

# 基于轻量 AlexNet 的电容型电压互感器故障诊断

漆梓渊<sup>1</sup>, 吴浩<sup>1</sup>, 陈伟哲<sup>1</sup>, 罗春兰<sup>1</sup>, 吴杰<sup>2</sup>

(1. 四川轻化工大学自动化与信息工程学院, 四川 宜宾 644002;

2. 国网四川省电力公司电力科学研究院, 四川 成都 610041)

**摘要:** 电容型电压互感器 (CVT) 是重要的一次侧电压监测元件。针对环境温度、湿度以及元件老化等因素造成的电容型电压互感器一次侧电容上下臂击穿或互感器二次侧短路等故障, 提出了一种基于轻量 AlexNet 的电容型电压互感器故障诊断方法。该方法利用 Matlab 建立了 CVT 电路模型, 分别对高压臂电容击穿、低压臂电容击穿以及互感器二次侧短路 3 种典型的故障进行仿真。采集 CVT 二次侧电压数据, 利用马尔可夫变迁场将其转化为特征矩阵, 最后使用轻量化的 AlexNet 神经网络对电压特征矩阵进行故障分类。仿真实验证明, 所提方法在不拆除 CVT 的情况下, 能准确检测出 CVT 的故障类型。

**关键词:** 电容型电压互感器; 特征提取; AlexNet 神经网络; 故障诊断

**中图分类号:** TM 451 **文献标志码:** A **文章编号:** 1003-6954(2024)01-0091-07

**DOI:** 10.16527/j.issn.1003-6954.20240114

## Lightweight AlexNet-based Fault Diagnosis for Capacitor Voltage Transformers

QI Ziyuan<sup>1</sup>, WU Hao<sup>1</sup>, CHEN Weizhe<sup>1</sup>, LUO Chunlan<sup>1</sup>, WU Jie<sup>2</sup>

(1. School of Automation and Information Engineering, Sichuan University of Science&Engineering,

Yibin 644002. Sichuan, China; 2. State Grid Sichuan Electric Power Research Institute,

Chengdu 610041, Sichuan, China)

**Abstract:** Capacitor voltage transformers (CVT) are important primary voltage monitoring components, but due to the influence of ambient temperature, humidity, aging of the components and other factors caused by capacitor upper and lower arm breakdown in primary side of capacitor voltage transformer and short circuit in secondary side of the transformer and other faults, a light-weight AlexNet-based fault diagnosis method for capacitor voltage transformer is proposed. This method uses Matlab to build a CVT circuit model and simulates three typical faults, namely, capacitance breakdown of high-voltage arm, capacitance breakdown of low-voltage arm and short circuit in secondary side of the transformer. The voltage data in secondary side of CVT are collected and transformed into feature matrices using Markov transition fields. Finally the voltage feature matrices are classified into faults using a light-weight AlexNet neural network. The simulation experiments prove that the proposed method can accurately detect the fault type of CVT without removing the CVT.

**Key words:** capacitor voltage transformer; feature extraction; AlexNet neural network; fault diagnosis

## 0 引言

由于电容型电压互感器 (capacitor voltage

transformers, CVT) 在长时间运行过程中会受到环境的影响, 容易出现各种故障。当 CVT 一次侧发生故障时, 二次侧的监测电压将会传递错误电压信号到继电保护装置, 造成保护的误动作; 同时, CVT 的二次侧发生短路, 继电保护装置将不能检测到一次侧线路的故障电压, 保护装置将不会动作, 导致电网瘫

**基金项目:** 四川省科技厅项目 (2022YFS0518, 2022ZHCG0035); 人工智能四川省重点实验室项目 (2020RZY03)

痪。因此,对电容型电压互感器的故障及时进行检测并准确判断故障类型有助于电力系统安全运行。

文献[1]将有故障的 CVT 进行拆除,使用电桥平衡法分别测量 CVT 绝缘电阻、电容量以及介质损耗进行综合判断诊断出故障。文献[2]通过对故障 CVT 进行解体,发现其内部的中压变压器受潮进水,导致了绕组间短路,从而引起了 CVT 单相失压。文献[3]通过解体 CVT 的方式测量电容并分析 A 相与 C 相的高压臂电容故障,提出检测 CVT 二次侧电压波动取值范围对一次侧故障进行判断。文献[4]通过解体 CVT,诊断出 CVT 一次绕组高压端的断点故障。文献[5]通过 CVT 的诊断实验与解体检查,诊断出 CVT 低压臂电容的击穿故障。文献[6]与文献[7]提出在不拆高压接引线的情况下,使用等变比测试与穿心电流互感器相减的方式,测试电桥平衡,但是测试的前提也是将 CVT 解体。文献[8]引入了机器学习中 K-means 聚类算法,使用滑动时窗法进行数据的扩展,通过测量故障时 CVT 二次侧异常电压的不同突变情况判断电容的击穿类型。

虽然上述算法能对电容型电压互感器的故障进行检测,但需要对设备拆解,才能进一步确定故障发生的位置,这需要耗费大量的物力财力。所以下面提出了一种基于轻量 AlexNe 神经网络的 CVT 故障诊断方法,在不对电容型电压互感器拆解的情况下,利用故障发生时 CVT 二次侧的异常电压进行故障类型的判断。

## 1 CVT 建模与数据采集

### 1.1 CVT 模型建立

根据 CVT 的结构以及工作原理<sup>[9]</sup>,使用 Matlab 对 220 kV 的 CVT 进行建模,如图 1 所示。

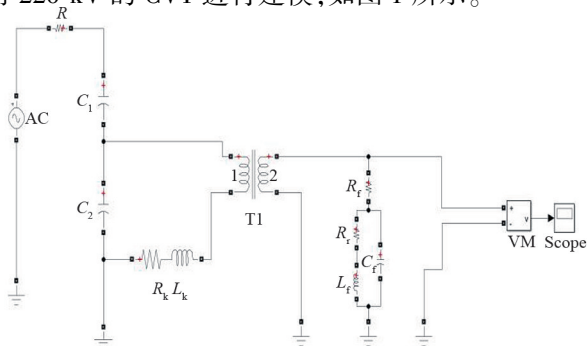


图 1 CVT 仿真模型

CVT 的故障可以分为高压臂电容击穿故障、低压臂电容击穿故障、二次侧短路故障,利用所建模型对这 3 种故障进行仿真。当电容击穿故障后电容值将减小,使用电容值很小的  $C_{break}$  代表击穿后的电容;在进行故障仿真时,用开关控制不同种类故障接入,开关的控制方式设置为高电平开关触发、低电平开关关断。

1) 模拟高压臂电容  $C_1$  击穿故障:闭合连接击穿电容  $C_{break}$  的开关,同时断开电容  $C_1$  的开关,击穿电容  $C_{break}$  将会接入运行。

2) 模拟低压臂  $C_2$  电容击穿故障:开关会断开电容  $C_2$ ,击穿电容  $C_{break}$  的开关关闭,接入击穿电容  $C_{break}$ 。

3) 模拟二次侧发生短路故障:二次侧的故障开关直接闭合,二次侧电压直接接地。

### 1.2 仿真结果分析与数据采集

以图 1 所示 CVT 仿真模型为对象,设置系统频率为 50 Hz,总仿真时间为 0.5 s,在 0.25 s 时施加击穿故障,仿真结果如图 2 所示:无故障时 CVT 二次侧的电压值稳定在 CVT 的检测范围;当高压臂电容  $C_1$  击穿时,由于电容  $C_1$  减小,分压比公式的分子分母同时减小,二次侧电压也会减小,仿真波形与理论分析的二次侧电压相符;当低压臂  $C_2$  击穿时,由于电容  $C_2$  减小,分压比公式的分母减小,二次侧电压会增大,仿真波形也与理论分析相同;当在 CVT 的二次侧设置短路故障时,二次侧的电压为 0。

设置采样频率为 100 kHz,采集 3 种故障的二次侧电压值作为数据样本,每组数据样本包含二次侧电压故障前 0.01 s 至故障后 0.03 s 时域内的电压值;在不同时刻设置故障并采集数据样本,故障间隔时间为  $10^{-5}$  s,针对每种故障采集 1000 组二次侧故障电压数据样本,3 种故障共计 3000 组数据样本。以编码的形式对 3 种 CVT 异常工作状态进行标注。随机在每种故障的 1000 组数据样本中选取 100 组构成测试集。训练集数据样本数共计 2700 组,测试集数据样本数共计 300 组,表 1 为实验数据集组成。

表 1 实验数据集描述

CVT 工作状态	训练集样本数	测试集样本数	标签
$C_1$ 击穿故障	900	100	1
$C_2$ 击穿故障	900	100	2
二次侧短路故障	900	100	3

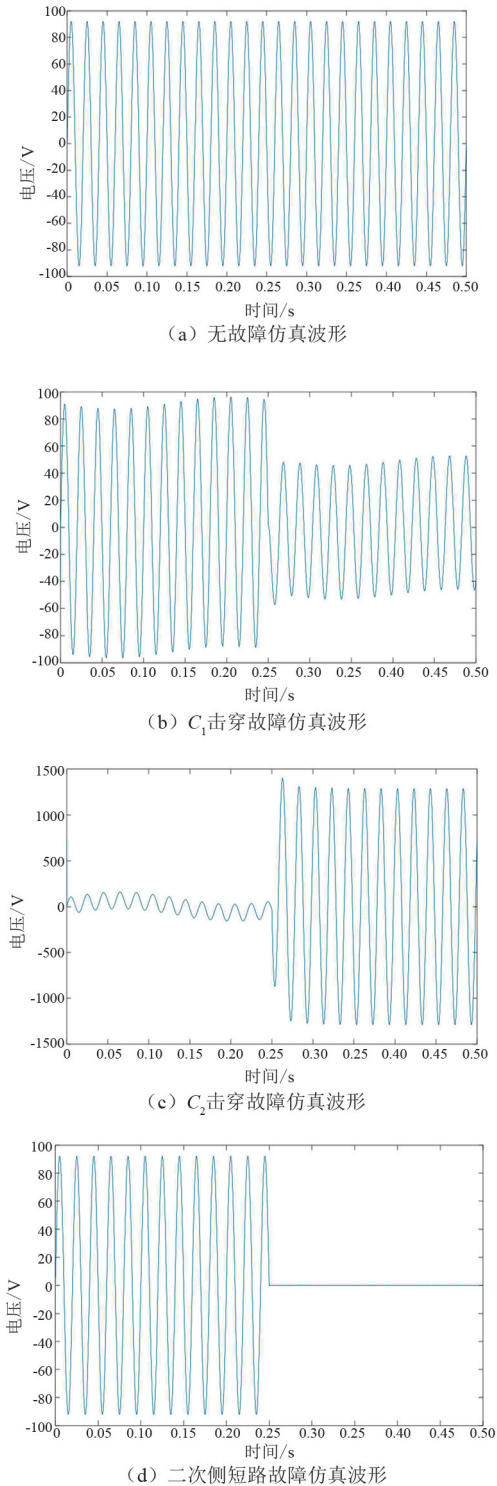


图 2 模型仿真结果

## 2 马尔科夫变迁场算法

马尔科夫变迁场 (Markov transition field, MTF) 是基于 1 阶马尔科夫链的分析时间序列的一种方法,MTF 可以完成时间序列成像功能,其主要的作用是将原本的时间序列信号用矩阵的形式

进行表示。

首先,将时间序列信号进行离散化,将信号离散的过程称为马尔可夫过程,也称马氏链,离散后的信号用  $X(m)$  表示,离散后的时间序列长度为  $N$ ,如式(1)所示;按照离散信号的长度,根据时间序列的范围划分成  $Q$  个区域,如式(2)所示,将离散信号中的每个数据点的  $q_Q$  相关联。

$$X_m = \{X(m), m = 1, 2, \dots, N\} \quad (1)$$

式中: $X_m$ 为连续的离散信号; $X(m)$ 为离散信号在  $m$  时刻对应函数值。

$$q_Q = \{q(k), k = 1, 2, \dots, Q\} \quad (2)$$

式中: $q_Q$ 为总的信号区域划分值; $q(k)$ 为信号区域  $k$  的划分值。

将马尔可夫性质用条件概率表示为式(3),含义为  $m$  时刻离散信号的离散值处于状态  $a(k)$  的条件下,离散信号在  $m+n$  时刻的离散值转移到  $q(j)$  的概率值。

$$P_{kj}(m, m+n) =$$

$$P[X(m+n) = q(j) | X(m) = q(k)] \quad (3)$$

式中, $q(k)$ 与  $q(j)$ 分别为  $k, j$  的信号区域的划分值。

由于马氏链在时刻  $m$  从任何一个空间状态  $q(k)$  出发,到另一个时刻  $m+n$ ,是转移到  $q(1), q(2), \dots, q(j)$  等诸多空间状态中的一个,于是将式(3)进一步表示为式(4)。

$$\sum_{k,j} P_{kj}(m, m+n) = 1 \quad (4)$$

根据式(4)构建马尔可夫转移矩阵  $\mathbf{W}$ ,如式(5)所示。式(5)中每一行元素之和等于 1,矩阵的行、列数均为  $Q$ ,矩阵中的数据  $w_{kj}$ 表示  $q(k)$  中的数据与  $q(j)$  中的数据的转移概率,表示了信号  $X(m+n)$  属于  $q(j)$  条件下,信号  $X(m)$  属于  $q(k)$  的概率值。

$$\mathbf{W} = \begin{bmatrix} w_{11} & \cdots & w_{1j} & \cdots & w_{1Q} \\ \vdots & \ddots & & & \vdots \\ w_{k1} & & w_{kj} & & w_{kQ} \\ \vdots & & & \ddots & \vdots \\ w_{Q1} & \cdots & w_{Qj} & \cdots & w_{QQ} \end{bmatrix} \quad (5)$$


$$w_{kj} = P[X(m) \in q(k) | X(m+n) \in q(j)]$$

式中: $\mathbf{W}$ 为马尔可夫转移矩阵; $w_{kj}$ 为转移概率值。

通过沿时间顺序的方式将计算的每个跟随概率进行排列<sup>[15]</sup>,即可以构成马尔可夫变迁场矩阵  $\mathbf{M}$ 。

$$M = \begin{bmatrix} w_{kj} | x_1 \in q(k), x_1 \in q(j) \cdots w_{kj} | x_1 \in q(k), x_n \in q(j) \\ w_{kj} | x_2 \in q(k), x_1 \in q(j) \cdots w_{kj} | x_2 \in q(k), x_n \in q(j) \\ \vdots \quad \quad \quad \ddots \quad \quad \quad \vdots \\ w_{kj} | x_n \in q(k), x_1 \in q(j) \cdots w_{kj} | x_n \in q(k), x_n \in q(j) \end{bmatrix} \quad (6)$$


MTF 与格拉米角场类似,为提高数据的计算效率,减小矩阵  $M$  的大小,同时将矩阵  $M$  网格化,用平均值代替每个网格的子图。采集 CVT 不同故障的二次侧电压数据,该数据为时间序列信号,将其通过 MTF 进行特征变换后输出二维特征矩阵。利用 MTF 进行数据转换后,3 种故障的特征矩阵如图 3 所示。



(a)  $C_1$  击穿故障特征



(b)  $C_2$  击穿故障特征



(c) 二次测短路故障特征

图 3 3 种故障 MTF 特征

## 3 轻量 AlexNet 神经网络 CVT 故障诊断算法

### 3.1 AlexNet 神经网络

AlexNet 是 2017 年 ISLVR 2012 竞赛中取得冠军的神经网络,被应用于多个学科领域<sup>[11-16]</sup>。AlexNet 网络由 5 个卷积层、3 个池化层、3 个全连接层<sup>[17]</sup>组成,在网络的全连接层使用了 Dropout 技

术<sup>[18]</sup>,利用随机丢失神经元的方法在减少模型参数的同时防止在分类时出现过拟合。

AlexNet 网络所有的卷积层和全连接层都使用非线性的 Relu 激活函数。与 Sigmoid 激活函数相比,Relu 激活函数能使网络表达能力增强,该激活函数克服了梯度消失的问题,同时使网络计算速度加快。

AlexNet 网络中的池化层主要使用最大池化计算(Maxpool)进行特征浓缩,Maxpool 池化层的主要作用是进行特征融合与降维。池化核先将特征矩阵划分成不同区域,每个区域输出一个特征值<sup>[19]</sup>组成一个新的特征矩阵。

为了对故障进行分类,AlexNet 网络的最后 3 个卷积层使用全连接层对数据进行展平,将特征矩阵转换为特征向量方便进行网络的分类。AlexNet 神经网络的每层结构参数见表 2。

表 2 AlexNet 网络结构

网络计算层	卷积核尺寸	步长	通道
Conv1	11×11	4	96
Maxpool	3×3	2	96
Conv2	5×5	2	256
Maxpool	3×3	2	256
Conv3	3×3	1	384
Conv4	3×3	1	384
Conv5	3×3	1	384
Maxpool	3×3	2	256
Fc6			4096
Fc7			4096
Fc8			1000

### 3.2 AlexNet 网络改进方法

在保证检测精度的情况下,对 AlexNet 神经网络进行改进,将其引入 CVT 的隐形故障检测。改进 AlexNet 卷积神经网络的结构如图 4 所示。黑色立方体代表卷积层,每个卷积层先进行卷积计算,再使用激活函数;红色立方体代表最大池化层。首先输入图片为 3 通道的彩色图片,图片尺寸为 224×224×3,经过卷积核尺寸为 11×11 的卷积计算后,变成大小为 55×55×48 的特征矩阵,并执行 Relu 激活函数,在完成最大池化层计算后的特征矩阵大小为 27×27×48;接着使用卷积运算以调整特征通道,此时特征矩阵尺寸变为 27×27×128;将特征矩阵最大池化处理,其大小变为 13×13×128;紧接着进行的两次卷积运算

改变特征矩阵通道为 192, 再进行一次不改变特征矩阵高宽的卷积运算, 将通道变成 128; 进行一次最大池化计算和两次卷积计算后, 最后得到大小为  $1 \times 1 \times 3$  的特征矩阵。




图 4 改进 AlexNet 神经网络结构

轻量化 AlexNet 将每一个卷积层和池化层的卷积核个数都进行了减半计算。AlexNet 网络的最后 3 层为全连接神经网络, 第一、第二、第三个全连接层的输入分别是 4608、4096、4096。改进的算法将 3 个全连接层用 2 个卷积层进行替换, 卷积特征尺寸分别为  $3 \times 3 \times 64$  和  $1 \times 1 \times 3$ 。所改进网络的最后一个卷积层特征尺寸为  $1 \times 1 \times 3$ , 其中“3”代表最后的分类类别。将卷积计算后的  $1 \times 1 \times 3$  特征矩阵进行展平, 再经过 Softmax 归一化函数得到分类结果。与传统的 AlexNet 神经网络对比, 轻量 AlexNet 神经网络的网络体积大小只有 1.02 M, 能更加方便在嵌入式设备上部署。

改进后的网络包含 7 个卷积层和 3 个池化层, 取消网络中的全连接层, 将每一个卷积层和池化层的卷积核个数减半, 网络结构参数见表 3。

表 3 轻量 AlexNet 网络结构

网络计算层	卷积核尺寸	步长	通道
Maxpool	$3 \times 3$	2	48
Conv2	$5 \times 5$	2	128
Maxpool	$3 \times 3$	2	128
Conv3	$3 \times 3$	1	192
Conv4	$3 \times 3$	1	192
Conv5	$3 \times 3$	1	192
Maxpool	$3 \times 3$	2	128
Conv6	$3 \times 3$	2	64
Conv7	$3 \times 3$	1	3

### 3.3 故障诊断算法流程

在不拆除电压互感器的情况下, 以二次侧电压的变化情况作为故障检测依据。利用 CVT 模型分别进行高压臂电容  $C_1$  击穿故障、低压臂电容  $C_2$  击穿故障、二次侧短路故障 3 种故障的仿真, 采集这 3 种故障的二次侧电压数据, 将其进行 MFT 变换转换成特征矩阵, 再用这 3 种故障的特征矩阵数据对轻量化的 AlexNet 神经网络进行训练。通过训练好的轻量化 AlexNet 神经网络对 3 种故障的特征矩阵进行预测。算法流程如图 5 所示。

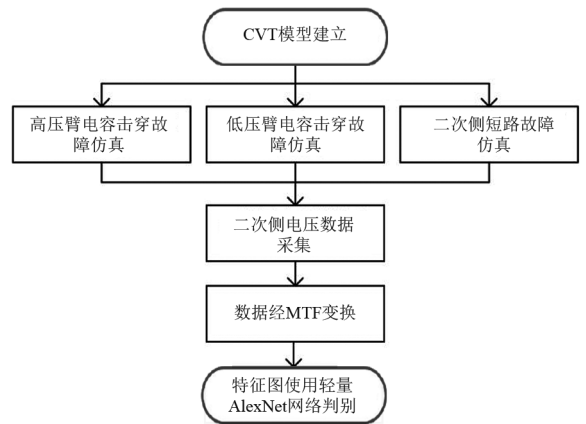



图 5 算法流程

## 4 仿真实验


### 4.1 网络训练与测试

实验的操作系统为 Windows10 专业版, 软件环境是 Pycharm, 编程语言使用 python3.7, 基于 1.10.1 版本的 pytorch 搭建深度学习框架。硬件配置 CPU (Intel Core i7 - 11800H)、GPU (NVIDIA RTX3060 8G)。训练与测试用的数据集包含 3 种故障共计 3000 组, 使用马尔可夫变迁场对数据进行转换, 将 3000 组数据转换为 3000 张特征矩阵图, 3000 组特征矩阵图中的 90% 划分为训练集 (train), 10% 划分为测试集 (test)。训练特征矩阵与测试特征矩阵随机裁剪尺寸到  $224 \times 224$ , 训练 100 轮 (epoch), 训练数据集的 batch\_size 设置为 32, 测试数据集的 batch\_size 设置为 4, 学习率 (learning rate) 设置为 0.000 2。训练网络前先初始化权重参数, 再使用训练集对权重参数进行调整, 最后使用测试集进行准确率测试。训练过程中的损失值和准确率的参数曲线如图 6 所示。所提改进算法最终损失值下降至 0.024 8 左右趋于平稳, 此时网络收敛, 训练集准确率达到

100%。训练结果说明,轻量 AlexNet 网络具有空间不变性,在网络训练中能对特征图进行空间变换突出有辨别能力的特征信息区域,可获取到更准确的特征表达,从而大大提高轻量 AlexNet 网络的学习效率,能更好地对 3 种故障进行分类。



(a) 训练模型准确率



(b) 训练模型损失值

图 6 训练参数曲线

## 4.2 实验结果分析

为了验证轻量 AlexNet 网络模型对 CVT 的 3 种经典故障识别性能,使用分类的精确率  $P$  作为网络性能的评判指标,如式(7)所示。

$$P = \frac{P_T}{P_T + P_F} \quad (7)$$

式中: $P_T$ 表示模型预测为真,标签也为真; $P_F$ 表示模型预测为真,标签为假。

分别使用 BP(back propagation)神经网络、K 最邻近(K-nearest neighbor, KNN)算法、贝叶斯分类算法与轻量 AlexNet 神经网络算法对 3 种故障的特征矩阵数据集样本进行故障的分类预测试验,预测结果如表 4 所示。


从表 4 分析可知,针对训练样本数据集,BP 神经网络相较于贝叶斯分类对  $C_1$  击穿故障和二次侧

短路故障的预测精确率有了提高,但是对于 3 种故障的预测精度还有欠缺。KNN 算法在 3 种故障的预测精确率能达到很高的精度,但是还是存在有错分的情况。所提轻量 AlexNet 对 3 种故障的预测精度均是 100%,不存在错分的情况。


针对测试样本数据集,BP 神经网络、KNN 算法、贝叶斯分类算法对 3 种故障的预测精确率下降,其中:BP 神经网络不能对二次侧短路故障进行识别;贝叶斯算法不能对  $C_2$  击穿故障进行预测。而轻量 AlexNet 并没有受数据集数目的影响,对 3 种故障的预测准确率依然保持 100%,不存在错分的情况。

综上,与传统的分类算法进行的对比实验表明,使用所提轻量 AlexNet 神经网络算法对 3 种故障预测,精确率都有显著的提升。相较于文献[8]使用的基于滑动时窗的 K-means 聚类算法,在故障类型的判别上,轻量 AlexNet 神经网络能对 CVT 发生二次短路的故障进行识别分类。

由于外界环境的不确定因素,在进行二次侧电压数据采集传输过程中,可能会发生数据丢失的情况。为测试所提算法在数据随机丢失情况下的性能,先对 3 种故障的一维二次侧电压数据进行随机丢失处理,以高压臂电容击穿故障后出现数据丢失情况为例进行仿真,如图 7 所示。



(a) 数据未丢失波形



(b) 数据丢失300个采样点

图 7 数据未丢失以及丢失情况下波形

表 4 不同网络预测准确率

单位:%

算法类型	训练数据样本分类预测准确率			测试数据样本分类预测准确率		
	$C_1$ 击穿故障	$C_2$ 击穿故障	二次侧短路	$C_1$ 击穿故障	$C_2$ 击穿故障	二次侧短路
所提算法	100	100	100	100	100	100
BP 神经网络	100	62	79	41	91	0
KNN 算法	99	100	99	87	97	93
贝叶斯分类	65	95	60	28	0	56

对3种故障随机选取5组一维电压数据进行测试,分别将数据随机丢失100个、200个、300个、400个,即每组数据丢失2.5%、5%、7.5%、10%。对数据丢失后的故障电压使用MTF特征变换,再使用轻量AlexNet网络对故障进行分类,测试结果见表5。可以看出即使存在10%的数据丢失,所提算法对3种故障均能进行准确的预测。

表5 所提方法随机丢失数据测试结果

数据丢失数量/个	分类准确率/%		
	C <sub>1</sub> 击穿故障	C <sub>2</sub> 击穿故障	二次侧短路
100	100	100	100
200	100	100	100
300	100	100	100
400	100	100	100

## 5 结论

针对传统的CVT故障检测时需将CVT进行解体等问题,提出了一种轻量AlexNet的CVT故障诊断方法。该方法先采集各类故障的二次侧电压数据,再对采集的一维数据使用马尔可夫变换提取特征,并将其转换成二维特征矩阵,最后使用轻量AlexNet网络进行故障的分类。在保证检测精度的情况下,将AlexNet网络的卷积层与池化层通道减半,将最后一层的全连接网络替换为卷积网络。经实验证明轻量AlexNet网络与原AlexNet网络相比,更适合进行嵌入式设备的移植;与传统的机器学习分类算法相比较,具有更高的检测精度。所提方法对CVT潜伏性故障的预测有积极的指导意义。

### 参考文献

[1] 郑云海. 110 kV 电容式电压互感器试验数据异常分析处理[J]. 电工技术, 2018(5): 116-117.

[2] 陈何成. 500 kV 电容式电压互感器故障原因分析[J]. 电工技术, 2020(17): 100-102.

[3] 刘永鑫, 王鹏皓, 李艳鹏, 等. 基于 CVT 电容元件击穿事故分析计算[J]. 电力电容器与无功补偿, 2014, 35(6): 77-80.

[4] 尹青华, 李培, 郭良峰, 等. 一起 66 kV 电容式电压互感器二次失压故障诊断分析[J]. 国网技术学院学报, 2020, 23(2): 4-6.

[5] 徐鹏, 殷鑑, 沈亚春, 等. 一起 220 kV CVT 二次电压异常事件调查[J]. 电力电容器与无功补偿, 2021, 42(5): 94-99.

[6] 周林波, 符玉珊, 文峰, 等. 110 kV 电容式电压互感器间接自激法不拆引线试验研究[J]. 科技风, 2021(10): 196-198.

[7] 赵铁羽. 220 kV 电容式电压互感器介损试验不拆线测量方法误差分析[J]. 变压器, 2019, 56(8): 57-59.

[8] 强文渊, 韦家富, 刘友波, 等. 基于滑动时窗 K-Means 聚类的 CVT 早期故障诊断[J]. 电力电容器与无功补偿, 2019, 40(3): 89-95.

[9] 马朝华. 电容式电压互感器暂态特性研究[D]. 郑州: 郑州大学, 2007.

[10] 姜家国, 郭曼利. 基于 MTF-DenseNet 的滚动轴承故障诊断[J]. 仪器仪表用户, 2021, 28(9): 54-56.

[11] 唐贵基, 田寅初, 田甜. 基于 AlexNet-Adaboost 的多工况滚动轴承故障识别方法[J]. 振动与冲击, 2022, 41(2): 20-25.

[12] 江华, 于同刚, 吴丽琼, 等. 基于 AlexNet 的桥小脑角脑膜瘤和听神经瘤 MRI 图像的识别研究[J]. 中国医疗器械信息, 2022, 28(1): 44-47.

[13] 徐兢成, 王丽华. 基于 AlexNet 网络的交通标志识别方法[J]. 无线电工程, 2022, 52(3): 470-475.

[14] 何江, 张科星. 基于机器视觉的 AlexNet 网络煤矸石检测系统[J]. 煤炭技术, 2022, 41(3): 205-208.

[15] 林丽惠, 魏毅, 潘俊虹. 基于卷积神经网络的武夷岩茶叶片分类方法[J]. 宁德师范学院学报(自然科学版), 2021, 33(4): 363-369.

[16] 院老虎, 陈源强, 杜白雨, 等. 基于 AlexNet 和迁移学习的滚动轴承故障诊断研究[J]. 机电工程, 2021, 38(8): 1016-1022.

[17] 丁维龙, 李涛, 丁潇, 等. 基于改进 AlexNet 的手腕骨图像成熟等级识别[J]. 浙江工业大学学报, 2021, 49(6): 614-622.

[18] 谢东阳, 李丽宏, 苗长胜. 基于改进 AlexNet 卷积神经网络的手写体数字识别[J]. 河北工程大学学报(自然科学版), 2021, 38(4): 102-106.

[19] 张振威, 王红成. 基于改进卷积神经网络及 SVM 的手写数字识别方法[J]. 东莞理工学院学报, 2021, 28(5): 57-61.

[20] 李辉. 基于改进 AlexNet 模型的断层识别方法[J]. 油气地质与采收率, 2022, 29(1): 107-112.

[21] 刘鹏, 谢春华, 安文韬, 等. 改进 AlexNet 的高分三号全极化海岛地物分类[J]. 遥感信息, 2021, 36(5): 142-147.

### 作者简介:

漆梓渊(1997), 男, 硕士研究生, 研究方向为电气设备状态监测;

吴浩(1980), 男, 博士, 教授, 研究方向为智能信息处理、电力系统及智能控制。

(收稿日期: 2023-06-17)