

DOI: 10.12158/j.2096-3203.2023.04.027

基于相空间张量分解的有载分接开关故障诊断

陈文通¹, 盛骏¹, 钱肖¹, 吴雪峰¹, 王丰华²

(1. 国网浙江省电力有限公司金华供电公司, 浙江 金华 321000;

2. 上海交通大学(电力传输与功率变换控制教育部重点实验室), 上海 200240)

摘要:有载分接开关一次档位切换过程中伴生的振动信号与其机械状态密切相关。文中基于有载分接开关档位切换过程中振动信号的高维相点空间分布,对有载分接开关多个位置处的振动信号进行张量化表示,用以捕捉尽可能丰富的有载分接开关机械状态信息。然后对所构建的相空间三阶张量进行 Tucker 张量分解以获取核心张量,据此建立基于卷积神经网络的有载分接开关机械故障判别模型。以某 CM 型有载分接开关动作时的振动信号为例进行分析,结果表明,有载分接开关动作时的振动信号的相空间核心张量信息全面且冗余少,所构建的基于卷积神经网络的有载分接开关机械故障诊断模型性能良好,准确率超过 95%,可为有载分接开关的故障识别及状态维修提供参考依据。

关键词:有载分接开关;振动信号;故障诊断;相空间重构;张量分解;卷积神经网络

中图分类号:TM403.4

文献标志码:A

文章编号:2096-3203(2023)04-0248-08

0 引言

低碳背景下新型电力系统的建设需求对电力设备的安全可靠运行提出了更高的要求,有载分接开关(on-load tap-changer, OLTC)是有载调压变压器在不断电情况下进行电压调整的重要部件,其可靠性直接关系到变压器及电网的稳定运行^[1-2]。受制于 OLTC 的复杂机械结构,其故障率随着档位切换次数及使用年限的增加而增长,且居高不下。据统计,OLTC 故障 90% 以上来源于机械缺陷^[3-5]。因此,准确判别 OLTC 机械缺陷极为重要,这是提升电网内在防御和风险抵御能力的关键。

OLTC 档位切换过程中机械结构件运动过程伴生的振动信号与其机械状态相关性极高,且近年来 OLTC 故障频发,因此 OLTC 的机械故障振动监测技术凭借其灵敏度高和现场实施方便等优势成为研究热点。文献[6-8]基于小波变换提取 OLTC 振动信号的时域包络,根据其“垄脊分布图”特征建立基于自组织映射网络的 OLTC 机械故障诊断模型。文献[9-10]综合分析 OLTC 振动信号幅值、波峰时刻等多个特征参数,实现了 OLTC 的弹簧储力不足、触头磨损与触头烧蚀等机械缺陷的分析诊断。针对 OLTC 机械振动信号的强时变特征,经验模态分解算法及其变体等时频分析方法将 OLTC 振动信号分解为多个固有模式函数,进而分别依据支持向量机与优化自相关向量机实现 OLTC 机构卡涩、触头松

动等早期机械缺陷的诊断^[11-13]。文献[14]基于 OLTC 振动信号自适应变分模态分解算法的分解结果,提出基于模拟退火优化极限学习机的 OLTC 机械故障诊断模型。文献[15-17]从 OLTC 振动信号时间序列的低频混沌特征出发,对 OLTC 振动信号进行相空间重构,基于其相空间分布特征构建 OLTC 典型机械故障的隐马尔科夫诊断模型。文献[18]对计算得到的 OLTC 振动信号相空间分布进行 K-means 聚类,根据聚类结果定义簇中心位移矢量,对 OLTC 的机械状态进行检测。已有研究表明,对 OLTC 振动信号进行相空间重构能够从高维吸引子中提取出更完善的表征设备运行状态的特征参数。但现有研究大都针对单一振动传感器获取的 OLTC 振动信号进行特征分析,对测点位置的选取要求高且涵盖的设备状态信息有限。如何获取 OLTC 多个测点处振动信号所包含的特征参数并探索 OLTC 机械故障的高效诊断方法,仍有待研究。

张量是多维数据表示形式之一,是标量、向量及矩阵的一种高阶延拓,具有强大的数据表示能力和特征提取能力,已被成功应用于文本、视频图像、脑电信号、金融时序预测等领域^[19-21]。为更加全面有效地获取振动信号所包含的 OLTC 机械状态信息,文中从 OLTC 振动信号的高维相空间分布和深度学习网络优异的分类性能出发,尝试对 OLTC 多个振动测点处的振动信号相空间分布进行张量化表示并提取其核心张量,据此构建基于卷积神经网络(convolutional neural network, CNN)的 OLTC 机械故障诊断模型。最后以应用较多的某 CM 型 OLTC

收稿日期:2022-12-05;修回日期:2023-02-07

基金项目:国家重点研发计划资助项目(2019YFE0102900)

模型为测试对象,通过获取的振动信号验证文中所提方法及模型的有效性。

1 OLTC 振动信号相空间分布的张量化表示及其分解

1.1 相空间重构

若把一个时间序列看成是由一个确定性的非线性动力学系统产生的,则根据相空间重构理论,可把具备混沌特征的时间序列重建为一个等价的状态空间,从而挖掘其演化规律^[22]。根据 Takens 定理,只要重构相空间的嵌入维数 m 满足 $m \geq 2D + 1$ (D 为动力学系统的维数),则基于该嵌入维数所构造的高维系统的吸引子会在拓扑、几何结构和动力学特性等方面与原动力学系统完全相同,从而为混沌时间序列的高维空间特征提取提供重要的理论依据。

对时间序列 $\{x(i)\} (i = 1, 2, \dots, N)$, 其重构相空间 X 可表示为:

$$\begin{cases} X(1) = \{x(1), x(1 + \tau), \dots, x(1 + (m - 1)\tau)\} \\ X(2) = \{x(2), x(2 + \tau), \dots, x(2 + (m - 1)\tau)\} \\ \vdots \\ X(K) = \{x(K), x(K + \tau), \dots, x(K + (m - 1)\tau)\} \end{cases} \quad (1)$$

式中: τ 为延迟时间; $K = N - (m - 1)\tau$, 为相空间相点数目, N 为时间序列长度。

参数 m 和 τ 是对一维时间序列进行高维空间重构的关键,文中根据 OLTC 档位切换时振动信号的非平稳性和强时变特征,选用时间复杂度相对较低的 C-C 法对这 2 个参数进行计算^[23]。

1.2 重构相空间的张量化

张量的本质是高阶数组或高阶阵列,通常使用 $\mathbf{A} \in \mathbf{R}^{I_1 \times I_2 \times \dots \times I_N}$ 表示一个 N 阶张量。其中,张量的模 n 展开是将张量表示变换成矩阵的常用分析方法,张量 $\mathbf{A} \in \mathbf{R}^{I_1 \times I_2 \times \dots \times I_N}$ 的模 n 展开运算($n = 1, 2, \dots, N$)^[23] 可表示为:

$$f_n(\mathbf{A}) = \mathbf{A}_{(n)} \in \mathbf{R}^{I_n \times (I_1 \times \dots \times I_{n-1} \times I_{n+1} \times \dots \times I_N)} \quad (2)$$

式中: $\mathbf{A}_{(n)}$ 为张量 \mathbf{A} 经由模 n 展开得到的矩阵。

对式(1)所示的由 K 个相点组成的相空间,因每个相点具有 m 维数据,即数据规格为 $K \times m$,故可将相空间 X 表示为一个阶数为 2、规格为 $K \times m$ 的张量,其第一阶表示相空间相点数目,第二阶表示相空间相点维数。

针对 OLTC 一次档位切换时的振动信号,通常会使用多个振动加速度传感器进行测试。若记 P 个测点处的振动信号分别为 S_1, S_2, \dots, S_P , 为保证

OLTC 多个振动测点处重构相空间维度的一致性,及相空间重构信息的完整性,取联合重构相空间的延迟时间 τ 和嵌入维数 m 分别为 $\min(\tau_c)$ 和 $\max(m_c)$ ($c = 1, 2, \dots, P$), 则经式(1)重建各个振动测点处的相空间后可得到 P 个二阶张量。以测点数为第三阶坐标与上述二阶张量进行组合,可构建包含所有测点振动信号信息的相空间三阶张量,记为 $\mathbf{A}_X \in \mathbf{R}^{I_1 \times I_2 \times \dots \times I_N}$, 图 1 为这一过程的示意图。




图 1 多振动测点相空间三阶张量的构造过程

Fig.1 Construction process of phase space three-order tensor of multi measure points of vibration signals

显然,三阶张量 \mathbf{A}_X 中包含了 OLTC 一次档位切换过程中所有振动测点的动力学信息,据此可进一步对 OLTC 的机械状态进行分析。但是,受到 OLTC 切换开关动作时间及采样频率等影响,基于 OLTC 振动信号相空间分布所构建的三阶张量的数据规模较大,普通计算机处理该类数据时间成本较高,故文中将图 1 所示三阶张量作为原始张量样本,提取其核心张量以表征 OLTC 机械状态的特征信息。

1.3 基于 Tucker 分解的相空间核心张量提取

Tucker 算法是目前使用较为普遍的张量分解算法,一个 N 阶张量 $\mathbf{A} \in \mathbf{R}^{I_1 \times I_2 \times \dots \times I_N}$ 的 Tucker 分解结果可表示为:

$$\mathbf{A} \approx \mathbf{G} \times_1 \mathbf{U}^{(1)} \times_2 \mathbf{U}^{(2)} \times_3 \dots \times_N \mathbf{U}^{(N)} \quad (3)$$

式中: $\times_n (n = 1, 2, \dots, N)$ 为张量的模 n 乘积运算符; \mathbf{G} 为 Tucker 张量分解后得到的核心张量; $\mathbf{U}^{(1)}, \mathbf{U}^{(2)}, \dots, \mathbf{U}^{(N)}$ 为对应阶的投影矩阵。

此处,核心张量可视为原始张量去除冗余之后的主成分张量,相应的正交投影矩阵则可看作是各个阶上的主元^[18]。

对三阶张量 $\mathbf{A} \in \mathbf{R}^{I_1 \times I_2 \times I_3}$ 进行 Tucker 分解时的目标函数为:

$$\arg \min_{\mathbf{G}, \mathbf{U}^{(n)}} \|\mathbf{A} - \mathbf{G} \times_1 \mathbf{U}^{(1)} \times_2 \mathbf{U}^{(2)} \times_3 \mathbf{U}^{(3)}\|^2 \quad (4)$$

通常使用高阶正交迭代法进行求解^[18],具体步骤如下。

(1) 初始化。对各投影矩阵 $\mathbf{U}^{(n)} (n = 1, 2, 3)$ 进

行随机初始化,记为 $U_k^{(n)} (k=0)$, k 为步长。

(2) 更新投影矩阵。令 $k = k + 1$, 执行以下运算:

$$B_k = A \times_1 U_{k-1}^{(1)T} \times_2 U_{k-1}^{(2)T} \times_3 U_{k-1}^{(3)T} \quad (5)$$

然后对 B_k 的模 n 展开矩阵 $B_k^{(n)}$ 进行奇异值分解,得到 $B_k^{(n)} = UDV^T$ (U 、 V 分别为左奇异值矩阵和右奇异值矩阵; D 为 $B_k^{(n)}$ 的奇异值矩阵), 并令 $U_k^{(n)} = U$ 。

(3) 核心张量计算。对应的计算公式为:

$$G_k = A \times_1 U_k^{(1)T} \times_2 U_k^{(2)T} \times_3 U_k^{(3)T} \quad (6)$$

(4) 收敛判断。若满足收敛条件 $\|G_k - G_{k-1}\| < \varepsilon$ (ε 为预设的收敛阈值), 则进行步骤(5), 否则返回步骤(2)继续进行迭代。

(5) 输出核心张量 G 与投影矩阵 $U^{(1)}$ 、 $U^{(2)}$ 和 $U^{(3)}$ 。

2 基于 CNN 的 OLTC 故障诊断模型

CNN 是由生物视觉系统演化而来的一种前馈型人工神经网络,已在目标检测、语音及图像识别等领域取得良好应用效果,也是在张量形式数据领域中使用最为广泛的模式识别方法之一^[24-26]。其在训练过程中采用权值共享及池化等方式,能够有效降低算法复杂度,从而高效地从输入样本中提取相应特征。

CNN 主要由卷积层、池化层以及全连接层等组成。针对 CNN 的输入数据样本,卷积层利用卷积核对其进行卷积运算,并经由激活函数得到输出特征参数。若记 CNN 中第 i 层的输出特征参数为 Z_i , 则卷积层的运算过程可表示为:

$$Z_i = \varphi(Z_{i-1} \otimes F_i + b_i) \quad (7)$$

式中: \otimes 表示卷积运算; F_i 为第 i 层所使用卷积核的权值矩阵; b_i 为第 i 层的偏置向量; $\varphi(\cdot)$ 为激活函数。常用激活函数 ReLU 可以显著提高训练过程的收敛速度,且函数中不存在饱和区域,能够避免在训练中出现“梯度消失”现象^[21]。

池化层可将卷积层输出的一定范围内的特征参数收集至一个特征之中,用以降低数据处理量并保留有用信息,其计算过程可表示为:

$$Z_i = \text{pooling}(Z_{i-1}) \quad (8)$$

式中: $\text{pooling}(\cdot)$ 代表池化运算。此处,最大值池化方式对输入的数据样本的稀疏特征更为敏感,故应用较为普遍^[26]。

全连接层是将池化层输出的数据进行加权求和,然后通过激活函数对其进行非线性变换,其计算过程可表示为:

$$Z_i = \varphi(w_i Z_{i-1} + b_i) \quad (9)$$

式中: w_i 为全连接层的权重。

CNN 训练是计算网络输出和目标之间的误差过程,目的是最小化损失函数。常用的优化方法为梯度下降算法,即计算残差通过梯度下降进行反向传播,逐层更新 CNN 中的参数,主要包括均方根传递算法、带动量的梯度下降算法、自适应动量 (adaptive momentum, Adam) 算法等^[27],文中在 CNN 的训练过程中引入了 Adam 算法以提高训练效率。综上,可获取基于相空间张量分解的 OLTC 机械故障智能诊断流程,如图 2 所示。

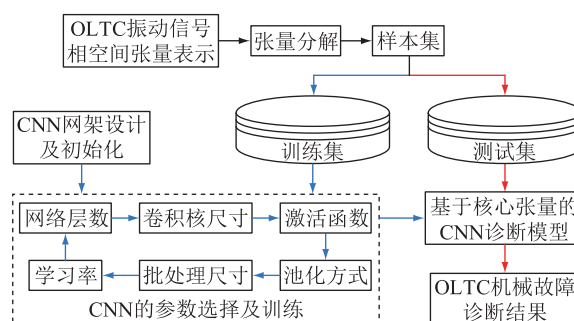


图 2 OLTC 机械故障诊断流程

Fig.2 Flow chart of mechanical fault recognition of OLTC

3 OLTC 振动特性测试

选取变电站现场应用较多的某 CM 型 OLTC 样机为对象,对其不同机械状态下档位切换时的壳体振动信号进行测试。其中,由选择开关和切换开关等组成的 OLTC 芯子与实际产品一致,被放置于小油箱中模拟实际变压器 OLTC 的切换特性;振动信号使用放置于 OLTC 头盖上的 6 个振动加速度传感器进行测试,其灵敏度为 $10 \text{ mV/g} (1 \text{ g} = 9.8 \text{ m/s}^2)$, 振动信号的采样频率为 50 kHz , 如图 3 所示。




图 3 振动加速度传感器放置位置

Fig.3 Position of acceleration vibration sensors

依据现场 OLTC 典型故障的统计结果,主要对出现频率较高的储能弹簧磨损、静触头松动及软连接松动故障进行模拟,如图 4 所示。其中,储能弹簧力下降是通过砂轮磨断 OLTC 弹簧仓内部的储能弹

簧端部实现,记为故障1;静触头松动是将 OLTC 的 A 相弧形板上的静触头拧松一个螺丝环,记为故障2,松动部位为图 4(b)中红色部分的紧固螺栓;软连接松动通过拧松软连接的紧固螺栓实现,记为故障3。




图4 OLTC 典型机械故障模拟

Fig.4 Typical mechanical fault simulation of OLTC

限于篇幅,以图3中测点2处的振动信号为例给出测试结果,对应于 OLTC 第3—4档切换的情形,如图5所示。由图5可知,OLTC 振动信号为呈现非平稳特征的强时变时间序列,包括多个幅值不同的时变脉冲,持续时间与 OLTC 内部切换开关的机械动作时间接近。当 OLTC 切换开关出现典型机械缺陷时,虽然可以完成正常的档位切换过程,但对应的振动信号的幅值、不同时变脉冲对应的峰值时刻等主要参数均出现了程度不同的变化。文中借助相空间重构与张量分解,从高维空间中提取 OLTC 振动信号特征参数,实现 OLTC 不同机械状态的有效区分。




图5 OLTC 不同机械状态下的振动信号

Fig.5 Vibration signals of OLTC with different mechanical states

4 OLTC 故障诊断结果

4.1 振动信号相空间的张量分解结果

在对获取的 OLTC 振动信号进行相空间重构时,首先计算延迟时间与嵌入维数。文中依据 C-C 法进行计算,仍以第3—4档切换时振动信号的计算

结果为例,结果如表1所示。据此可对 OLTC 多个测点处振动信号的相空间进行张量表示,以获取 OLTC 振动信号的相空间三阶张量。

表1 振动信号的延迟时间与嵌入维数

Table 1 Delay time and embedding dimension of vibration signals

测点	正常		故障1		故障2		故障3	
	τ	m	τ	m	τ	m	τ	m
1	21	4	18	4	20	4	20	4
2	22	4	19	4	19	4	21	4
3	22	4	20	4	19	4	22	4
4	21	4	18	4	20	4	21	4
5	20	4	17	4	21	4	20	4
6	22	4	18	4	19	4	21	4
重构参数	20	4	17	4	19	4	20	4

图6为所构建的 OLTC 振动信号相空间三阶张量经 Tucker 分解所得的核心张量,对应于 OLTC 正常状态。图中,3个坐标轴分别对应核心张量的不同数据阶数,并以灰度值的形式呈现各个坐标上的数据点数值。由图可见,相空间三阶张量经 Tucker 分解所得的核心张量依然为三阶张量,但其维数已由分解前的 $\mathbf{A} \in \mathbf{R}^{440 \times 4 \times 6}$ 变化为 $\mathbf{G} \in \mathbf{R}^{4 \times 4 \times 4}$,为3个阶数为2、数据规模为 4×4 的张量,极大降低了特征张量的数据规模。另外,图中数据点的色域以右侧色谱柱上0值对应的中灰度为主,仅在局部出现了少量接近白色或黑色的数据点,对应核心张量中的数值尖峰。




图6 OLTC 第3—4档切换时的振动信号核心张量

Fig.6 Core tensor of vibration signal for tap position 3-4 of OLTC

图7为 OLTC 振动信号核心张量 \mathbf{G} 的模1展开向量 $\mathbf{V}^{(1)}$,包括 OLTC 正常状态与3种典型机械缺陷的情形。由图7可见,OLTC 振动信号核心张量的模1展开向量中多数数据点分布在零点附近,仅在少数位置出现数值尖峰,与图6所示的核心张量三维图像特征吻合良好。此外,OLTC 不同机械状态下的振动信号核心张量模1展开向量存在明显差

异。其中,故障 1 的数据曲线中部分数值相比于正常状态明显偏小,故障 2 与故障 3 的数据曲线虽与正常状态曲线幅值大致相当,但其数据尖峰出现的位置及极性等特征均发生了明显变化,表明 OLTC 振动信号核心张量对其不同机械状态下的振动信号具有良好的区分性。




图 7 OLTC 不同工况下第 3—4 档位切换时核心张量模 1 展开向量

Fig.7 Mode-1 unfolding vector of core tensor for tap position 3-4 of OLTC in different conditions

4.2 OLTC 故障诊断模型

依据标准 LeNet-5 的 CNN 模型建立 OLTC 的机械故障诊断模型^[23],具体结构如表 2 所示。训练时,须依据所构建的数据集对 CNN 的学习速率和批尺寸这 2 个训练参数进行调参,以寻求所构建的 OLTC 识别模型在训练时间、训练过程的稳定性及故障识别准确率等关键指标间的优化平衡。

表 2 OLTC 机械故障的智能诊断模型
Table 2 Intelligent recognition model of mechanical fault of OLTC

层数	层结构	层参数
0	输入层	分辨率 4×16
1	卷积层	卷积核:3×3,6 个; 池化方式:最大池化; 激活函数:ReLU
2	池化层	池化核:2×2; 池化方式:最大池化
3	卷积层	卷积核:3×3,16 个; 池化方式:最大池化; 激活函数:ReLU
4	池化层	池化核:2×2; 池化方式:最大池化
5	全连接层	神经元数:4; 激活函数:Softmax

以 OLTC 正常状态与 3 种典型机械缺陷下的振动信号核心张量的计算结果构建 CNN 的数据样本

集,共计 480 组。在 OLTC 的每种机械状态下中随机抽取 320 组数据样本构成训练集,余下的 120 组和 40 组数据样本分别作为测试集和验证集,据此实现 CNN 中学习速率和批尺寸的优化选取。文中主要基于 Adam 算法自适应选取学习率,具有收敛速度快,对内存需求小等优势^[23],可满足 OLTC 张量数据集的训练需求。

批尺寸为每次参数更新过程中投入网络的训练样本数量,过小会导致网络训练时间延长,且会在样本梯度中引入较强的随机性,影响收敛速度;而过大的批尺寸虽能够减少所有训练样本在网络中通过一个 Epoch 所需的迭代次数,但会降低模型的识别精度。一个 Epoch 表示神经网络学习中所有训练样本数据均被使用过一次时的更新次数。故文中针对所使用的 OLTC 张量数据集,选取 10 为批尺寸步长,计算 CNN 在不同批尺寸下的训练误差,从而选择最优的批尺寸,如图 8 所示。可见,随着 Epoch 数目的增加,网络的训练误差逐渐减少,最终收敛阶段的训练误差随批尺寸的减小而减小。




图 8 不同批尺寸的训练误差对比
Fig.8 Comparison of training errors in different batch sizes

表 3 为所构建的 CNN 模型在不同批尺寸下的训练时间及最终识别准确率。可见,当批尺寸超过 40 后,CNN 最终的识别准确率有所下降,且批尺寸为 40~60 时对应的网络均具有相对较低的训练时间。综合权衡训练成本与识别效果,选取批尺寸大小为 40。

表 3 不同批尺寸的 CNN 训练结果
Table 3 Training results of CNN with different batch sizes

批尺寸	训练时间/s	识别准确率/%
20	24.94	98.75
30	13.28	98.75
40	7.82	98.13
50	6.65	92.50
60	5.91	85.63

4.3 OLTC 机械故障诊断结果

图 9 为所构建的 CNN 的训练曲线。图中,一次迭代表示一个批尺寸单位,即 40 组数据的训练过程,对应网络的一次参数更新,每进行 8 次迭代完成一个 Epoch 的训练过程。为实时监测 CNN 在训练过程中对核心张量的识别性能变化,在每次迭代完成后均会使用当前网络结构对测试样本进行一次测试,计算结果如图 9 所示。可见,训练集与测试集 的识别准确率均随着 CNN 迭代次数的增加呈现先上升后稳定的趋势。其中,训练曲线在迭代次数较低时出现了多次准确率波动,而测试曲线的上升趋势较为平稳。在 Epoch3 训练完成后,2 条曲线的识别准确率均不再变化,表明网络已达到收敛。

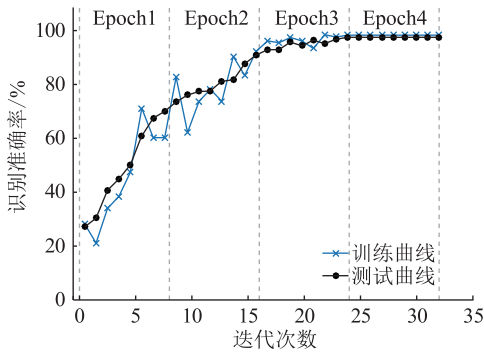


图 9 CNN 训练与测试曲线

Fig.9 Training and testing curves of CNN

图 10 为所构建的基于 CNN 的 OLTC 故障诊断模型针对验证集的计算结果,同时给出了直接将振动信号重构所得的相空间矩阵及使用测点 2 处振动信号重构所得的相空间矩阵送入相同结构的 CNN 进行训练的识别结果。

可见,文中提出的诊断模型对 OLTC 的不同机

样本实际状态	正常	39 97.5%	0 0%	0 0%	1 2.5%
	故障1	0 0%	40 100.0%	0 0%	0 0%
	故障2	1 2.5%	0 0%	39 97.5%	0 0%
	故障3	1 2.5%	0 0%	1 2.5%	38 95.0%
		正常	故障1	故障2	故障3

诊断模型识别结果
(a) 文中诊断模型

样本实际状态	正常	30 70.5%	1 2.5%	2 5.0%	7 17.5%
	故障1	1 2.5%	35 87.5%	4 10.0%	0 0%
	故障2	3 7.5%	4 10.0%	31 77.5%	2 5.0%
	故障3	9 22.5%	1 2.5%	2 5.0%	28 70.0%
		正常	故障1	故障2	故障3

诊断模型识别结果
(b) 基于相空间的诊断模型

样本实际状态	正常	32 80.0%	1 2.5%	2 5.0%	5 12.5%
	故障1	2 5.0%	35 87.5%	2 5.0%	1 2.5%
	故障2	3 7.5%	4 10.0%	32 80.0%	1 5.0%
	故障3	7 17.5%	1 2.5%	2 5.0%	30 75.0%
		正常	故障1	故障2	故障3

诊断模型识别结果
(c) 使用单一测点与相空间的诊断模型

图 10 OLTC 机械故障模型识别结果的混淆矩阵

Fig.10 Confusion matrix of recognition results of OLTC mechanical fault model

械故障类型均具有较高的识别准确度,总体平均识别准确率为 97.0%,明显优于基于相空间的诊断模型或使用单一测点与相空间的诊断模型。针对 OLTC 振动信号特征参数变化相对较为明显的故障 1,所构建的智能诊断模型的识别准确率达到 了 100%,表明其具有强大的特征参数捕捉能力与模式识别能力。显然,文中构建的 OLTC 机械故障智能诊断模型所采用的张量分解运算既提取了各测点信号的潜在关联信息,也去除了原始张量中的冗余信息,有效提升了故障诊断的准确率。

5 结论

文中基于涵盖 OLTC 多测点振动信号相空间分布的三阶张量表示及其 Tucker 张量分解结果,构建基于 CNN 的 OLTC 机械故障智能诊断模型,结果表明:

(1) 使用张量形式表示 OLTC 多个测点处振动信号重构所得相空间数据,可有效提升 OLTC 振动信号描述能力并获取更加全面的 OLTC 机械状态信息。

(2) OLTC 振动信号相空间核心张量在保留原始张量主要信息的同时,可对表示 OLTC 不同机械状态的特征参量进行区分性表征,且其数据规模远低于原始张量。

(3) 使用核心张量作为输入数据的 OLTC 机械故障诊断模型收敛速度快,识别准确率超过 95.0%,有助于及时发现 OLTC 的机械缺陷,为 OLTC 状态检修策略的制定提供重要参考依据。

致谢

本文得到国网浙江省电力有限公司科技项目(B311JH210005)资助,谨此致谢!

参考文献:

[1] 王蕾,袁洪跃,王季琴,等. 变压器有载分接开关技术和故障诊断发展现状及展望[J]. 高压电器,2022,58(3):171-180.
WANG Lei, YUAN Hongyue, WANG Jiqin, et al. Development

- status and prospect of transformer on-load tap-changer technology and fault diagnosis [J]. *High Voltage Apparatus*, 2022, 58(3):171-180.
- [2] 杨晓望,张丹丹,王珏,等. 基于信息融合和模糊理论的有载分接开关故障诊断[J]. *高压电器*, 2022, 58(10):143-148, 157.
YANG Xiaowang, ZHANG Dandan, WANG Jue, et al. Fault diagnosis of on-load tap changer based on information fusion and fuzzy theory [J]. *High Voltage Apparatus*, 2022, 58(10):143-148, 157.
- [3] 马勇,王树刚,王同磊,等. 基于驱动电机电流与振动信号的有载分接开关故障诊断方法[J]. *高压电器*, 2022, 58(5):202-210.
MA Yong, WANG Shugang, WANG Tonglei, et al. Fault diagnosis method for on-load tap changer based on driven motor current and vibration signal [J]. *High Voltage Apparatus*, 2022, 58(5):202-210.
- [4] 段若晨,王丰华,周荔丹. 基于优化 HHT 算法与洛仑兹信息量度的换流变用有载分接开关机械特征提取[J]. *中国电机工程学报*, 2016, 36(11):3101-3109.
DUAN Ruochen, WANG Fenghua, ZHOU Lidan. Mechanical features extraction of on-load tap-changer in converter transformer based on optimized HHT algorithm and Lorentz information measure [J]. *Proceedings of the CSEE*, 2016, 36(11):3101-3109.
- [5] 郑婧,何婷婷,郭洁,等. 基于独立成分分析和端点检测的变压器有载分接开关振动信号自适应分离[J]. *电网技术*, 2010, 34(11):208-213.
ZHENG Jing, HE Tingting, GUO Jie, et al. Adaptive separation of vibration signal of on-load tap changer based on independent component analysis and endpoint detection [J]. *Power System Technology*, 2010, 34(11):208-213.
- [6] KANG P, BIRTWISTLE D. Condition monitoring of power transformer on-load tap-changers. Part 1: automatic condition diagnostics [J]. *IEE Proceedings-Generation, Transmission and Distribution*, 2001, 148(4):301-306.
- [7] KANG P, BIRTWISTLE D. Condition monitoring of power transformer on-load tap-changers. Part 2: detection of ageing from vibration signatures [J]. *IEE Proceedings-Generation, Transmission and Distribution*, 2001, 148(4):307-311.
- [8] KANG P J, BIRTWISTLE D. Condition assessment of power transformer on-load tap changers using wavelet analysis and self-organizing map: field evaluation [J]. *IEEE Transactions on Power Delivery*, 2003, 18(1):78-84.
- [9] RIVAS E, BURGOS J C, GARCIA-PRADA J C. Condition assessment of power OLTC by vibration analysis using wavelet transform [J]. *IEEE Transactions on Power Delivery*, 2009, 24(2):687-694.
- [10] RIVAS E, BURGOS J C, GARCÍA-PRADA J C. Vibration analysis using envelope wavelet for detecting faults in the OLTC tap selector [J]. *IEEE Transactions on Power Delivery*, 2010, 25(3):1629-1636.
- [11] LIU J X, WANG G, ZHAO T, et al. Fault diagnosis of on-load tap-changer based on variational mode decomposition and relevance vector machine [J]. *Energies*, 2017, 10(7):946-959.
- [12] DUAN X M, ZHAO T, LI T, et al. Method for diagnosis of on-load tap changer based on wavelet theory and support vector machine [J]. *The Journal of Engineering*, 2017, 2017(13):2193-2197.
- [13] 陈明,马宏忠,徐艳,等. 基于改进掩膜信号优化的经验模态分解算法的有载分接开关机械故障诊断[J]. *智慧电力*, 2019, 47(6):88-94.
CHEN Ming, MA Hongzhong, XU Yan, et al. Mechanical fault diagnosis of on-load tap changer based on empirical mode decomposition algorithm for improved mask signal [J]. *Smart Power*, 2019, 47(6):88-94.
- [14] 钱国超,彭庆军,程志万,等. 基于参数自适应 VMD 和 SA-ELM 的有载分接开关故障诊断[J]. *电力工程技术*, 2020, 39(1):157-164.
QIAN Guochao, PENG Qingjun, CHENG Zhiwan, et al. Fault diagnosis of on-load tap-changer based on the parameter-adaptive VMD and SA-ELM [J]. *Electric Power Engineering Technology*, 2020, 39(1):157-164.
- [15] 赵彤,张黎,李庆民. OLTC 振动信号的多维空间相轨图几何特征[J]. *高电压技术*, 2007, 33(8):102-105.
ZHAO Tong, ZHANG Li, LI Qingmin. Feature analysis methodology for phase portrait structure of mechanical vibration signals of on-load tap changers in multidimensional space [J]. *High Voltage Engineering*, 2007, 33(8):102-105.
- [16] 赵彤,李庆民,陈平. OLTC 振动信号特征提取的动力学分析方法[J]. *电工技术学报*, 2007, 22(1):41-46.
ZHAO Tong, LI Qingmin, CHEN Ping. Dynamic analysis method for feature extraction of mechanical vibration signals of on-load tap changers [J]. *Transactions of China Electrotechnical Society*, 2007, 22(1):41-46.
- [17] LI Q M, ZHAO T, ZHANG L, et al. Mechanical fault diagnosis of on-load tap changer within power transformers based on hidden Markov model [J]. *IEEE Transactions on Power Delivery*, 2012, 27(2):596-601.
- [18] 周翔,王丰华,傅坚,等. 基于混沌理论和 K-means 聚类的有载分接开关机械状态监测[J]. *中国电机工程学报*, 2015, 35(6):1541-1548.
ZHOU Xiang, WANG Fenghua, FU Jian, et al. Mechanical condition monitoring of on-load tap changers based on chaos theory and K-means clustering method [J]. *Proceedings of the CSEE*, 2015, 35(6):1541-1548.
- [19] 邹本友,李翠平,谭力文,等. 基于用户信任和张量分解的社会网络推荐[J]. *软件学报*, 2014, 25(12):2852-2864.
ZOU Benyou, LI Cuiping, TAN Liwen, et al. Social recommendations based on user trust and tensor factorization [J]. *Journal of Software*, 2014, 25(12):2852-2864.
- [20] LIU Y Y, SHANG F H, FAN W, et al. Generalized higher order orthogonal iteration for tensor learning and decomposition [J]. *IEEE Transactions on Neural Networks and Learning Systems*,

- 2016, 27(12):2551-2563.
- [21] 李大舟,于锦涛,高巍,等. 融合延迟变换和张量分解的金融时序预测算法[J]. 计算机工程与设计, 2022, 43(5): 1295-1303.
LI Dazhou, YU Jintao, GAO Wei, et al. Financial timing prediction algorithm fusing delay transform and tensor decomposition[J]. Computer Engineering and Design, 2022, 43(5): 1295-1303.
- [22] 谢全民,贾永胜,丁凯,等. 隧道爆破振动信号的混沌特征分析[J]. 振动与冲击, 2022, 41(3):238-244, 306.
XIE Quanmin, JIA Yongsheng, DING Kai, et al. Chaotic characteristics analysis of tunnel blasting vibration signals [J]. Journal of Vibration and Shock, 2022, 41(3):238-244, 306.
- [23] 齐波,张鹏,荣智海,等. 基于相空间重构的变压器油色谱数据最优长度选择方法[J]. 中国电机工程学报, 2018, 38(8):2504-2512, 2560.
QI Bo, ZHANG Peng, RONG Zhihai, et al. Optimal length selection method of DGA data based on phase space reconstruction[J]. Proceedings of the CSEE, 2018, 38(8):2504-2512, 2560.
- [24] 杨秀,胡钟毓,田英杰,等. 基于关注指标和深度学习的台区配变重过载预警方法研究[J]. 智慧电力, 2021, 49(4): 66-74.
YANG Xiu, HU Zhongyu, TIAN Yingjie, et al. Research on early warning method of substation distribution transformer overload based on attention index and deep learning[J]. Smart Power, 2021, 49(4):66-74.
- [25] 徐龙飞,张磊,郁进明. 基于改进的 CNN 语音识别研究[J]. 计算机应用与软件, 2022, 39(1):119-125.
XU Longfei, ZHANG Lei, YU Jinming. Research of speech recognition based on improved CNN[J]. Computer Applications and Software, 2022, 39(1):119-125.
- [26] 徐舒玮,邱才明,张东霞,等. 基于深度学习的输电线路故障类型辨识[J]. 中国电机工程学报, 2019, 39(1):65-74, 321.
XU Shuwei, QIU Caiming, ZHANG Dongxia, et al. A deep learning approach for fault type identification of transmission line[J]. Proceedings of the CSEE, 2019, 39(1):65-74, 321.
- [27] 吴子斌,闫巧. 基于动量的映射式梯度下降算法[J]. 计算机科学, 2022, 49(S1):178-183.
WU Zibin, YAN Qiao. Projected gradient descent algorithm with momentum[J]. Computer Science, 2022, 49(S1):178-183.

作者简介:



陈文通

陈文通(1984),男,硕士,高级工程师,从事电力系统运行工作(E-mail:17772228@qq.com);

盛骏(1983),男,硕士,高级工程师,从事电力设备管理工作;

钱肖(1971),男,硕士,高级工程师,从事电力系统运行工作。

Intelligent diagnosis of mechanical fault of on-load tap-changer based on tensor decomposition in phase space

CHEN Wentong¹, SHENG Jun¹, QIAN Xiao¹, WU Xuefeng¹, WANG Fenghua²

(1. Jinhua Power Supply Company of State Grid Zhejiang Electric Power Co., Ltd., Jinhua 321000, China;

2. Shanghai Jiao Tong University (Key Laboratory of Control of Power Transmission and Conversion, Ministry of Education), Shanghai 200240, China)

Abstract: Vibration signals associated with on-load tap-changer (OLTC) gear switching is closely related to its mechanical state. Based on the high-dimensional phase point spatial distribution of the vibration signal of OLTC, the vibration signals at multiple positions of OLTC are represented by tensor quantization to capture as rich as possible the mechanical status information of OLTC. Then, the third order tensor in the phase space is decomposed into Tucker tensor to obtain the core tensor, and a discriminative model of OLTC mechanical fault based on convolutional neural network is established. Taking the vibration signal of a certain CM type OLTC as an example for analysis, the results show that the phase space core tensor information of the vibration signal of OLTC is comprehensive and less redundant when the OLTC acts. The mechanical fault diagnosis model based on the convolutional neural network has good performance, with an accuracy rate of more than 95%, which can provide a reference for fault identification and condition maintenance of OLTC.

Keywords: on-load tap-changer; vibration signal; fault diagnosis; phase space reconstruction; tensor decomposition; convolutional neural network

(编辑 方晶)