

基于电力大数据的变电主设备缺陷演化规律红外成像分析方法

付鑫[†], 郭阳

(北京中电普华信息技术有限公司, 北京 100192)

摘要:针对目标区域与背景区域混杂, 变电主设备缺陷缺陷演化规律不明的问题, 提出了基于电力大数据的变电主设备缺陷演化规律红外成像分析方法。应用红外成像技术采集变电主设备红外图像后, 使用Otsu算法分割变电主设备红外图像内目标区域和背景区域; 以分割后的变电主设备红外图像和电力大数据作为输入, 通过混合深度学习神经网络模型输出变电主设备缺陷检测结果; 将变电主设备缺陷检测结果输入到RFPA^{2D}软件内, 分析变电主设备缺陷检测结果基元破裂情况, 得到变电主设备缺陷演化规律分析结果。实验结果表明: 该方法采集变电主设备图像与其实际图像吻合度较高; 分割变电主设备红外图像目标区域与背景区域时, 受对比度影响较小; 可有效检测变电主设备缺陷类型和分析其缺陷演化规律。

关键词: 电力大数据; 变电主设备; 缺陷演化规律; 红外成像; 小波变换

中图分类号: TP393

文献标识码: A

Infrared Imaging Analysis Method of Defect Evolution Law of Substation Main Equipment Based on Power Big Data

FU Xin[†], GUO Yang

(Beijing China—power Information Technology Co., Ltd., Beijing 100192, China)

Abstract: Aiming at the problem that the target area and background area are mixed, and the evolution law of substation main equipment defects is unknown, an infrared imaging analysis method based on power big data is proposed. After collecting the infrared image of the main substation equipment with infrared imaging technology, Otsu algorithm is used to segment the target area and background area in the infrared image of the main substation equipment. Taking the segmented infrared image of the main substation equipment and power big data as inputs, the defect detection results of the main substation equipment are output through the hybrid deep learning neural network model. Input the defect detection results of the main substation equipment into RFPA2D software, analyze the primitive fracture of the defect detection results of the main substation equipment, and obtain the analysis results of the defect evolution law of the main substation equipment. The experimental results show that the image of the main substation equipment collected by this method is highly consistent with the actual image. When segmenting the target area and background area of the infrared image of the main substation equipment, it is less affected by the contrast. It can effectively detect the defect type of the main equipment of the substation and analyze its defect evolution law.

Key words: power big data; main substation equipment; defect evolution law; infrared imaging; wavelet transform

变电主设备是变电站内直接用于接收或者分配电能的所有设备, 即配电网内的一次变电设备。

收稿日期: 2022-10-21

作者简介: 付鑫(1987—), 男, 山东临沂人, 硕士, 工程师, 研究方向: 电力大数据挖掘分析, 电力人工智能应用, 电力运营监测分析等。

[†]通信联系人, E-mail: 15901020699@163.com

当变电主设备发生故障时,会导致整个配电网瘫痪^[1]。

为此,于希娟等^[2]提出一种基于图像处理和半监督学习的变电设备故障类型诊断方法,对收集到的红外图像数据进行特征提取,将其中的温度特征、纹理特征和形状特征作为模型的参考向量,利用 SMOTE 算法,对有标签样本的少数类样本进行样本扩充,汇总样本数据,构建图半监督学习网络,并对其进行训练,但该方法程序较简单,其实际应用效果有待确认;肖永立等^[3]按照关联规则思想,分析电力设备大数据内设备缺陷关联关系,并建立缺陷模型,利用 FP-growth 算法对其分析结果进行检测,得到变电站设备缺陷和缺陷演化规律,但该方法在应用过程中受变电站设备当前状态数据采集能力影响,导致其最终缺陷检测结果不佳。邵宇鹰等^[4]后者则利用声成像技术获得变电站设备运行时的声音数据,利用声成像缺陷检测技术获得变电站设备缺陷声检测结果,介绍基于 DAMAS 算法的声成像技术,研制一种可搭载于变电站巡检机器人的电力设备异响检测系统,研究 GIS 设备机械振动异响、高压端电晕放电异响两种变电站典型设备异响情况。但该方法在应用过程中采集变电站声音效果不佳,且其采集的变电站运行声音数据内存在大量的干扰噪声,使其对变电站缺陷检测以及其缺陷演化规律分析效果不佳。

红外成像技术是利用光电技术获得被测物体辐射红外线特定波段信号后,将该信号转换成图像或者图形的形式呈现给用户^[5]。红外成像技术目前被广泛应用于目标检测和缺陷识别过程,可较好地呈现目标物体的红外线分布情况。本文将红外成像技术应用到变电站缺陷演化规律分析过程中,提出基于电力大数据的变电主设备缺陷演化规律红外成像分析方法,提升变电主设备缺陷检测技术水平。

1 变电主设备缺陷演化规律红外成像分析方法

1.1 变电主设备红外图像采集

红外成像技术使用红外扫描仪发射红外辐射线,将其转换成电信号后生成红外线图像^[6,7]。红外扫描仪可吸收红外波范围为 $2\sim 14\ \mu\text{m}$,使用红外成像技术采集变电主设备红外图像过程如图 1 所示。




图 1 利用红外成像技术采集变电主设备红外图像

图 1 中,开启红外水平扫描仪和红外垂直扫描仪,校准扫描仪内温度,按照变电主设备的温度量程设置其升温范围后,开始扫描变电主设备的红外线,然后利用探测器和信号处理器将采集到的变电主设备红外线信号转换成图像并发送到显示器内^[8],完成变电主设备红外图像采集。

1.2 变电主设备红外图像目标区域分割

利用红外技术采集变电主设备红外图像后,该红外图像内的缺陷区域和背景区域是一体的^[9],为更准确地获得变电主设备红外图像缺陷特征,使用 Otsu 算法对变电主设备图像的目标区域和背景区域进行分割处理,其处理过程如下:

令 L 表示初始的变电主设备红外图像灰度等级,其中灰度为 i 的像素个数由 n_i 表示,图像内总像素数量由 N 表示。则变电主设备红外图像各个灰度出现概率表达公式如下:

$$Q_i = \frac{n_i}{N} \quad (1)$$

设置变电主设备红外图像灰度等级分割阈值为 t ,将变电主设备红外图像灰度划分为 $C_0 = (1, 2, \dots, t)$ 和 $C_1 = (t+1, t+2, \dots, L-1)$ 两个类别,则该两个类别灰度值出现的概率表达公式如下:

$$\varphi_0 = \sum_{i=0}^t Q_i = \varphi(t) \quad (2)$$

$$\varphi_1 = \sum_{i=t+1}^{L-1} Q_i = 1 - \varphi(t) \quad (3)$$

上述公式中, φ_0 和 φ_1 分别表示 C_0 和 C_1 的灰度类别的出现概率。

计算 C_0 和 C_1 的灰度类别的平均灰度值,其表达公式如下:

$$b_0 = \sum_{i=0}^t i \times Q_i / \varphi_0 \quad (4)$$

$$b_1 = \sum_{i=t+1}^{L-1} i \times Q_i / \varphi_1 \quad (5)$$

依据公式(4)、(5)计算 C_0 和 C_1 的灰度类别的方差 J_0^2 、 J_1^2 ,其表达公式如下:

$$J_0^2 = \frac{\sum_{i=0}^t (i - b_0)^2 \times Q_i}{\sum_{i=0}^t \varphi_0} \quad (6)$$

$$J_1^2 = \frac{\sum_{i=t+1}^{L-1} (i - b_1)^2 \times Q_i}{\sum_{i=t+1}^{L-1} \varphi_1} \quad (7)$$

设置变电主设备红外图像的类内方差和类间方差分别为 J_w^2 、 J_b^2 , 依据公式(6)、(7)结果, 计算变电主设备红外图像的类内方差和类间方差, 表达公式如下:

$$J_w^2 = \varphi_0 \sigma_0^2 + \varphi_1 \sigma_1^2 \quad (8)$$

$$J_b^2 = \varphi_1 \times \varphi_0 (b_0 - b)^2 + \varphi_1 \times \varphi_0 (b_1 - b)^2 \quad (9)$$

公式(8)、(9)即为变电主设备红外图像目标区域与背景区域分割阈值 t 的函数。设置阈值 t 的判决规则如下:

$$\eta(t) = \frac{1}{J_w^2} \times J_b^2 \quad (10)$$

按照阈值 t 的判决规则, 计算 C_0 和 C_1 的灰度类别的最佳分割阈值 t' , 表达公式如下:

$$t' = \max_{0 \leq t \leq L-1} \eta(t) \quad (11)$$

按照公式(11)获得的灰度类别最佳分割阈值对变电主设备红外图像进行分割后, 即可完成其目标区域与背景的分割。

1.3 基于主成分分析方法的目标区域特征识别

提取变电站设备红外图像特征是检测其缺陷的基础。在此使用主成分分析方法提取变电主设备红外图像目标区域特征, 其详细过程如下:

将特征矢量 u_i 对应的特征值 λ_i 进行降序排列后, 得到主成分分析的最优投影方向, 依据该方向对变电站设备红外图像特征信号进行重构后, 得到变电站设备红外图像特征分解值。

令 $f(x, y)$ 表示变电站设备红外图像, 其维度为 $A \times A$, 将该变电站设备红外图像按照其维度的行相连后, 生成 $A^2 \times 1$ 矢量 χ 。利用变电站设备红外图像 $f(x, y)$ 构建训练集, 由 $\{\chi_i \mid i = 1, 2, \dots, R\}$ 表示, 其中 R 表示训练样本总数。则 R 副变电站设备红外图像的平均值向量表达公式如下:

$$\mu = \frac{\sum_{i=1}^R \chi_i}{R} \quad (12)$$

分解变电站设备红外图像特征值。令 x 表示变电主设备红外图像的实信号向量, 其协方差矩阵由 C_x 表示, 其表达公式如下:

$$C_x = U^T V U \quad (13)$$

上述公式中, C_x 为正定矩阵; $U = (u_1, u_2, \dots, u_n)$ 为 C_x 的特征矢量正交矩阵; $V = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$ 表示特征矢量 u_i 对应特征值的对角矩阵。

将公式(12)结果代入公式(13)内, 则变电站设备红外图像协方差矩阵 C 表达公式如下:

$$C = \frac{\sum_{i=1}^R (\chi_i - \mu) (\chi_i - \mu)^T}{R} = \frac{FF^T}{R} \quad (14)$$

$$F = [\chi_1 - \mu, \chi_2 - \mu, \dots, \chi_M - \mu] \quad (15)$$

上述公式中, F 表示考察矩阵。由于维数较多, 对其进行求解时, 需先计算考察矩阵的特征值 λ'_i 和特征向量 τ'_i , 则考察矩阵 F 满足下式关系:

$$F^T F \tau'_i = \lambda'_i \tau'_i \quad (16)$$

在公式(16)的两侧同时乘 F 后, 则该公式变更如下:

$$(FF^T) F \tau'_i = \lambda'_i \cdot F \tau'_i \quad (17)$$

通过上述公式可知, 公式(14)的特征值和特征向量分别为 λ'_i 与 $F \tau'_i$ 。

将 λ'_i 和 $F \tau'_i$ 数值进行降序排列后, 最大的特征值和特征向量可有效地反应变电主设备红外图像的差异性, 且特征值呈现指数降低趋势^[10]。在序列的 λ'_i 和 $F \tau'_i$ 序列内选取前 m 个特征值对应的特征向量构建变电主设备红外图像的特征空间, 由 $\tau = (\tau_1, \tau_2, \dots, \tau_m)$ 表示。并将该特征空间对应的变电主设备红外图像看作特征子图像。

令 v 表示变电主设备红外图像特征, 其表达公式如下:

$$v = \tau^T * \times \epsilon \quad (18)$$

上述公式中, ϵ 表示变电主设备红外图像与图像均值的差值。

经过上述过程, 获得变电主设备红外图像的特征, 为后续分析变电主设备缺陷演化规律提供图像数据支撑。

1.4 变电主设备缺陷检测方法

混合深度学习神经网络模型是对数据表征进行学习的方法, 其结合数据各个特征之间的关系, 得出复杂且抽象的组合特征^[11], 实现缺陷检测与识别等过程。

利用变电主设备红外图像目标区域特征和历史电力大数据构建数据集 Z , 使用混合深度学习神经网络模型对该数据集进行迭代输出变电主设备缺陷类型, 其详细过程如下:

将数据集 Z 输入混合深度学习神经网络模型的输入层内, 该层为神经网络模型的第一层, 其负

责对电力大数据和红外图像特征进行归一化处理。然后将其输入卷积层内,卷积层负责对电力大数据和红外图像特征进行高维映射,得到变电站红外图像和电力大数据的高维特征。卷积层选取变电站红外图像和电力大数据高维度特征点时的权值矩阵为其卷积运算的卷积核,该卷积核的特征面长度表达公式如下:

$$H_{\text{ength}} = (D_{\text{ength}} - D'_{\text{ength}} + 1) / T_{\text{ength}} \quad (19)$$

上述公式中, H_{ength} 表示卷积核特征面长度; D_{ength} 、 D'_{ength} 、 T_{ength} 分别表示输入特征面长度、卷积核大小和卷积操作滑动步长。

令 $L_{i,j}$ 表示卷积层输出的变电主设备红外特征图和电力大数据特征图,其中 i 、 j 均表示特征图的灰度值,其表达公式如下:

$$L_{i,j} = f\left(\sum_{i=1} L_{i,j} - 1 \times \tilde{\omega}_{i,j} + a_{i,j}\right) f(\tilde{\omega}_{i,j} + a_{i,j}) \quad (20)$$

上述公式中, $a_{i,j}$ 表示偏置项; $\tilde{\omega}_{i,j}$ 表示变换系数。

卷积层对变电主设备红外图像特征和电力大数据特征进行高维映射处理后,利用公式(20)输出高维映射后的变电站在设备红外图像特征与电力大数据特征并输入到池化层内。池化层对高维变电站设备红外图像特征和电力大数据特征进行下采样处理^[12,13],池化层的最大池化模型表达公式如下:

$$O_{\text{max}} = \max_{i=1, j=1} (f_{i,j}) \quad (21)$$

上述公式中, O_{max} 表示池化层最大池化模型; $f_{i,j}$ 表示池化函数。

池化层平均池化模型表达公式如下:

$$I_{\text{avg}} = \frac{\sum_{m=1} \sum_{n=1} (f_{i,j})}{k^2} \quad (22)$$

上述公式中, I_{avg} 表示平均池化模型; k 表示移动步长; m 、 n 均表示随机常数。

池化层利用公式(21)、(22)获得变电主设备红外图像和电力大数据下采样数值后,利用池化域将变电主设备红外图像和电力大数据局内目标缺陷抽象为特征图,利用 RFPA2D 软件将特征图均匀地划分为大小相同的正方形,其中每个正方形均表示一个基元。当相邻的基元发生破裂时,则说明相连的基元属于同一个破裂集团。破裂集团则为变电主设备缺陷,破裂集团数量是变电主设备缺陷个数,此时则池化域表达公式如下:

$$U = \begin{cases} \frac{\sum_{m=1} \sum_{n=1} (f_{i,j})}{m^2} \\ \frac{\left[\sum_{m=1} \sum_{n=1} (f_{i,j}) \right]^2}{n^2} \end{cases} \quad (23)$$

上述公式中, U 表示池化域。

将池化域结果输入 Softmax 层内。Softmax 层为混合深度学习神经网络模型的输出层^[14,15],利用该层获得变电主设备红外图像的缺陷类型。

令 $q(y^{(i)} = n | x_i, \theta)$ 表示变电主设备红外图像缺陷概率,其表达公式如下:

$$q(y^{(i)} = n | x_i, \delta) = \begin{bmatrix} p(y^{(i)} = 1 | x_i, \delta) \\ p(y^{(i)} = 2 | x_i, \delta) \\ \vdots \\ p(y^{(i)} = k | x_i, \delta) \end{bmatrix} \quad (24)$$

上述公式中, δ 表示概率向量。

利用代价函数对公式(24)进行反向传播处理,代价函数 $H'(\delta)$ 表达公式如下:

$$H'(\delta) = \frac{\left[\sum_{m=1} \sum_{n=1} (f_{i,j}) (y^{(i)} = K | x_i, \delta) \log + \frac{\lambda}{2} \right]}{m} \quad (25)$$

上述公式中, λ 表示阈值。将公式(24)结果代入公式(25)内,得到混合深度学习神经网络模型的输出结果,该结果即为变电主设备红外图像缺陷检测结果。

应用 RFPA2D 软件呈现变电主设备红外图像基元破裂情况,得到变电主设备缺陷演化规律结果。

2 实验分析

以国网某省供电公司作为实验对象,使用本文方法分析该电网变电主设备缺陷演化规律,并验证本文方法应用效果。该省大电网为直流交流混合电网,其中变电主设备众多,且该省气候环境较为湿润,降雨量较大,环境温度较高。变电主设备在潮湿和高热环境中容易出现风化、腐蚀变形、裂纹等情况。

2.1 变电主设备红外图像采集测试

变电主设备红外图像采集是实现其缺陷演化规律分析的基础。在采集变电主设备红外图像时,当前环境光照、目标的摆动均影响其采集效果。为

验证本文方法采集变电主设备红外图像能力,选择阴天光照度不佳,且变电主设备随风摆动情况下,采集该变电主设备——柱式绝缘子。采集结果如图 2 所示。




图 2 变电主设备红外图像采集结果

分析图 2 可知,本文方法采集的变电主设备图像与其实际图像吻合度极高,且不存在变形、模糊等现象。该结果说明本文方法可在采集环境较为恶劣的情况下有效采集变电主设备红外图像,具备较好的红外图像采集能力。

2.2 目标区域分割测试

变电主设备红外图像的目标区域分割是提取其特征和检测缺陷类型的基础。以一组本文方法采集的变电主设备红外图像为实验对象,对其进行目标区域分割处理,结果如图 3 所示。




图 3 变电主设备红外图像目标区域分割结果

分析图 3 可知,本文方法可有效对变电主设备红外图像目标区域进行分割,且在初始的变电主设备红外图像内上方和右下方目标区域与背景区域对比度较低情况下,依然有效分割目标区域和背景区域,说明本文方法在分割变电主设备红外图像目标区域和背景区域时受红外图像对比度影响较小。

2.3 变电主设备缺陷检测

验证本文方法识别变电主设备缺陷类型性能。以 10000 组变电主设备缺陷红外图像为实验对象,

使用本文方法和文献[2]方法检测该 10000 组变电主设备缺陷图像内数值为 0.2~0.5mm 的微小裂纹和其他缺陷,对比结果如表 1 所示。

表 1 变电主设备缺陷检测结果(个)

变电主设备 红外图像数量	微小裂纹		
	实际累计 数量	本文方法检测 累计数量	文献[2]方法 检测累计数量
1000	117	117	112
2000	209	209	205
3000	238	238	235
4000	306	306	301
5000	381	381	380
6000	511	511	506
7000	664	663	658
8000	791	789	786
9000	833	825	826
10000	909	901	898

分析表 1 可知,变电主设备红外图像数量越多时,变电主设备红外图像内缺陷数量越多。本文方法整体上优于文献[2]方法,准确性更高,证明图像处理与识别能力更优,其中变电主设备红外图像为 7000 组之前时,本文检测到的变电主设备红外图像内存在微小裂纹的图像数量与实际数量完全相同。当变电主设备红外图像超过 7000 组后,本文方法检测到的微小裂纹缺陷开始出现偏差,但偏差数值不大。在变电主设备红外图像为 10000 个时,本文检测到的微小裂纹累计数量与实际累计数量差值仅为 8 个。上述结果说明:本文方法不仅可有效检测变电主设备红外图像内微小裂纹类型,且其检测精度极高,应用效果较好。

2.4 变电主设备缺陷演化规律分析

以某变电主设备红外图像为实验对象,使用本文方法对其在时间段内裂纹缺陷的演化规律进行分析,结果如图 4 所示。

分析图 4 可知,初始的变电主设备裂纹缺陷共有 2 个,其中裂纹缺陷位置 2 的裂纹面积较大。但 2 个月后,该变电主设备的两个裂纹缺陷逐渐扩大,合并成 1 个稍大的裂纹缺陷。经过 3 个月和 4 个月后,该变电主设备裂纹缺陷由缺陷中心逐渐向外扩展,且主要扩展方向为向下,说明该变电主设备受力方向为上方,其裂纹随着时间的推移逐渐向下延伸。综上结果:本文方法可有效分析变电主设备红外图像裂纹缺陷随着时间的演化规律。




图 4 变电主设备缺陷演化规律

3 结 论

研究了基于电力大数据的变电主设备缺陷演化规律红外成像分析方法。在该方法以历史电力大数据为基础,利用混合深度学习神经网络模型识别变电主设备缺陷类型,并使用 RFPA2D 软件得到变电主设备缺陷演化规律,使其具备较好的变电主设备红外图像目标区域与背景区域分割能力,并可精确检测变电主设备红外图像微小缺陷和分析其演化规律,应用性较强。

参考文献

[1] 潘成胜,李惠,陈波,等. 基于组合核函数的类均值核主元故障诊断方法[J]. 计算机仿真,2019,36(2):414—418.

[2] 于希娟,孙宏伟. 基于图像处理和半监督学习的变电设备故障诊断[J]. 电网与清洁能源,2022,38(8):60—68.

[3] 肖永立,刘松,见伟,等. 一种基于 FP-growth 算法的变电站二次设备缺陷分析方法[J]. 电测与仪表,2020,57(12):83—90.

[4] 邵宇鹰,王泉,彭鹏,等. 基于声成像技术的电力设备缺陷检测方法研究[J]. 中国测试,2021,47(7):42—48.

[5] 马超,李宁,李新平,等. 基于红外热成像的电缆终端漏油缺陷检测机理分析[J]. 南方电网技术,2021,15(5):58—63.

[6] 史俊,刘兴涛,刘乐,等. 基于红外、紫外和可见光融合检测输电变电设备缺陷技术[J]. 工业安全与环保,2019,45(7):28—30+48.

[7] 刘齐,王茂军,高强,等. 基于红外成像技术的电气设备故障检测[J]. 电测与仪表,2019,56(10):122—126+152.

[8] 李文璞,谢可,廖道,等. 基于 Faster RCNN 变电设备红外图像缺陷识别方法[J]. 南方电网技术,2019,13(12):79—84.

[9] 刘光辉,王维庆. 计及等效负荷密度的电网二维故障选线仿真[J]. 计算机仿真,2020,37(7):123—127.

[10] 杨宁,毕建刚,弓艳朋,等. 1100 kV GIS 设备内部缺陷局部放电带电检测方法试验研究及比较分析[J]. 高压电器,2019,55(8):37—47+57.

[11] 罗鹏,王波,马恒瑞,等. 基于组合式目标检测框架的低漏报率缺陷识别方法[J]. 高电压技术,2021,47(2):454—464.

[12] 庄建煌,彭健,陈重,等. 基于泛在电力物联网的多技术融合变电设备发热缺陷判别预测系统的研究设计[J]. 高压电器,2020,56(9):54—59.

[13] 梁文武,朱维钧,李辉,等. 基于粗糙集的智能变电站保护设备仿生故障诊断方法[J]. 电力系统保护与控制,2021,49(21):132—140.

[14] 任博,郑永康,王永福,等. 基于深度学习的智能变电站二次设备故障定位研究[J]. 电网技术,2021,45(2):713—721.

[15] 肖发龙,吴岳忠,沈雪豪,等. 基于深度学习和知识图谱的变电站设备故障智能诊断[J]. 电力建设,2022,43(3):66—74.