

基于格拉姆角场和深度残差网络的变压器绕组 松动故障诊断模型

肖雨松*, 马宏忠

(河海大学 能源与电气学院, 江苏 南京 211100)

Transformer Winding Looseness Fault Diagnosis Model Based on GAF and Depth Residual Network

XIAO Yusong*, MA Hongzhong

(College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: Aiming at the problem that the feature quantity is difficult to select in the fault diagnosis of transformer winding looseness and relying on manual experience, a diagnosis method of transformer winding looseness based on automatic encoder noise reduction, gramian angle field (GAF) and depth residual network (ResNet) recognition is proposed. The method automatically learns effective fault features from GAF images without manually extracting the feature quantity. Firstly, the vibration signal is denoised through an automatic encoder to obtain a vibration signal with a higher signal-to-noise ratio. Then, the GAF method is used to convert the vibration signal into a two-dimensional image and generate an image dataset. Based on this, ResNet is trained to construct a network model suitable for classification and recognition of transformer winding looseness faults. Finally, a transformer winding looseness fault test platform is built to collect vibration signals of the winding under different looseness and experimental currents for analysis. The experimental results show that the proposed diagnosis method has an accuracy of over 95% in identifying transformer winding looseness, and can effectively identify the looseness phase and degree. It is suitable for identifying and diagnosing transformer winding looseness faults.

Key words: transformer vibration; winding looseness; denoise auto-encoder; gramian angular field (GAF); depth residual network

摘要: 针对变压器绕组松动故障诊断中特征量难以选取,依赖人工经验的问题,提出了一种基于自动编码器降噪,格拉姆角场(GAF)和深度残差网络(ResNet)进行识别的变压器绕组松动诊断方法。该方法直接从GAF图像中自动学习有效的故障特征,不需要手动提取特征量。首先,将振动信号经过自动编码器进行降噪,获得信噪比更高的振动信号。然后,采用GAF方法将振动信号转化为二维图像,生成图像数据集,在此基础上训练ResNet,构建适用于变压器绕组松动故障分类识别的网络模型。最后,搭建变压器绕组松动故障试验平台,采集绕组在不同松动和试验电流下的振动信号并进行分析。试验结果表明,所提诊断方法对变压器绕组松动识别准确率达95%以上,能够有效识别松动相和松动程度,适用于变压器绕组松动故障的识别和诊断。

关键词: 变压器振动; 绕组松动; 降噪自动编码器; 格拉姆角场(GAF); 深度残差网络

0 引言

变压器是电网系统中关键枢纽设备之一,其运行状况关系到整个电网的安全稳定。变压器发生绕组松动后,抗短路冲击能力大幅下降,形成严重的安全隐患^[1-2]。因此有必要对变压器绕组松动故障的诊断技术进行研究,保障变压器及电网安全运行。

频率响应法、低压脉冲法以及短路电抗法等是检测绕组松动的传统方法,这些方法往往只能用于离线检测,且精度不足,不能反映松动程度。相比于传统方法,振动检测法具有支持在线监测、与被测设备之间无电气联系以及不易受干扰等优点,被广泛应用于变压器、电抗器和断路器等电力

基金项目: 国家自然科学基金(51577050); 国家电网江苏省电力有限公司重点科技项目(J2022047)

National Natural Science Foundation of China (51577050);
Science and Technology Foundation of State Grid Jiangsu Electric Power Corporation(J2022047)

设备的机械故障诊断领域^[3-4]。目前振动信号诊断往往通过支持向量机(Support Vector Machines, SVM)和K均值聚类(K-Means)等机器学习方法进行故障识别和分类^[5-6]。文献[7]通过变分模态分解(Variational Mode Decomposition, VMD)将振动信号分解为多组模态分量并提取排列熵作为特征量,再输入天牛须搜索(Beetle Antennae Search, BAS)优化的SVM进行识别;文献[8]从时域、频域和时频域提取振动信号的多维特征量,并对特征量进行筛选,最后采用贝叶斯优化算法优化的极致梯度提升(eXtreme Gradient Boosting, XGBoost)模型进行诊断。

但这些传统机器学习分类方法不具备特征提取能力,需要手动提取特征,依赖人工经验;而且特征量往往只能反映数据某一方面的特征,反映的故障信息不够全面,泛用性不足。近年来,随着深度学习技术在分类、预测等领域的迅速发展,通过深度学习模型进行电气设备智能诊断成了新趋势。其中卷积神经网络(Convolutional Neural Network, CNN)具有很强的特征自动提取能力,避免了手动选取特征的困难,可以直接对原始时序信号进行学习,反映的故障信息更加全面;而且不依赖人工经验和特征分析,属于通用的方法。由于CNN在二维图像识别领域应用最为广泛,技术最为成熟,因此将一维信号转化为二维图像再进行特征提取具有明显的优势^[9-10]。

常用的图像编码算法有马尔可夫变迁场(Markov Transition Field, MTF)、短时傅里叶变换(Short-Time Fourier Transform, STFT)和格拉姆角场(Gramian Angular Field, GAF)等。其中格拉姆角场是一种利用格拉姆矩阵计算时间序列内部相关关系的图像编码方法,能够保留时间依赖性,且调整参数较少,没有小波基选取等问题,适合工程应用^[11]。

为了增强特征提取能力,新型CNN模型层数不断加深,但随着网络层数的增加也带来了时梯度爆炸、网络退化等问题,而深度残差网络(Residual Network, ResNet)针对这些问题进行了优化,从而提高了深层神经网络的特征提取能力,已在故障诊断领域得到了应用。文献[12]通过变分模态分解将接触器振动信号分解为固有模态分量,再转化为模态时频图,输入ResNet50进行

故障诊断;文献[13]将一维扰动信号转换为具有明显形状特征的二维轨迹圆,输入到ResNet进行特征学习并分类识别。但上述研究大多没有进行降噪处理,用于含有大量噪声的信号时效果可能不佳。

为实现不依赖人工提取特征量的变压器绕组松动诊断,提高诊断准确率,本文提出一种基于GAF和ResNet18的变压器振动信号绕组松动诊断方法,并加入自动编码器对振动信号进行降噪。最后通过试验验证了该方法的有效性。数据分析结果表明,所提方法能够有效识别绕组松动,诊断准确率达到97.6%。

1 振动信号处理

1.1 格拉姆角场

格拉姆角场(GAF)是一种在笛卡尔坐标系下将一维波形转化为二维图像的映射,反映了时序信号之间的相关程度,将振动信号转化为GAF图像有利于后续分类模型充分提取其中振动信息。GAF首先通过极坐标投影将时序中的步长和幅值转化为半径和角度;然后以三角函数衡量极坐标下每个点之间的相关性,通过三角函数变换形成格拉姆矩阵^[14-16]。

对于给定的时间序列 $X = \{x_1, x_2, \dots, x_n\}$,为了便于后续角度计算,首先将其缩放至 $[-1, 1]$ 区间内,缩放后的时间序列 x'_i 为

$$x'_i = \frac{[(x_i - \max X) + (x_i - \min X)]}{\max X - \min X} \quad (1)$$

然后将缩放后的时间序列 x'_i 映射到极坐标系下,数值大小编码为余弦角 θ , θ 取值区间为 $[0, \pi]$,保留了数值上的关系;并把时间映射为半径 r ,保留了时间上的关系。映射关系如下所示:

$$\begin{cases} \theta = \arccos x'_i, -1 \leq x'_i \leq 1, x'_i \in X' \\ r = \frac{t_i}{N}, t_i \in N \end{cases} \quad (2)$$

式中: t_i 为时间步; N 为常数因子。

在 $\theta \in [0, \pi]$ 区间内, $\cos \theta$ 单调递减,所以对于给定的时间序列,在极坐标下具有唯一对应的结果。此外,通过极坐标半径 r ,也保证了绝对的时间关系,属于双射变换。

将时间序列映射到极坐标后,可以通过每个点之间角度和或角度差的关系来计算相关性,即

格拉姆角和场 (Gramian Angular Summation Field, GASF) 和 格拉姆角差场 (Gramian Angular

Difference Field, GADF) 两种编码方式, GASF 和 GADF 的计算式分别为

$$\text{GASF} = \begin{cases} \cos(\theta_1 + \theta_1) & \cdots & \cos(\theta_1 + \theta_i) & \cdots & \cos(\theta_1 + \theta_m) \\ \vdots & & \vdots & & \vdots \\ \cos(\theta_i + \theta_1) & \cdots & \cos(\theta_i + \theta_i) & \cdots & \cos(\theta_i + \theta_m) \\ \vdots & & \vdots & & \vdots \\ \cos(\theta_m + \theta_1) & \cdots & \cos(\theta_m + \theta_i) & \cdots & \cos(\theta_m + \theta_m) \end{cases} \quad (3)$$

$$\text{GADF} = \begin{cases} \sin(\theta_1 - \theta_1) & \cdots & \sin(\theta_1 - \theta_i) & \cdots & \sin(\theta_1 - \theta_m) \\ \vdots & & \vdots & & \vdots \\ \sin(\theta_i - \theta_1) & \cdots & \sin(\theta_i - \theta_i) & \cdots & \sin(\theta_i - \theta_m) \\ \vdots & & \vdots & & \vdots \\ \sin(\theta_m - \theta_1) & \cdots & \sin(\theta_m - \theta_i) & \cdots & \sin(\theta_m - \theta_m) \end{cases} \quad (4)$$

经过上述变换, 将长度为 n 的时间序列转化为沿主对角线对称的二维 $n \times n$ 矩阵, 并保留了原序列的完整性和时间依赖性。GAF 编码流程如图 1 所示。




图 1 GAF 编码流程

Fig. 1 GAF conversion process

1.2 降噪自动编码器

自动编码器是一种特殊的神经网络模型, 如图 2 所示, 包含编码器和解码器两部分, 两侧结构对称, 编码器的输出对应解码器的输入, 两者维度相同。因此自动编码器能够在无监督的条件下将输入数据编码到低维空间, 同时保证输入变量的有效表征, 再通过解码器对压缩数据进行重构还原。

作为一种无监督机器学习方法, 自动编码器具有良好的特征提取能力, 不仅能降低样本维度, 还可以用于降噪^[17-19]。用于降噪时, 自动编码器的输入为加入了噪声的信号, 并通过训练预测无噪声的原始信号, 如下式所示:

$$\begin{cases} h = f(Wa' + b) \\ a = f(W'h + b') \end{cases} \quad (5)$$

式中: a' 和 a 分别为含噪声信号和原始信号; W 和 W' 分别为编码器和解码器的权重; b 和 b' 分别为编码器和解码器的偏置; $f(\cdot)$ 为激活函数; h 为经过编码器的隐含层输出。




图 2 自动编码器模型结构

Fig. 2 Structure of auto-encoder model

2 基于 ResNet 的故障诊断

2.1 深度残差网络

深度残差网络 (ResNet) 是一种针对传统 CNN 网络退化问题进行改进的卷积神经网络模型。根据经验, CNN 的层数越多, 提取的特征越全面, 效果更好。但在实际应用中, 随着网络不断加深, 深层网络的效果不但没有提升, 甚至在训练集和测试集上的准确率均低于浅层网络, 即出现了网络退化。

为了解决网络退化问题, ResNet 在网络中添加了残差模块, 残差模块中引入短路路径, 在保留了卷积网络特征提取能力的同时, 确保性能相比上一层残差模块至少不会下降, 从而解决了深层

网络退化问题^[20-21]。ResNet 由多个残差模块堆叠组成,一个基本残差模块如图 3 所示,包括卷积层、批规范化(Batch Normalization, BN)层、激活层和短路路径,图中短路路径为恒等映射。其中 BN 层用于解决训练过程中梯度爆炸和梯度消失问题。激活层采用 ReLU 函数,其收敛速度更快,并能增强网络非线性,也能一定程度避免梯度消失。

若卷积运算过程中改变了特征图的维度,残差拟合输出和恒等映射维度不一致,不能直接相加,此时可以加入 1×1 的卷积层调整短路路径的输出尺寸,再与残差相加。

ResNet 的核心思想是残差学习,基本残差模块学习的是目标 $H(x)$ 和输入 x 之间的残差 $F(x) = H(x) - x$ 。经过多层神经网络拟合后,模型准确率已经很高,残差数值很小,此时拟合过程接近于恒等映射。通过卷积层拟合恒等映射较为困难,因此带来网络退化问题。而残差 $F(x)$ 较小,拟合难度更低,从而提高了深层网络学习效果。此外,因为学习对象是残差,若单一网络层误差增大对模型整体性能影响较小,相比之下,常规 CNN 模型中单一网络层误差增大会造成整体性能明显下降。




图 3 残差模块

Fig. 3 Residual block

ResNet 具有多种不同深度的结构,包括 ResNet18、ResNet50 和 ResNet152 等,本文选择使用层数最少的 ResNet18。

2.2 GAF-ResNet 故障诊断模型

基于 GAF-ResNet 的绕组松动故障诊断流程如下:将振动信号按一定长度分帧,通过自动编码器降低其中的噪声,并采用 GAF 进行编码,生成二维图像;按一定比例将图像数据集划分为训练集和测试集;将训练集输入 ResNet 进行训练,得到故障诊断模型,再输入测试集数据对诊断效果进行分析。具体诊断流程如图 4 所示。

3 试验方案

为验证本文方法对绕组松动故障诊断的效




图 4 诊断流程图

Fig. 4 Flow chart of diagnosis

果,在一台 110 kV 三相油浸式变压器上搭建试验平台。变压器型号为 SFZ10-31500/110,低压侧额定电压 U_N 为 10.5 kV,额定电流 I_N 为 1 732 A。振动传感器使用 JF-2020 压电式加速度传感器,灵敏度为 20 mV/g。采集仪采样频率为 10 kHz,每组数据采集时长为 10 s。

振动信号的传播过程存在干扰,而干扰大小受传播路径和变压器结构影响,因此在不同位置测量的效果不同。大型变压器为钟罩式结构,绕组及铁心与油箱顶部通过结构件紧密接触,在油箱顶部测得的信号更为明显,传播路径短,受到干扰少,因此选择在油箱顶部布置 3 个测点,如图 5 所示。




图 5 测点布置示意图

Fig. 5 Schematic layout of measuring points

在设置绕组松动故障时,将变压器油抽出后吊罩,绕组的松动程度由预紧力确定,首先松开故障所在相的绕组紧固螺母;然后使用液压千斤顶压紧绕组并调节压力,以此定量模拟不同程度的松动。试验中设置有 5 种松动情况:正常(所有绕组均为额定预紧力 28 MPa)、A 相松动(A 相绕组

预紧力为 0 MPa,其他两相为额定)、A 相轻微松动(A 相预紧力为 14 MPa)、B 相松动(B 相绕组预紧力为 0 MPa)、和三相全松动(所有相绕组预紧力均为 0 MPa)。

试验中对变压器进行短路试验,为验证本文方法在不同负载电流下均具有较强的识别能力,共设置有 40%、60%、80%、100% 以及 110% I_N 五种试验电流。试验中电压保持恒定且铁心紧固程度不变,避免铁心振动对整体振动信号造成影响。

4 试验结果与分析

4.1 自动编码器降噪

第 3 节中试验环境非常稳定,基本不存在干扰,而实际运行环境中不可避免的存在大量干扰,会降低 GAF 图像质量从而降低诊断准确率。一些研究中通过分析峭度、相关系数等指标消除干扰信号,但不同类型、不同条件下的干扰信号具有不同的特征,不同变压器的自身振动信号特征也有所不同,很难通过某一固定的指标对干扰信号进行区分,泛用性不足,并依赖人工经验。因此本文选择加入自动编码器进行降噪,经过训练自动编码器能自动去除振动信号中的噪声,并保留其中的有效信息。

为分析自动编码器的抗干扰能力,取一段不含噪声的碾压其振动原始信号,向原始信号中同时添加敲击变压器油箱产生的振动信号和谐波分量(300 Hz 和 500 Hz)这两种不同类型的干扰,再划分出训练集和测试集,以训练集训练自动编码器,对测试集波形进行降噪。并将降噪前后的信号分别生成 GAF 图像,自动编码器降噪效果如图 6 所示。

由图 6 可见通过自动编码器能有效地消除噪声的干扰,降噪后波形中噪声分量明显减少,所生成的 GAF 图像虽然在清晰度和细节上有一定损失,但仍然保留了主要的特征,信噪比由 0 dB 提升至 39 dB 左右,有助于提高后续深度残差网络诊断的精度。

4.2 信号采样

GAF 图像大小和时间序列长度呈平方关系,若采样长度过长,会导致 GAF 图像大小增加,增加模型训练的时间和难度,并消耗更多的内存和存储空间;若采样长度过短,又不能有效反映故障




图 6 降噪效果

Fig. 6 Results of noise reduction

信息。本试验的采样频率为 10 kHz,而绕组振动基频为 100 Hz^[22-24],一个基频周期有 100 个数据点。为了获得最合适的采样长度,根据已有经验,本试验选取 4 种待选长度,分别为 300、500、700 和 1 000。以这 4 种采样长度,根据 2 号测点振动信号分别生成 2 500 组不同尺寸的 GADF 图像,再按 8 : 2 的比例划分训练集和测试集,使用 ResNet18 分别进行训练,最终分类结果对比如图 7 所示。

由图 7 可见,采样长度为 1 000 时,由于图像尺寸过大,耗时明显增加,而且需要训练的参数过多,准确率反而下降;长度为 300 时,由于包含的数据过少,准确率较低;长度为 500 和 700 时,准确率无明显差异,但长度为 700 时训练耗时较长。因此,综合考虑耗时和精度,本文选择采用 500 个数据点作为采样长度来生成 GAF 图像数据集。

采样长度为 500 时不同测点的分类准确率如表 1 所示。由于 2 号测点布置于变压器中部的 B 相绕组上方,两侧结构大致对称,对两侧 A 相和 C 相的振动信号同样敏感,诊断准确率最高;而 1 号和 3 号测点因为振动信号传播路径不对称,对侧




图7 样本长度预试验的准确率对比

Fig. 7 Accuracy comparison of sample length pretests

绕组的振动信号传播距离远且会受到 B 相振动信号的干扰,诊断准确率较低。因此选择 2 号测点振动信号进行下一步的研究分析。

表1 不同测点位置准确率对比

Tab. 1 Comparison of accuracy of different measurement point positions %

测点	1	2	3
准确率	91.6	96.4	89.4

4.3 故障诊断分析

根据上述分析,最优时间序列长度为 500,换算为时长即 0.05 s,为 5 个基频周期,每组试验数据采集时长为 10 s,故每组试验数据可以得到 200 个图像样本,又共有 25 种故障-负载组合,总计可以获得 5 000 个 GAF 图像样本,训练集和测试集分割比例为 8:2,测试集图像数量为 1 000。

使用 GADF 和 GASF 两种编码方式生成图像,并通过 ResNet18 分别进行训练,设置训练 epoch 数为 50,批尺寸为 32,优化器选择 Adam。两种编码方式的分类准确率训练迭代图如图 8 所示,准确率对比如表 2 所示。




图8 准确率迭代图

Fig. 8 Iterative graphs of the accuracy

表2 两种编码方式准确率对比

Tab. 2 Comparison of accuracy between two encoding methods %

编码方式	验证集准确率	测试集准确率
GADF	99.4	97.6
GASF	99.1	96.1

由图 8 和表 2 可见,在训练集上两者表现差距不大,但在测试集上 GADF 编码图像的准确率优于 GASF 编码。为了进一步探究模型故障诊断性能,绘制 GADF-ResNet18 混淆矩阵,如图 9 所示。在不同大小的试验电流下故障诊断准确率如表 3 所示。

由混淆矩阵可见,本文方法对不同松动故障均能有效识别,准确率均不低于 95%,总体准确率达到 97.6%,并可以有效区分不同的松动程度,但仍存在少量故障相定位错误。

0	190 95.0%	0 0.0%	9 4.5%	0 0.0%	1 0.5%
1	0 0.0%	196 98.0%	4 2.0%	0 0.0%	0 0.0%
2	3 1.5%	2 1.0%	195 97.5%	0 0.0%	0 0.0%
3	0 0.0%	0 0.0%	0 0.0%	196 98.0%	4 2.0%
4	0 0.0%	0 0.0%	0 0.0%	1 0.5%	199 99.5%
	0	1	2	3	4

图9 混淆矩阵

Fig. 9 Confusion matrix

表3 不同负载电流下的诊断准确率

Tab. 3 Diagnostic accuracy under different load currents

电流/A	准确率/%	电流/A	准确率/%
110% I_N	98.5	60% I_N	98.5
100% I_N	98.0	40% I_N	96.0
80% I_N	97.0	总计	97.6

绕组振动幅值与施加电流呈平方关系,而 GAF 编码会把数据缩放到 $[-1, 1]$ 区间内,生成的图像与原始数据的绝对幅值大小无关,减少了振动幅值大小带来的影响。由表 3 可见,在不同的试验电流下均有较高准确率。

以上分析表明本文所提方法能较好地实现绕组松动故障诊断,并受电流影响较小,具有良好的诊断精度和适用性。

4.4 诊断效果对比

为了进一步验证本文方法的优越性,分两方面与其他诊断方法进行对比:一是与不同图像编

码方式对比,包括马尔可夫变迁场(MTF)和短时傅里叶变换(STFT);二是与不同的 CNN 网络模型对比,包括浅层 CNN、ResNet34 和 ResNet50。准确率和训练耗时对比结果如图 10 所示。




图 10 不同模型诊断性能对比

Fig. 10 Comparison of diagnostic performance between different models

由图 10 可以看出,相比于 MTF 和 STFT 编码图像,GADF 编码方法的准确率最高,并且 GADF 需要调整的参数很少,没有小波基选择等问题,计算速度较快,更适合实际应用。

网络模型对比中,浅层 CNN 的结构最简单,训练速度最快,但准确率较低;相比之下 ResNet18 虽然耗时较高,但具有更高的诊断准确率;而 ResNet34 和 ResNet50 相比于 ResNet18 准确率变化不大,但训练耗时明显增加,对硬件的要求也更高。综合来看,ResNet18 在具备较强特征提取能力同时具有较快的训练速度,优于其他网络模型。

5 结语

为了挖掘变压器绕组松动振动信号的特征,实现数据驱动下的松动故障诊断,考虑到卷积神经网络在图像处理领域的优势,本文构建了基于 GAF 和 ResNet18 的绕组松动故障诊断模型,并采用自动编码器进行降噪,主要优势体现在:

(1) 通过 GAF 将振动信号转化为图像,直接将图像输入深度残差网络进行学习,充分发挥卷积神经网络的特征提取能力,无需手动提取振动信号特征量,是通用方法。

(2) 深度残差网络能有效解决深层卷积神经网络梯度以及网络退化问题,用于变压器绕组松动诊断的准确率达 95% 以上,并能识别松动所在相和松动程度。

(3) 自动编码器能有效消除复杂环境中振动信号的噪声成分,增强了鲁棒性,提高了所提方法的适用性。

参考文献

- [1] 时维国, 桑尧尧. 基于电压电流混合模型的新型磁链观测器[J]. 电机与控制应用, 2019, 46(7): 14-19.
SHI W G, SANG Y Y. Novel flux observer based on voltage-current hybrid model[J]. Electric Machines & Control Application, 2019, 46(7): 14-19.
- [2] 崔佳嘉, 马宏忠. 基于 CEEMDAN-小波阈值和 3D-CNN 的变压器铁心松动故障诊断模型[J]. 电机与控制应用, 2022, 49(10): 46-52.
CUI J J, MA H Z. Transformer iron core looseness fault diagnosis model based on CEEMDAN-wavelet-threshold and 3D-CNN [J]. Electric Machines & Control Application, 2022, 49(10): 46-52.
- [3] 颜君凯, 马宏忠, 李凯, 等. 基于振动信号的变压器绕组松动故障诊断方法[J]. 电力系统自动化, 2017, 41(3): 122-128.
YAN J K, MA H Z, LI K, et al. Vibration signal based diagnosis method for looseness fault of transformer winding [J]. Automation of Electric Power Systems, 2017, 41(3): 122-128.
- [4] 侯鹏飞, 马宏忠, 吴金利, 等. 基于混沌理论与蝗虫优化 K-means 聚类算法的电抗器铁芯和绕组松动状态监测[J]. 电力自动化设备, 2020, 40(11): 181-187.
HOU P F, MA H Z, WU J L, et al. Looseness status monitoring of reactor core and winding based on chaos theory and K-means clustering algorithm optimized by grasshopper algorithm [J]. Electric Power Automation Equipment, 2020, 40(11): 181-187.
- [5] 李楠, 马宏忠, 张玉良, 等. 基于特征筛选和改进深度森林的变压器内部机械状态声纹识别[J]. 电机与控制应用, 2022, 49(9): 57-65+74.
LI N, MA H Z, ZHANG Y L, et al. Voiceprint recognition of transformer internal mechanical state based on feature screening and improved deep forest [J]. Electric Machines & Control Application, 2022, 49(9): 57-65+74.
- [6] 李楠, 马宏忠, 朱昊, 等. 基于 50 Hz 倍频小波时频熵和 RUSBoost 的变压器绕组松动声纹识别[J]. 电机与控制应用, 2022, 49(5): 87-93+102.
LI N, MA H Z, ZHU H, et al. Transformer winding

- looseness voiceprint recognition based on 50 Hz frequency multiplying wavelet time-frequency entropy and RUSBoost [J]. *Electric Machines & Control Application*, 2022, 49(5): 87-93+102.
- [7] 顾仲翔,马宏忠,张勇,等. 基于VMD与优化SVM的变压器绕组松动缺陷振动信号诊断方法[J]. *高压电器*, 2023, 59(1): 117-125.
- GU Z X, MA H Z, ZHANG Y, et al. Vibration signal diagnosis method of transformer winding looseness defect based on VMD and optimized SVM [J]. *High Voltage Apparatus*, 2023, 59(1): 117-125.
- [8] 裴瑶,武建文,马速良,等. 基于多特征评估与XGBoost的高压断路器故障诊断[J]. *高压电器*, 2023, 59(4): 1-9.
- CHANG Y, WU J W, MA S L, et al. Fault diagnosis of high voltage circuit breaker based on multi-feature assessment and XGBoost [J]. *High Voltage Apparatus*, 2023, 59(4): 1-9.
- [9] 张重远,罗世豪,岳浩天,等. 基于Mel时频谱-卷积神经网络的变压器铁芯声纹模式识别方法[J]. *高电压技术*, 2020, 46(2): 413-422.
- ZHANG C Y, LUO S H, YUE H T, et al. Pattern recognition of acoustic signals of transformer core based on Mel-spectrum and CNN [J]. *High Voltage Engineering*, 2020, 46(2): 413-422.
- [10] 崔佳嘉,马宏忠. 基于改进MFCC和3D-CNN的变压器铁芯松动故障声纹识别模型[J]. *电机与控制学报*, 2022, 26(12): 150-160.
- CUI J J, MA H Z. Voiceprint recognition model of transformer core looseness fault based on improved MFCC and 3D-CNN [J]. *Electric Machines and Control*, 2022, 26(12): 150-160.
- [11] 古莹奎,吴宽,李成. 基于格拉姆角场和迁移深度残差神经网络的滚动轴承故障诊断[J]. *振动与冲击*, 2022, 41(21): 228-237.
- GU Y K, WU K, LI C. Rolling bearing fault diagnosis based on Gram angle field and transfer deep residual neural network [J]. *Journal of Vibration and Shock*, 2022, 41(21): 228-237.
- [12] 李海英,孙越,张笑,等. 模态时频图与ResNet50融合的真空接触器故障诊断方法[J]. *高电压技术*, 2023, 49(5): 1831-1840.
- LI H Y, SUN Y, ZHANG X, et al. Fault diagnosis of vacuum contactor based on modal time-frequency diagram and ResNet50 [J]. *High Voltage Engineering*, 2023, 49(5): 1831-1840.
- [13] 兰名扬,刘宇龙,金涛,等. 基于可视化轨迹圆和ResNet18的复合电能质量扰动类型识别[J]. *中国电机工程学报*, 2022, 42(17): 6274-6286.
- LAN M Y, LIU Y L, JIN T, et al. An improved recognition method based on visual trajectory circle and ResNet18 for complex power quality disturbances [J]. *Proceedings of the CSEE*, 2022, 42(17): 6274-6286.
- [14] 万可力,马宏忠,崔佳嘉,等. 基于Mel-GADF与ConvNeXt-T的变压器铁芯松动故障诊断方法[J/OL]. *电力自动化设备*, 2023-07-06. <https://doi.org/10.16081/j.epae.202307003>.
- WAN K L, MA H Z, CUI J J, et al. Fault diagnosis method of transformer core loosening based on Mel-GADF and ConvNeXt-T [J/OL]. *Electric Power Automation Equipment*, 2023-07-06. <https://doi.org/10.16081/j.epae.202307003>.
- [15] 郑炜,林瑞全,王俊,等. 基于GAF与卷积神经网络的电能质量扰动分类[J]. *电力系统保护与控制*, 2021, 49(11): 97-104.
- ZHENG W, LIN R Q, WANG J, et al. Power quality disturbance classification based on GAF and a convolutional neural network [J]. *Power System Protection and Control*, 2021, 49(11): 97-104.
- [16] 张辉,戈宝军,韩斌,等. 基于GAF-CapsNet的电机轴承故障诊断方法[J]. *电工技术学报*, 2023, 38(10): 2675-2685.
- ZHANG H, GE B J, HAN B, et al. Fault diagnosis method of motor bearing based on GAF-CapsNet [J]. *Transactions of China Electrotechnical Society*, 2023, 38(10): 2675-2685.
- [17] 张立智,井陆阳,徐卫晓,等. 基于卷积降噪自编码器和CNN的滚动轴承故障诊断[J]. *组合机床与自动化加工技术*, 2019(6): 58-62.
- ZHANG L Z, JING L Y, XU W X, et al. Fault diagnosis of rolling bearing based on convolutional denoising auto-encoder and CNN [J]. *Modular Machine Tool & Automatic Manufacturing Technique*, 2019(6): 58-62.
- [18] 王挺韶,季天瑶,姜雨滋,等. 基于降噪自动编码器与一维卷积网络的风机故障诊断方法[J]. *电测与仪表*, 2023, 60(1): 87-93+173.
- WANG T S, JI T Y, JIANG Y Z, et al. Fault diagnosis method for wind turbines based on de-noise auto-encoder and one-dimensional convolution

- network [J]. Electrical Measurement & Instrumentation, 2023, 60(1): 87-93+173.
- [19] 王亚伦, 周涛, 陈中, 等. 基于堆叠式降噪自动编码器和深度神经网络的风电调频逐步惯性智能控制[J]. 上海交通大学学报, 2023, 57(11): 1477-1491.
- WANG Y L, ZHOU T, CHEN Z, et al. Stepwise inertial intelligent control of wind power for frequency regulation based on stacked denoising autoencoder and deep neural network [J]. Journal of Shanghai Jiaotong University, 2023, 57(11): 1477-1491.
- [20] 贺才郡, 李开成, 杨王旺, 等. 基于双通道 GAF 和深度残差网络的电能质量复合扰动识别[J]. 电网技术, 2023, 47(1): 369-376.
- HE C J, LI K C, YANG W W, et al. Power quality compound disturbance identification based on dual channel GAF and depth residual network [J]. Power System Technology, 2023, 47(1): 369-376.
- [21] 赵小强, 张毓春. 基于双路并行多尺度 ResNet 的滚动轴承故障诊断方法[J]. 振动与冲击, 2023, 42(3): 199-208.
- ZHAO X Q, ZHANG Y C. Fault diagnosis method of rolling bearing based on dual-path parallel multi-scale ResNet method[J]. Journal of Vibration and Shock, 2023, 42(3): 199-208.
- [22] 颜锦, 马宏忠, 朱昊, 等. 基于 LMD 边际谱能量熵与 FWA-SVM 的变压器绕组松动诊断[J]. 电测与仪表, 2021, 58(11): 74-80.
- YAN J, MA H Z, ZHU H, et al. Diagnosis for transformer winding looseness based on LMD marginal spectrum energy entropy and FWA-SVM [J]. Electrical Measurement & Instrumentation, 2021, 58(11): 74-80.
- [23] 师愉航, 汲胜昌, 张凡, 等. 变压器绕组多倍频振动机理及特性[J]. 高电压技术, 2021, 47(7): 2536-2544.
- SHI Y H, JI S C, ZHANG F, et al. Multi-frequency vibration mechanism and characteristics of transformer windings [J]. High Voltage Engineering, 2021, 47(7): 2536-2544.
- [24] 张仕民, 丰遥. 基于振动信号的变压器铁心与绕组故障区分方法[J]. 电测与仪表, 2021, 58(6): 161-166.
- ZHANG S M, FENG Y. Discrimination method of transformer core and winding fault based on vibration signal [J]. Electrical Measurement & Instrumentation, 2021, 58(6): 161-166.

收稿日期:2023-07-29

收到修改稿日期:2023-10-07

作者简介:

马宏忠(1962-),男,博士,教授,研究方向为电力设备状态监测与故障诊断,hhumhz@163.com;

* 通信作者:肖雨松(1999-),男,硕士研究生,研究方向为电力设备状态监测与故障诊断,573634302@qq.com。

Transformer Winding Looseness Fault Diagnosis Model Based on GAF and Depth Residual Network

XIAO Yusong^{*}, MA Hongzhong

(College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Key words: transformer vibration; winding looseness; de-noise auto-encoder; gramian angular field (GAF); depth residual network

Transformers are key hub equipment in the power grid, and winding looseness of transformers can pose serious safety hazards. The vibration signal detection method is a commonly used method for diagnosing winding looseness, but traditional diagnostic methods have problems such as difficult feature selection and low diagnostic accuracy.

In recent years the convolutional neural network (CNN) technology for image processing has rapidly developing, and its conversion of time series into two-dimensional images can effectively improve the accuracy of classification and calculation methods, and there is no need to manually extract features in advance.

Therefore, this article proposes a transformer winding looseness fault diagnosis method based on gramian angular fields (GAF) and residual neural network (ResNet), and denoises the vibration signal through a de-noise auto-encoder. This method first trains an automatic encoder to process vibration signals and eliminate noise. Secondly, GAF is used to convert transformer vibration signals into images and preserve their temporal correlation. Finally, the features in the image are extracted through ResNet. ResNet solves the problem of network degradation while the network depth is increased. The GAF conversion process and flow chart of diagnosis are respectively shown in Fig.1 and Fig.2.

This method achieves automatic feature extraction of vibration signals and adaptive noise elimination. Compared with traditional methods, this method does not require manual feature extraction and does not rely on expert experience and data analysis. It directly analyzes the complete vibration

signal, reflecting more comprehensive fault features and higher accuracy.

Finally, an experimental platform is established to verify the method proposed in this paper. The analysis results indicate that de-noise auto-encoder can effectively eliminate noise. GADF performs better than other image conversion algorithms. Compared to other network models, ResNet has the highest accuracy.




Fig. 1 GAF conversion process




Fig. 2 Flow chart of diagnosis