电力系统保护与控制,2021,49(20):120-128.
- [12] 杜小磊,肖龙,周庆辉,等.增强同步挤压 Stockwell 变换和改进集成深层极限学习机的轴承工况识别方法 [J].电机与控制学报,2022,26(11):141-150.
- [13] 李东东,刘宇航,赵阳,等.基于改进生成对抗网络的风机行星齿轮箱故障诊断方法[J].中国电机工程学报,2021,41(21):7496-7507.
- [14] 李兵,梁舒奇,单万宁,等.基于改进正余弦算法优化堆叠降噪自动编码器的电机轴承故障诊断[J].电工技术学报,2022,37(16):4084-4093.
- [15] 李俊卿,张承志,胡晓东,等.基于 CNN-ViT 的滚动轴承故障类型识别方法[J].电力科学与工程,2023,39(2):64-71.
- [16] 杨隽豪,韦延方,王鹏,等.基于 Swin Transformer 的柔性直流电网单端量故障诊断[J].电力建设,2023,44(5):53-60.
- [17] Siyu Shao, Stephen McAleer, Ruqiang Yan, et al. Highly accurate machine fault diagnosis using deep transfer learning[J]. IEEE Transactions on Industrial Informatics, 2019, 15(4):2446-2455.

Fault diagnosis of wind turbine gearbox based on MTF-Swin Transformer

Zhang Binqiao^{1,2}, Lei Jun^{1,2}, Wan Gang³

(1.Electric and New Energy Faculty, China Three Gorges University, Yichang 443002, China; 2.Hubei Key Laboratory of Operation and Control of Cascade Hydropower Station, Yichang 443002, China; 3.China Yangtze Power Co.,Ltd., Yichang 443002, China)

Abstract: In response to the challenge posed by the limited accuracy of traditional fault diagnosis methods in wind turbine gearbox applications due to the complex and variable operational conditions and the presence of significant noise, the MTF-Swin Transformer wind turbine gearbox fault diagnosis model is proposed. Initially, the one-dimensional vibration time series signal is transformed into a two-dimensional feature map with correlated temporal information using the Markov Transition Field (MTF) graph encoding method. Subsequently, this feature map is employed as the input for the Swin Transformer model, which utilizes a self-attention mechanism for automatic feature extraction. This process culminates in the classification of various fault types. The results demonstrate a fault diagnosis accuracy of 99.48%, affirming the effectiveness and superiority of the proposed method.

Keywords: Markov Transition Field; Swin Transformer; wind turbine gear box; fault diagnosis