

[电气设备]

配电电气设备状态监测与故障诊断的智能化方法研究

文/张凤仪
国网辽阳供电公司

提出了一种智能化的方法，利用机器学习算法和人工智能技术建立精确的模型来分析实时数据，实现故障预警和诊断功能，从而最大程度减少故障对电力供应的影响。通过ELE-CNN网络进行配电电气设备的状态智能监测和故障诊断，取得了较好的效果。实验证明该网络在准确性和稳定性方面表现出色。

在现代社会中，电力供应对各行各业都起着至关重要的作用。然而，由于配电电气设备的长期运行和外部环境的影响，这些设备往往会发生故障，甚至导致停电事故的发生。因此，实时监测和快速诊断电气设备的状态和故障是保障电力供应稳定运行的重要任务。

目前，传统的配电电气设备状态监测和故障诊断方法主要依赖于人工巡检和定期维护，这种方式存在以下几个问题：一是人工巡检效率低下，无法及时获取设备运行信息；二是许多潜在的故障往往需要设备停机才能进行维修，给电力供应造成不必要的中断；三是传统方法仅依靠人员经验判断，容易出现误判或漏判。

本研究旨在探索一种智能化的方法来监测配电电气设备的状态，并能快速、准确地诊断设备的故障。利用机器学习算法和人工智能技术，建立精确的模型来分析大量实时数据，实现故障预警和诊断功能，以最大程度减少故障对电力供应的影响。本研究的实施，将为改善配电电气设备状态监测与故障诊断提供新的解决方案，提高电力供应的可靠性和稳定性，为社会经济的发展做出贡献。

配电电气系统中的智能化方法概述

1. 配电电气设备的种类和故障类型

配电电气设备进行检修维护工作是提高供电效率和降低设备运行风险的重要途径，对设备运行稳定性和使用寿命具有重要意义。配电电气设备状态检测参数和常见故障见表1。

表1 配电电气设备状态检测参数和常见故障

配电电气设备	状态监测参数	故障类型
变压器	热点温度、油温、油流量、电压和电流	过载、短路、局部放电
开关柜	开关位置、开关状态、电压、电流、温度	开关跳闸、接触不良

电力变压器在电网运行中经常使用，承受重载，因此变压器故障的情况较多。主要分为热故障和电气故障两种。热故障是变压器热应力引起的。热应力主要是绝缘材料变质按温度范围进行热失效，分为低温过热故障、中温过热故障和高温过热故障。电气故障是由于变压器元件内部结构设计或操作问题产生高压电场导致绝缘材料劣化，通常分为低能放电、高能放电和局部放电三种方式。局部放电形成原因复杂，一般在放电初期，属于低能放电；低能量放电又称火花放电，电悬浮电位之间、

电场极不均匀或感应电位极易引起火花放电；高能放电是电弧放电的一种常见形式，其主要形式为变压器匝间绕组绝缘击穿、内部闪络引起的过电压、引线断裂和分接开关飞弧等。

2. 人工智能赋能电气设备故障诊断与监测

针对配电网电气设备实际运行中的设备故障，本文以变压器的状态监测和故障诊断为例，介绍当前形势下，人工智能技术在推动故障诊断研究发展的应用。

人工智能技术，尤其是深度学习方法，在变压器状态监测中具有广泛的应用前景。由于变压器在电力系统中起着至关重要的作用，及时准确地监测其状态对于确保电力系统的稳定运行和可靠性至关重要。深度学习方法利用多层神经网络模型来进行复杂数据的处理和分析，可以从大量的数据中学习并提取特征。在变压器状态监测中，深度学习方法可以通过学习变压器正常运行时的数据特征，并将其与异常运行时的数据进行比较，从而实现状态识别和故障检测。

具体应用方法包括以下几个步骤：① 数据采集，通过安装传感器和监测设备，采集变压器的温度、振动、声音等参数。这些数据将作为训练模型的输入；② 数据预处理，对采集到的原始数据进行预处理，包括数据清洗、去噪和归一化等操作，以减小数据噪声对模型训练的影响；③ 模型训练，利用深度学习方法，设计合适的神经网络结构，并使用已标注的训练数据进行模型的训练。在训练过程中，模型将逐渐学习到正常状态下的特征和异常情况的区别；④ 状态监测，将训练好的模型应用于实时数据流中，对变压器状态进行持续监测。当模型检测到异常情况时，可以及时发出警报或采取相应的措施；⑤ 故障诊断与预测，通过分析监测到的异常数据，深度学习模型可以帮助识别故障原因，并预测可能发生的故障类型，进一步提高变压器的可靠性和维护效率。在实际应用中，还需要针对具体的变压器类型和特点进行算法调优和系统集成，以达到更好的监测效果。

3. ELE-CNN电气状态智能监测方法

利用卷积神经网络强大的特征提取能力和不易陷入过拟合的优势，以热点温度、油温、油流量、电压和电流作为输入特征量；使用8种典型的

变压器故障类型作为输出结果来识别变压器的故障类型。

卷积神经网络是一类前馈神经网络，包括卷积计算并具有深层结构。当前的卷积神经网络通常由卷积层、收敛层和全连接层的交叉堆栈组成，具有三种结构属性：局部连通性、权重共享和收敛。这些属性允许卷积神经网络具有一定程度的平移、缩放和旋转不变性。与前馈神经网络相比，卷积神经网络的参数更少。卷积层是构建卷积神经网络的核心层，它产生了网络中的大部分计算工作量。卷积层的作用是提取局部区域的特征，不同的卷积核相当于不同的特征提取器。收敛层，也称为子采样层，是为了选择和减少特征的数量，从而减少参数的数量，避免过度拟合。

本文采用的输入变量为一维向量，因此，卷积神经网络使用一维卷积，每一个卷积层中的输出为多输入特征的卷积结果。

$$x_j^l = f \left(\sum_{i \in M_l} x_i^{l-1} \times k_{ij}^l + b_j^l \right) \quad (1)$$

式中， x_i^{l-1} 为 l 层网络输入的特征矢量； k_{ij}^l 为卷积核； b_j^l 为网络偏置量； x_j^l 为网络的 l 层输出。

在卷积神经网络中，非线性激活函数可以选用Relu函数，该激活函数相对于基本的sigmoid函数，可以使得网络中部分的神经元输出为0，从而提高网络的稀疏性，有益于减缓过拟合问题。

$$\text{Relu} = f(y_i^{l+1}(j)) = \max\{0, y_i^{l+1}(j)\} \quad (2)$$

式中， $y_j^{l+1}(j)$ 为卷积后的输出值；Relu为经过Relu之后的激活值。

随后是池化层，池化层中，使用最大池化，可以在输入的特征中提取局部最大值，降低可训练参数数目并提高特征的鲁棒性。

$$P_i^{l+1}(j) = \max_{(j-1)W+1:tjW} \{q_i^l(t)\} \quad (3)$$

式中， $q_i^l(t)$ 为 l 层 i 特征的第 t 个神经元值； W 为池化的宽度大小，输出为 $l+1$ 神经元对应的值。

最终神经元输出为对最后的池化层输出展开为一维向量并首尾连接后，使用Softmax函数进行分类。

$$\text{OUT} = f(b_o + w_o f_v) \quad (4)$$

式中， w_o 为权值矩阵； f_v 为CNN输出的特征向量；

OUT为分类输出结果。

采用1D-CNN网络结构,输入为一维向量,分别是通过热点温度、油温、油流量、电压和电流等的监测,作为网络输入的一维向量,以时间步作为时序特征的度量,分割为多个时间上的数据结合,提高数据质量。有利于对变压器实时运行状态监测参数的特征提取。

本文所构建的基于ELE-CNN的配电电气设备智能监测系统如图1所示。




图1 基于ELE-CNN的配电电气设备智能监测系统

采用多种高灵敏传感器进行实时状态监测,获取每一帧时刻的设备状态参数信息,作为ELE-CNN网络的输入参数。随后传感器模块获得的数据将作为输入变量输入中央处理模块,进行特征提取和故障类型监测,作为一个分类问题。最终分类结果作为预警模块的输入,通过阈值法实现实时状态信息预警和故障维护,保证配电系统的整体运行有效。

4. 实验结果

本文在数字空间中获取变压器工作电流和电压、绕组热点温度、变压器油温和油流量数据。本文从变压器工作电压、电流和热特性的角度,提取了变压器故障识别的1个关键特性,220 V电压特性、110 kV、35 kV、2 kV母线AB线电压。电流特性,包括绕组高A相电流,中A相电流和低A相电流。热特性,包括最高油温和绕组热点温度,变压器油流量。共9个特征。

实验中,将9个关键特征参数作为输入向量,以故障类别作为输出向量,将模型训练数据随机分为两部分:训练集中的数据用于训练模型,测试集中的数据用于评估训练后获得模型的准确性。本文使用的数据集包括10 000组正常数据,编号为0~9 999,以及1 600组异常数据,编号为10 000~11 599,其中包括8种不同类型的故障训练样本和测试样本按照80%和20%的比例分为4个部分。

输入层的特征向量是 1×9 的一维数组;

C1:卷积核数量为1,核大小为 8×2 ,stride为1,padding为4;

P1:池化层大小 1×2 ,stride为1;

C2:卷积核数量为32,核大小为 2×1 ,stride为1,padding为1;

P2:池化层大小 1×2 ,stride为2;

C3:卷积核数量为128,核大小为 2×1 ,stride为1,padding为1;

P3:池化层大小 2×1 ,stride为2;

随后使用Softmax进行全连接层构建并扩展为一维数据。优化器采用SGD,学习率设为0.000 1。由于是分类问题,采用交叉熵损失函数。

$$L = \frac{1}{N} \sum_i L_i = -\frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \log(p_{ic}) \quad (5)$$

式中, M 为类别数,本文所监测故障类型共8种加上正常状态,共分9类; p_{ic} 为样本 i 属于类别 c 的概率; y_{ic} 为样本 i 的真实类别是否为1。

实验结果表明,经过300个epoch的训练,变压器故障分类的准确率基本稳定在93%以上,在258 epoch时,达到最大,为95.3%。虽然正常数据较多导致产生样本数据不平衡问题,但经过多轮训练,分类器仍然有很好的效果,异常状态监测的召回率均达到90%以上。这对电气设备状态监测和故障诊断具有实用价值和意义,由于召回率高,所报告的异常警报信息大多具有实际意义,因此有利于配电系统的维修保养,进一步提高配电电气设备的智能化自动化程度。

结束语

本研究提出ELE-CNN网络进行配电电气设备的状态智能监测和故障诊断,取得了较好的效果。经过实验验证,发现ELE-CNN网络在准确性和稳定性方面表现出色,具有良好的应用前景。ELE-CNN网络能够准确地对配电电气设备的状态进行监测。通过对大量数据的训练和学习,该网络能够捕捉到设备不同状态下的特征模式,并能够准确地判断设备当前的工作状态,极大地提高了监测的准确性,为设备的维护和管理提供了重要的依据。EA

(收稿日期:2023-10-09)