

基于多尺度纹理特征的EPR电缆终端故障诊断方法

郭 蕾¹, 曹伟东¹, 张靖康¹, 白龙雷¹, 邢立勤¹, 项恩新², 周利军¹

(1. 西南交通大学 电气工程学院, 四川 成都 610031;

2. 云南电网有限责任公司 电力科学研究院, 云南 昆明 650217)

摘要:高速铁路列车中乙丙橡胶(EPR)电缆终端常因制作过程中操作不当而导致出现多种缺陷,造成终端局部放电甚至击穿的现象,对检测到的局部放电信号进行准确分类仍然是亟待解决的难题。分别制作了含尖端、环切划伤、金属微粒、气隙4种典型缺陷的终端试样,通过试验记录了各类试样的放电谱图信息。基于试验得到的局部放电谱图库,提出通过图像金字塔理论,构建多尺度局部放电谱图空间,并从中提取1阶纹理统计量、2阶纹理统计量及高阶纹理统计量作为缺陷类型识别的特征参量。同时,结合随机森林算法,基于gini指数完成了特征空间寻优工作,实现了对缺陷类型的正确分类。结果表明:通过随机森林算法,多尺度纹理特征的模型误差率和分类准确率明显优于单尺度纹理特征,能较好地对待终端典型缺陷进行分类;同时,由于气隙缺陷和划伤缺陷的放电机理存在相似性,二者缺陷处的局部放电特征同样存在相似现象,因此气隙缺陷和划伤缺陷的分类较易出现误差,导致其识别率偏低,还需针对其图像特征参数和识别算法继续开展研究。

关键词:乙丙橡胶电缆;典型缺陷;纹理特征;图像金字塔;随机森林算法;故障诊断

中图分类号:TM 247

文献标志码:A

DOI:10.16081/j.epae.202008018

0 引言

车载乙丙橡胶 EPR (Ethylene Propylene Rubber) 电缆是高速铁路动车组供电系统的关键设备,其健康状态与列车的安全可靠运行息息相关^[1]。然而由于 EPR 电缆终端在制作、安装的过程中,不可避免地会在终端部位留下各类缺陷,缺陷部位的电场畸变严重,极易在列车运行时发生局部放电,甚至造成电缆终端击穿,从而引发列车停运事故的频繁发生。因此,开展动车组电缆终端的局部放电特性^[2]及放电类型识别的研究势在必行。

在利用局部放电信息进行缺陷类型识别的研究中,放电信息特征提取方法及特征的丰富度是影响故障识别效果的重要因素。目前,针对局部放电信息提取的特征主要有分形特征^[3]、统计特征^[4]、小波特征^[5]、Weibull 参数^[6]、图像矩特征^[7]、纹理特征^[8]等。其中,图像的纹理特征由于其包含信息丰富、抗外界环境干扰能力强、具有较好的区分能力和灵敏性而逐渐被学者们关注。但是,现场进行电缆局部放电检测的过程费时费力,可供检测的“天窗”有限,获得的放电数据匮乏,且获得的单一维度纹理特征所包含的信息尺度有限,不能反映多尺度的信息特征,对缺陷类型的识别效果影响较大。因此国内外学者先后提出基于图像的多尺度纹理特征提取进行识别与分类的方法,并取得了较好的应用效果。文

献[9]针对场景分类问题,通过提取图片的多尺度局部二值模式特征,使对室外场景的分类正确率达到了84%以上;文献[10]针对遥感影像分类问题,通过提取影像数据的多尺度灰度共生矩阵,使对遥感图片信息的总体分类精度达到81.75%;文献[11]针对目标框架检测问题,通过提取图像的多尺度纹理和颜色特征,提出了一种自适应特征组合机制,并高概率地捕捉到了物体的边界;文献[12]针对表面纹理分类问题,提出了一种多尺度的灰度局部差分方法,将分类准确率提高到了96%。由此可见,通过增加采集信息的特征维度,可有效增加测量信息的丰富度,从而提高分类精度和准确率。

随着所提取纹理特征的维度增加,图像纹理特征种类也将更多,此时需要提取较多的特征组成高维向量空间才能较为全面地反映图像信息,但同时也会增加识别的运算量,减慢运算速度。因此,本文提出结合多尺度纹理特征与随机森林算法进行缺陷识别。随机森林算法通过多棵决策树对样本训练并进行预测,是一种在高维特征空间学习速度快、预测精度高的算法,在电缆终端放电故障识别中具有广阔的应用前景。

鉴于以上情况,本文针对车载 EPR 电缆终端典型缺陷的有效识别问题,制作了4种常见典型缺陷以模拟其实际故障情况,并基于试验记录的局部放电相位 PRPD (Phase Resolved Partial Discharge) 谱图,通过图像金字塔理论,构建了多尺度 PRPD 谱图空间,从中提取1阶纹理统计量、2阶纹理统计量及高阶纹理统计量作为 PRPD 谱图特征进行准确识别分析。同时,本文通过 gini 指数完成了特征空间寻

收稿日期:2019-11-19;修回日期:2020-06-17

基金项目:四川省科技计划资助项目(2020JDTD0009)

Project supported by the Science and Technology Program of Sichuan Province(2020JDTD0009)

优,并在此基础上结合随机森林算法实现了对所述典型缺陷类型的有效分类。结果表明,多尺度图像纹理特征和随机森林算法相结合不仅能够全面反映放电谱图信息,还能对缺陷类型进行高效、准确的分类和识别。

1 多尺度纹理特征和随机森林算法

1.1 纹理特征

纹理特征被广泛用在场景目标识别、遥感图像分析、工业检测、医学图像分析、文本分割等领域^[13]。本文根据从目标图像中提取的纹理特征阶数,将特征分为 1 阶纹理统计量、2 阶纹理统计量及高阶纹理统计量 3 类。

1.1.1 1 阶纹理统计量

1 阶纹理统计量是指基于图像纹理特征,从特征直方图中提取的特征,本文采用的特征直方图为灰度直方图、局部二进值模式(LBP)特征直方图,图 1 为从金属微粒缺陷 PRPD 谱图中提取的特征直方图。




图 1 特征直方图

Fig.1 Feature histogram

针对对数归一化后的特征直方图的提取公式为:

$$d_1 = \sum_{i=0}^{255} iH[i], d_2 = \sum_{i=0}^{255} (i - d_1)^2 H[i] \quad (1)$$

$$d_3 = \frac{1}{d_2^{3/2}} \sum_{i=0}^{255} (i - d_1)^3 H[i], d_4 = \frac{1}{d_2^2} \sum_{i=0}^{255} (i - d_1)^4 H[i] - 3 \quad (2)$$

$$d_5 = \sum_{i=0}^{255} (H[i])^2, d_6 = -H[i] \log_2 H[i] \quad (3)$$

其中, $H[i]$ 为归一化特征直方图; $d_1 \sim d_6$ 分别为直方图数组均值、方差、偏斜度、峰态、能量、熵。

1.1.2 2 阶纹理统计量

2 阶纹理统计量是指基于图像纹理特征,从图像的共生矩阵、梯度矩阵等图像矩阵中提取的特征,本文采用的矩阵特征为 Tamura 纹理特征、灰度共生

矩阵(GLCM)特征、Laws 纹理特征。

对于 Tamura 纹理^[14],主要提取其粗糙度、对比度、方向度、线性度、规整度、粗略度特征,本文对 Tamura 纹理中使用最多的前 3 个特征进行提取;对于 GLCM 特征^[15],Haralick 提取了 14 个 2 阶统计量作为纹理特征,其中使用较多的特征为角二阶矩(能量)、对比度、相关性、熵;对于 Laws 纹理特征^[16],本文提取目标图像的 9 个具有旋转不变性的纹理能量测度矩阵,并分别计算出相应矩阵的能量和方差。

1.1.3 高阶纹理统计量

图像的高阶统计量是指大于 2 阶统计量的高阶矩、高阶累积量以及它们所对应的高阶矩谱和高阶累积量谱等主要统计量^[17]。

本文针对高阶统计量中的高阶矩和高阶累积量进行提取, k 阶矩和 k 阶累积量均为 $k-1$ 个独立变元函数,将随机变量 $\{x(n), x(n+\tau_1), x(n+\tau_2), \dots, x(n+\tau_{k-1})\}$ 的 k 阶联合矩和 k 阶累积量分别记为 $p_k(\tau_1, \tau_2, \dots, \tau_{k-1})$ 和 $c_k(\tau_1, \tau_2, \dots, \tau_{k-1})$ 。

考虑到实际计算的复杂性,本文主要针对 3、4 阶统计量进行提取,具体表达式为:

$$p_3(\tau_1, \tau_2) = E[x(k)x(k+\tau_1)x(k+\tau_2)] \quad (4)$$

$$c_3(\tau_1, \tau_2) = E[(x(k)-p_1)(x(k+\tau_1)-p_1)(x(k+\tau_2)-p_1)] \quad (5)$$

$$p_4(\tau_1, \tau_2, \tau_3) = E[x(k)x(k+\tau_1)x(k+\tau_2)x(k+\tau_3)] \quad (6)$$

$$c_4(\tau_1, \tau_2, \tau_3) = p_4(\tau_1, \tau_2, \tau_3) - (p_2(\tau_1)p_2(\tau_3 - \tau_2) -$$

$$p_2(\tau_2)p_2(\tau_3 - \tau_1) - p_2(\tau_2)p_2(\tau_3 - \tau_1) - p_2(\tau_2)p_2(\tau_2 - \tau_1)) - p_1(p_3(\tau_2 - \tau_1, \tau_3 - \tau_1) + p_3(\tau_2, \tau_3) + p_3(\tau_1, \tau_3) + p_3(\tau_1, \tau_2)) + 2p_1^2(p_2(\tau_1) + p_2(\tau_2) + p_2(\tau_3) + p_2(\tau_3 - \tau_1) + p_2(\tau_3 - \tau_2) + p_2(\tau_2 - \tau_1) - 6p_1^4) \quad (7)$$

其中, $E[\]$ 表示数学期望; p_3 、 c_3 分别为 3 阶矩、3 阶累积量; p_4 、 c_4 分别为 4 阶矩、4 阶累积量; p_1 、 p_2 分别为 1 阶矩、2 阶矩。

1.2 图像金字塔

图像金字塔是一种图像多尺度表示技术, Gaussian 金字塔作为最常用的图像金字塔之一,被广泛应用于图像处理、信号处理等领域, Gaussian 金字塔构建的流程如下。

设原图像为 G , 以 G_0 作为 Gaussian 金字塔的底层, Gaussian 金字塔的第 k 层图像 G_k 可用式(8)表示, 首先将第 $k-1$ 层图像与低通窗口 $w(x, y)$ 进行卷积, 再把卷积的结果作隔行隔列的降采样。

$$G_k = \sum_{x=-2}^2 \sum_{y=-2}^2 w(x, y) G_{k-1}(2i+x, 2j+y) \quad (8)$$

$$0 \leq i < C_l, 0 \leq j < R_l, 0 < l \leq N$$

其中, N 为 Gaussian 金字塔顶层层号; C_l 为 Gaussian

金字塔第 l 层图像的列数; R_l 为 Gaussian 金字塔第 l 层图像的行数; $w(x, y)$ 为 5×5 维的窗口函数,表达式如式(9)所示。

$$w(x, y) = \frac{1}{256} \begin{bmatrix} 1 & 4 & 6 & 4 & 1 \\ 4 & 16 & 24 & 16 & 4 \\ 6 & 24 & 36 & 24 & 6 \\ 4 & 16 & 24 & 16 & 4 \\ 1 & 4 & 6 & 4 & 1 \end{bmatrix} \quad (9)$$

1.3 随机森林

随机森林算法是一种基于自助法(bootstrap)重采样和决策树的集成学习算法^[18-19],bootstrap重采样的基本思想为对于样本容量为 m 的原始数据集,从中有放回地进行随机抽样形成bootstrap数据集。bootstrap数据集的样本容量仍为 m ,虽与原始数据集样本容量相同,但bootstrap数据集可能包含了重复的样本,在采样过程中未被选中的样本成为袋外样本OOB(Out-Of-Bag),OOB数据集的容量为原始数据集样本容量的 $1/e$ 。bootstrap重采样过程如图2所示。




图2 bootstrap重采样过程

Fig.2 Bootstrap resampling process

对于样本容量为 m 的原始数据集,随机森林构建的流程如下。

(1)通过bootstrap重采样方法,从原始数据集中随机采样形成样本容量为 m 的bootstrap数据集,同时形成OOB数据集。

(2)假设bootstrap数据集有 t_{all} 个特征,从中随机挑选出 t_r 个子特征($t_r \leq t_{all}$),子特征的最优性由gini系数最小原则决定。通过计算 t_r 个子特征的最优性,挑选出一个最具有分类能力的特征作为决策树节点的分类方式。

(3)重复上述步骤 h 次,从而建立 h 棵决策树组成的随机森林。对于新的测试样本集,分类结果取决于 h 棵决策树的投票。

1.4 试验与识别方法过程

基于多尺度纹理特征和随机森林的电缆终端典型缺陷诊断的试验流程图见附录A中的图A1。该流程分为3步:

(1)完成试样制备,基于试验平台搭建PRPD谱图库,详见2.1节和2.2节;

(2)对目标图像进行Gaussian金字塔分解,得到Gaussian金字塔图像序列,提取图像序列的1阶纹理

统计量、2阶纹理统计量及高阶纹理统计量,详见2.3节;

(3)通过不同识别方案,基于随机森林算法比较单尺度纹理与多尺度纹理的分类准确性,同时根据gini指数对图像特征重要性进行排序,详见3.1节和3.2节。

2 试验设计及特征空间构建

2.1 试样制备

试验过程中,所制作的试样均来自于CRH380A型动车组(材料型号为QTO-J30G-25 kV)车顶高压EPR电缆。由于目前尚未出台有关EPR电缆终端缺陷制作的相关技术标准,试验中所述缺陷均是参照铁路行业、现场经验和相关文献^[20]所提供的方式进行制作,与实际情况的契合度较高。缺陷试样制作过程如下。

(1)剥去车载电缆终端处伞裙、外护套80 cm;剥去外屏蔽、外半导体层75 cm,露出主绝缘;截去端部绝缘7 cm,露出缆芯。

(2)在EPR绝缘上制作尖端、环切划伤、金属微粒、气隙4种缺陷,分别如附录A中的图A2(a)~(d)所示。其中,尖端缺陷用于模拟终端制作过程中,外半导体层截断处环切不当,使得外半导体层突起,引起电场集中,从而导致沿主绝缘方向上的沿面放电情况,其制作过程为将外半导体层裁剪为尖齿状;环切划伤缺陷用于模拟终端制作过程中,剥去外半导体层时,在绝缘与外半导体层断口处刀具留下的划痕;金属微粒缺陷用于模拟终端制作过程中,金属碎屑或漂浮的导电颗粒遗留在热缩管与绝缘之间的情况,其制作过程为先将金属铜箔随机放置在绝缘上,再用硅脂涂抹在金属铜箔四周;气隙缺陷用于模拟终端在制作过程中,热缩管与绝缘间出现气隙的情况,其制作过程为在EPR绝缘表面上制作长度、宽度、深度分别为100、0.5、1 mm的凹槽。

(3)按照电缆附件制作规范,将电缆终端安装完成。需要说明的是,本文对4种缺陷类型均制作了3根电缆试样,共计12根电缆试样,并按照表1对试样进行编码和编号,以便用于后续的算法分类研究。根据相关研究^[2],局部放电现象是一种随机发生的行为,为减小放电试验研究中的随机性,得到EPR电缆终端各缺陷的代表性特征谱图,本文对同种类型的3根电缆试样数据均进行了综合分析。

表1 试验样品编号

Table 1 Test group number

缺陷类型	编号	编码	缺陷类型	编号	编码
尖端	a_1, a_2, a_3	1	金属微粒	c_1, c_2, c_3	3
环切划伤	b_1, b_2, b_3	2	气隙	d_1, d_2, d_3	4

2.2 局部放电试验平台

本文采用 CPL 542 检测阻抗和 MCT 120 高频电流互感器对局部放电信号进行采集,将其中之一的测试源作为开窗单位以抑制背景噪声,经试验,将 CPL 542 测试通道作为开窗单元, MCT 120 测试通道作为记录单元,此时背景噪声控制在 2pC 左右,抑制效果最佳。试验回路如附录 A 中的图 A3 所示,其中试验变压器为 TQSW 无局部放电工频试验变压器,其容量为 $10\text{ kV}\cdot\text{A}$,额定电压为 100 kV ;高压电阻阻值为 $400\text{ M}\Omega$;分压器的分压比为 $1000:1$;耦合电容为 1000 pF ;MCU 502 为数据采集装置。

2.3 特征空间构建

基于 2.2 节试验平台,分别测量了 12 根 EPR 电缆终端试样自起始放电至稳定放电的 PRPD 谱图信息。以金属微粒缺陷试样 c_1 为例,特征空间构建的步骤如下。

(1)记录 PRPD 谱图信息,经试验发现,试样在放电过程中,放电量变化会逐步趋于稳定,PRPD 谱图形状呈现规律性变化,如附录 A 中的图 A4 中的虚线框所示区域。因此,本文对这段区域以随机采样方式提取典型 PRPD 谱图作为目标图像,不同缺陷试样的典型 PRPD 谱图如附录 A 中的图 A5 所示。

(2)对目标图像进行多分尺度处理,从而构建 Gaussian 金字塔图像序列,本文将目标图像分解为 4 层,若后续的分类效果不佳,可对分解层数进行调整。其中,底层图像 G_0 的分辨率为 128×128 像素,第 1 层图像 G_1 的分辨率为 64×64 像素,第 2 层图像 G_2 的分辨率为 32×32 像素,第 3 层图像 G_3 的分辨率为 16×16 像素。分解后的图像如图 3 所示。




图 3 Gaussian 金字塔图像序列

Fig.3 Gaussian pyramid image sequence

(3)对 Gaussian 金字塔图像序列进行 1 阶纹理统计量、2 阶纹理统计量及高阶纹理统计量提取。对于单张图片,1 阶纹理统计量数量为 12,2 阶纹理统计量数量为 25,高阶纹理统计量数量为 4,特征量编号见附录 B。基于图像多尺度分解和纹理特征,共提取了 $41\times 4=164$ 个特征量。

3 分类结果

3.1 纹理特征性能比较

为了探寻多尺度纹理特征与单尺度纹理特征在随机森林算法中的优劣性,本文共采集了 576 张图片,其中每个缺陷试样采集图片 48 张,每个缺陷对

应 3 根试样。随机森林算法中训练样本和测试样本的选取如表 2 所示。将试样 a_1 、 a_2 、 b_1 、 b_2 、 c_1 、 c_2 、 d_1 、 d_2 的典型 PRPD 谱图特征作为训练样本,训练样本共计 384 个;将试样 a_3 、 b_3 、 c_3 的典型 PRPD 谱图特征作为测试样本,测试样本共计 192 个。

表 2 训练样本和测试样本

Table 2 Training and testing samples

样本类型	样本来源	样本数量	样本类型	样本来源	样本数量
训练样本	a_1 、 a_2	96	测试样本	a_3	48
	b_1 、 b_2	96		b_3	48
	c_1 、 c_2	96		c_3	48
	d_1 、 d_2	96		d_3	48

同时,在随机森林算法中还需要确定的参数有决策树数量 n_{tree} 和决策树分裂时的子特征数量 t_r ,通常由 $t_r = \sqrt{t_{\text{all}}}$ 决定。因此,本文以模型误差率和分类误差率为衡量指标对多尺度纹理特征和单尺度纹理特征进行性能比较,并设计了以下 7 个方案,其中方案 1—4 为单尺度特征空间,方案 5—7 为多尺度特征空间。

(1)方案 1:特征空间由底层图像 G_0 特征构建, $t_r=7$ 。

(2)方案 2:特征空间由第 1 层图像 G_1 特征构建, $t_r=7$ 。

(3)方案 3:特征空间由第 2 层图像 G_2 特征构建, $t_r=7$ 。

(4)方案 4:特征空间由第 3 层图像 G_3 特征构建, $t_r=7$ 。

(5)方案 5:特征空间由底层图像 G_0 和第 1 层图像 G_1 特征构建, $t_r=9$ 。

(6)方案 6:特征空间由底层图像 G_0 、第 1 层图像 G_1 和第 2 层图像 G_2 特征构建, $t_r=11$ 。

(7)方案 7:特征空间由底层图像 G_0 、第 1 层图像 G_1 、第 2 层图像 G_2 和第 3 层图像 G_3 特征构建, $t_r=13$ 。

图 4 为不同 n_{tree} 下随机森林模型误差率。由图可见,当 $n_{\text{tree}} \in (0, 50]$ 时,模型误差波动较大;当 $n_{\text{tree}} \in$




图 4 随机森林模型误差率

Fig.4 Error rate of random forest model

(50, 100]时,模型误差波动趋于平缓;当 n_{tree} 超过200后,模型误差率逐步趋于稳定。这是因为若 n_{tree} 选择过小,随机森林算法会向决策树“塌陷”,导致分类精度有所下降,或出现过拟合现象。对于多尺度纹理特征(方案5—7),其稳定后的模型误差率优于单尺度纹理特征(方案1—4)。

图5为 n_{tree} 为50、100、200时,随机森林模型的分类型准确率。由图可见,当 $n_{\text{tree}}=50$ 时,多尺度纹理特征与单尺度纹理特征的分类型准确率没有明显区别;当 $n_{\text{tree}}=100$ 时,方案5、7的准确率分别为96.354%、97.396%,明显高于方案3、4的准确率(分别为95.313%、94.371%),但方案1、2、6的准确率相同,均为95.833%;当 $n_{\text{tree}}=200$ 时,多尺度纹理特征的分类型准确率明显优于单尺度纹理特征的分类型准确率。




图5 随机森林模型的分类型准确率

Fig.5 Classification accuracy of random forest model

图5反映了特征空间整体的分类型准确率,但未反映随机森林对单个缺陷的分类型准确率,因此本文给出了 n_{tree} 为50、100、200时的混淆矩阵,见附录C中的图C1。混淆矩阵可用于评判分类器精度,比较分类结果和实际值是否相符,本文用4×4维的矩阵表示。从图C1可以看出, n_{tree} 的变化对编码1、3的分类型精度影响较小,而对编码2、4的分类型精度影响较大。另外,对于编码2的误分类大多集中在编码4,而对于编码4的误分类也大多集中在编码2。这是因为编码2、4分别对应环切划伤缺陷、气隙缺陷,气隙缺陷本质是由于纵切划伤程度较深而造成,与环切划伤在放电机理上存在相似之处,故使得引发的局部放电现象也存在相似之处,所以对气隙缺陷和环切划伤缺陷的分类型存在较多误分类的情况。

3.2 基于gini指数的特征重要性排序

gini指数是指不同特征分割同一决策树节点时gini不纯度的变化值,该值越大说明该特征越重要。gini指数的计算公式见式(10)。

$$\begin{cases} \text{gini}(M) = 1 - \sum_{i=1}^{n_s} g_i^2 \\ \text{gini}(M, A) = \sum_{j=1}^m \frac{|M_j|}{|M|} \text{gini}(M_j) \end{cases} \quad (10)$$

其中, $\text{gini}(M)$ 为样本 M 的基尼指数; n_s 为样本 M 的

分类数,本文中 $n_s=4$; g_i 为样本 M 中,第 i 个分类发生的概率; $\text{gini}(M, A)$ 为特征 A 划分样本 M 后的基尼指数; M_j 为第 j 份样本的数量。

基于3.1节,本文选取决策树的数量 $n_{\text{tree}}=200$,决策树的分类方式由该节点的最优特征决定,对于不同的bootstrap数据集,其最优特征可能不同,因此本文基于gini指数对方案7中输入的164个特征量进行排序,完整排序结果见附录C中的表C1。gini指数的降低比例反映了特征量替换后节点gini不纯度的降低值,数值越大表示变量越重要。

将gini指数降低比例超过0.01的33个特征量作为随机森林新的特征输入,并重新计算了随机森林的决策树数量 n_{tree} 和决策树分裂时的子特征数量 t_i ,其中子特征数量 t_i 根据经验公式取为6,将以上操作作为方案8。方案7、8的模型误差率和分类型准确率如图6所示。从图6(a)可以看出,使方案8的模型误差率稳定所需的 $n_{\text{tree}}=100$,仅为方案7($n_{\text{tree}}=200$)的50%,且方案8的模型误差率为0.0289,低于方案7的模型误差率(0.0313)。从图6(b)可以看出, n_{tree} 为50、100、200时,方案8的分类型准确率均高于方案7。




图6 方案7和方案8的随机森林模型性能对比

Fig.6 Performance comparison of random forest models between Scheme 7 and Scheme 8

综上所述可知,相比于原始的多尺度特征空间,即方案7,经过gini指数特征寻优后组成的特征空间使随机森林模型达到稳定所需的 n_{tree} 减少了50%,同时使模型误差率降低了2.84%,模型稳定后的识别准确率提高了1.04%。

3.3 识别算法对比

对BP神经网络、支持向量机和随机森林算法在多尺度纹理特征空间的分类准确率。将未经gini指数优化的多尺度纹理特征(共141个),作为识别算法的输入,各识别算法的分类准确率如表3所示。将经gini指数寻优后的多尺度纹理特征(共33个),作为识别算法的输入,各识别算法的分类准确率如表4所示。从表3、4可以看出,无论是未优化的特征空间,还是gini指数寻优后的特征空间,随机森林算法在识别准确率和算法耗时上,都优于BP神经网络和支持向量机算法。

表 3 优化特征前的算法性能比较

Table 3 Feature performance comparison among algorithms before feature optimization

算法	准确率 / %				耗时 / s
	尖端缺陷	环切划伤缺陷	金属微粒缺陷	气隙缺陷	
BP 神经网络	89.58	85.42	87.50	83.33	124.2
支持向量机	93.75	89.58	91.67	87.50	42.3
随机森林	100.00	95.83	100.00	95.83	3.3

表 4 优化特征后的算法性能比较

Table 4 Feature performance comparison among algorithms after feature optimization

算法	准确率 / %				耗时 / s
	尖端缺陷	环切划伤缺陷	金属微粒缺陷	气隙缺陷	
BP 神经网络	95.83	91.67	93.75	91.67	35.4
支持向量机	95.83	93.75	95.83	91.67	19.8
随机森林	100.00	100.00	100.00	95.83	1.2

4 结论

本文针对高铁列车中车载 EPR 电缆终端典型缺陷难以有效识别的问题,分别制作了含尖端、环切划伤、金属微粒、气隙缺陷的终端试样,并基于试验记录所得到的 PRPD 谱图,同时结合多尺度纹理特征与随机森林算法实现了对放电特征空间的寻优和典型缺陷类型的有效识别分类。结果表明:

(1)当随机森林中的决策树数量 n_{tree} 超过 200 时,使用多尺度纹理特征的模型误差率和分类准确率明显优于单尺度纹理特征,能较好地缺陷进行分类;

(2)由于气隙缺陷和划伤缺陷的放电机理存在相似处,二者在缺陷部位的局部放电特征同样存在相似处,导致二者的分类中较易出现误差,造成其识别率偏低,因此针对气隙缺陷和环切划伤缺陷的识别分类,还需要进一步的研究;

(3)与未经优化的特征空间相比,经 gini 指数寻优后的特征空间使随机森林达到稳定所需的 n_{tree} 减少了 50%,同时使模型的误差率减低了 2.84%,模型稳定后的识别准确率提高了 1.04%。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 吴广宁. 电气化铁道高电压工程[M]. 北京:中国铁道出版社, 2011:104-135.
- [2] 周利军,刘源,白龙雷,等. 高寒地区车载柔性电缆终端的局部放电特性与破坏机理[J]. 高电压技术,2019,45(1):189-195. ZHOU Lijun, LIU Yuan, BAI Longlei, et al. Partial discharge characteristics and breakdown mechanism for locomotive cable flexible terminal in alpine area[J]. High Voltage Engineering, 2019, 45(1): 189-195.
- [3] 李剑,孙才新,杜林,等. 局部放电灰度图像分维数的研究[J]. 中国电机工程学报,2002,22(8):123-127.
- LI Jian, SUN Caixin, DU Lin, et al. Study on fractal dimension of PD gray intensity image[J]. Proceedings of the CSEE, 2002, 22(8): 123-127.
- [4] 廖瑞金,杨丽君,孙才新,等. 基于局部放电主成分因子向量的油纸绝缘老化状态统计分析[J]. 中国电机工程学报,2006,26(14):114-119. LIAO Ruijin, YANG Lijun, SUN Caixin, et al. Aging condition assessment of oil-paper based on principal component and factor analysis of partial discharge[J]. Proceedings of the CSEE, 2006, 26(14): 114-119.
- [5] 陈伟根,杜杰,凌云,等. 变压器油纸绝缘气隙放电能量-小波矩特征及放电过程划分[J]. 电力自动化设备,2014,34(6): 89-95. CHEN Weigen, DU Jie, LING Yun, et al. Energy-wavelet moment characteristics of air-gap discharge in oil-paper insulation of transformer and partition of discharge process[J]. Electric Power Automation Equipment, 2014, 34(6): 89-95.
- [6] 苑津莎,尚海昆. 基于主成分分析和概率神经网络的变压器局部放电模式识别[J]. 电力自动化设备,2013,33(6):27-31. YUAN Jinsha, SHANG Haikun. Pattern recognition based on principal component analysis and probabilistic neural networks for partial discharge of power transformer[J]. Electric Power Automation Equipment, 2013, 33(6): 27-31.
- [7] 张晓虹,张亮,乐波,等. 基于局部放电的矩特征分析大电机主绝缘的老化[J]. 中国电机工程学报,2002,22(5):94-98. ZHANG Xiaohong, ZHANG Liang, LE Bo, et al. Analysis on aging condition of stator winding insulation of generator based on the moment characteristics of partial discharge[J]. Proceedings of the CSEE, 2002, 22(5): 94-98.
- [8] 魏振,齐波,左健,等. 基于局部放电图像特征的换流变压器油纸绝缘缺陷诊断方法[J]. 电网技术,2015,39(4):1160-1166. WEI Zhen, QI Bo, ZUO Jian, et al. A method to diagnose defects in oil-paper insulation of converter transformer based on image feature of partial discharge[J]. Power System Technology, 2015, 39(4): 1160-1166.
- [9] 史静,朱虹,邢楠,等. 一种多尺度时频纹理特征融合的场景分类算法[J]. 仪器仪表学报,2016,37(10):2333-2339. SHI Jing, ZHU Hong, XING Nan, et al. Multi-scale time-frequency texture feature fusion algorithm for scene classification [J]. Chinese Journal of Scientific Instrument, 2016, 37(10): 2333-2339.
- [10] 林雪,彭道黎,黄国胜,等. 结合多尺度纹理特征的遥感影像面向对象分类[J]. 测绘工程,2016,25(7):22-27. LIN Xue, PENG Daoli, HUANG Guosheng, et al. Object-oriented classification with multi-scale texture feature based on remote sensing image[J]. Engineering of Surveying and Mapping, 2016, 25(7): 22-27.
- [11] KETAN T, OSCAR C A, LU F, et al. Multi-scale analysis of color and texture for salient object detection[C]//2011 18th IEEE International Conference on Image Processing. Brussels, Belgium: IEEE, 2011: 2401-2404.
- [12] NORHENE G, MALEK K G L, ALIMA D M, et al. Multi-scale gray level and local difference for texture classification[J]. 2014 World Congress on Computer Applications and Information Systems. Hammamet, Tunisia: IEEE, 2014: 1-5.
- [13] KIM K I, JUNG K, PARK S H, et al. Support vector machines for texture classification[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(11): 1542-1550.
- [14] TAMURA H, MORI S, YAMAWAKI T. Textural features corresponding to visual perception[J]. IEEE Transactions on Systems Man and Cybernetics, 1978, 8(6): 460-473.
- [15] HARALICK R M, SHANMUGAM K, DINSTEN I H. Textural

- features for image classification[J]. IEEE Transactions on Systems, Man and Cybernetics, 1973, SMC-3(6):610-621.
- [16] KUMAR S S, GANESAN L. Texture classification using wavelet based laws energy measure[J]. International Journal of Soft Computing, 2008, 3(4):293-296.
- [17] 唐文彬, 郝重阳, 张宇, 等. 基于三阶累积量的图像特征提取新方法[J]. 中国图像图形学报, 1998, 3(11):922-925.
TANG Wenbin, HAO Chongyang, ZHANG Yu, et al. A novel method for extracting image feature based on triple cumulation[J]. Journal of Image and Graphics, 1998, 3(11):922-925.
- [18] PENG Xiaosheng, YANG Fan, WANG Ganjun, et al. A convolutional neural network-based deep learning methodology for recognition of partial discharge patterns from high-voltage cables[J]. IEEE Transactions on Power Delivery, 2019, 34(4):1460-1469.
- [19] 王守相, 周凯, 苏运. 基于随机森林算法的台区合理线损率估计方法[J]. 电力自动化设备, 2017, 37(11):39-45.
WANG Shouxiang, ZHOU Kai, SU Yun. Line loss rate estimation method of transformer district based on random forest algorithm[J]. Electric Power Automation Equipment, 2017, 37(11):39-45.
- [20] CHENG Zhe, YANG Fan, GAO Bing, et al. Partial discharge pattern recognition of XLPE cable based on vector quantization[J]. IEEE Transactions on magnetics, 2019, 55(6):1460-1464.

作者简介:



郭蕾

郭蕾(1981—),女,山东菏泽人,副教授,博士,主要研究方向为牵引供电系统建模和电能质量分析(E-mail: guolei_mail@swjtu.cn);

曹伟东(1995—),男,湖北荆门人,硕士研究生,主要研究方向为电缆局放放电特性及故障诊断(E-mail: wildoncao@163.com);

周利军(1978—),男,浙江杭州人,教授,博士,主要从事电气设备状态检测及故障诊断方面的教学与研究工作(E-mail: ljzhou10@163.com)。

(编辑 任思思)

Fault diagnosis method of EPR cable terminal based on multi-scale texture features

GUO Lei¹, CAO Weidong¹, ZHANG Jingkan¹, BAI Longlei¹, XING Limeng¹, XIANG Enxin², ZHOU Lijun¹

(1. College of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;

2. Electric Power Research Institute, Yunnan Power Grid Co., Ltd., Kunming 650217, China)

Abstract: In high-speed railway train, EPR (Ethylene Propylene Rubber) cable terminals often have many defects due to improper operation in the manufacturing process, resulting in PD (Partial Discharge) or even breakdown of the terminals. It is still a problem to be solved for the accurate classification of detected partial discharge signals. The terminal samples with four typical defects of tip, scratch, metal particle and air gap are made, and the discharge spectrum information of each sample is recorded by experiment. Based on the PD spectrum library obtained from the experiment, a new method is proposed to construct multi-scale PD spectrum space by image pyramid theory, from which the first-order texture statistics, the second-order texture statistics and the high-order texture statistics are extracted as the feature parameters of defect type recognition. At the same time, the random forest algorithm is introduced, and the feature space optimization is completed based on gini index, which realizes the correct classification of defect types. The results show that the model error rate and classification accuracy rate of multi-scale texture feature are significantly better than that of single scale texture feature, which can better classify the terminal typical defects, at the same time, because the discharge mechanism of air gap defect and scratch defect is similar, the partial discharge characteristics of both defects are similar, so the classification of air gap defect and scratch defect is prone to errors, resulting in low recognition rate. Further research on image feature parameters and recognition algorithm is needed.

Key words: EPR cable; typical defects; texture features; image pyramid; random forest algorithm; fault diagnosis

附录 A




图 A1 试验与识别方法流程

Fig.A1 Flowchart of test and identification method




图 A2 缺陷制作

Fig.A2 Defect making




图 A3 试验平台图

Fig.A3 Test platform diagram




图 A4 金属微粒缺陷下 PRPD 谱图变化

Fig.A4 Change of PRPD of metal particle defect




图 (c) 金属微粒缺陷

图 (d) 气隙缺陷

图 A5 不同缺陷下的 PRPD 典型谱图

Fig.A5 Typical PRPD with different defects

附录 B

表 B1 特征量编号及含义
Table B1 Numbers and meaning of characteristics

编号	含义	编号	含义	编号	含义	编号	含义	编号	含义
f1	第 1 层图像灰度直方图均值	f34	第 2 层图像 LBP 直方图峰态	f67	第 2 层图像 GLCM 纹理相关性	f100	第 2 层图像 L5R5 矩阵方差	f133	第 4 层图像 L5S5 矩阵能量
f2	第 1 层图像灰度直方图方差	f35	第 2 层图像 LBP 直方图能量	f68	第 2 层图像 GLCM 纹理熵	f101	第 2 层图像 S5R5 矩阵能量	f134	第 4 层图像 L5S5 矩阵方差
f3	第 1 层图像灰度直方图偏斜度	f36	第 2 层图像 LBP 直方图方差	f69	第 3 层图像 GLCM 纹理角二阶矩	f102	第 2 层图像 S5R5 矩阵方差	f135	第 4 层图像 L5R5 矩阵能量
f4	第 1 层图像灰度直方图峰态	f37	第 3 层图像 LBP 直方图均值	f70	第 3 层图像 GLCM 纹理对比度	f103	第 2 层图像 E5S5 矩阵能量	f136	第 4 层图像 L5R5 矩阵方差
f5	第 1 层图像灰度直方图能量	f38	第 3 层图像 LBP 直方图方差	f71	第 3 层图像 GLCM 纹理相关性	f104	第 2 层图像 E5S5 矩阵方差	f137	第 4 层图像 S5R5 矩阵能量
f6	第 1 层图像灰度直方图熵	f39	第 3 层图像 LBP 直方图偏斜度	f72	第 3 层图像 GLCM 纹理熵	f105	第 2 层图像 E5R5 矩阵能量	f138	第 4 层图像 S5R5 矩阵方差
f7	第 2 层图像灰度直方图均值	f40	第 3 层图像 LBP 直方图峰态	f73	第 4 层图像 GLCM 纹理角二阶矩	f106	第 2 层图像 E5R5 矩阵方差	f139	第 4 层图像 E5S5 矩阵能量
f8	第 2 层图像灰度直方图方差	f41	第 3 层图像 LBP 直方图能量	f74	第 4 层图像 GLCM 纹理对比度	f107	第 2 层图像 R5R5 矩阵能量	f140	第 4 层图像 E5S5 矩阵方差
f9	第 2 层图像灰度直方图偏斜度	f42	第 3 层图像 LBP 直方图熵	f75	第 4 层图像 GLCM 纹理相关性	f108	第 2 层图像 R5R5 矩阵方差	f141	第 4 层图像 E5R5 矩阵能量
f10	第 2 层图像灰度直方图峰态	f43	第 4 层图像 LBP 直方图均值	f76	第 4 层图像 GLCM 纹理方差	f109	第 2 层图像 S5S5 矩阵能量	f142	第 4 层图像 E5R5 矩阵方差
f11	第 2 层图像灰度直方图能量	f44	第 4 层图像 LBP 直方图方差	f77	第 1 层图像 L5E5 矩阵能量	f110	第 2 层图像 S5S5 矩阵方差	f143	第 4 层图像 R5R5 矩阵能量
f12	第 2 层图像灰度直方图熵	f45	第 4 层图像 LBP 直方图偏斜度	f78	第 1 层图像 L5E5 矩阵方差	f111	第 2 层图像 E5E5 矩阵能量	f144	第 4 层图像 R5R5 矩阵方差
f13	第 3 层图像灰度直方图均值	f46	第 4 层图像 LBP 直方图峰态	f79	第 1 层图像 L5S5 矩阵能量	f112	第 2 层图像 E5E5 矩阵方差	f145	第 4 层图像 S5S5 矩阵能量
f14	第 3 层图像灰度直方图方差	f47	第 4 层图像 LBP 直方图能量	f80	第 1 层图像 L5S5 矩阵方差	f113	第 3 层图像 L5E5 矩阵能量	f146	第 4 层图像 S5S5 矩阵方差
f15	第 3 层图像灰度直方图偏斜度	f48	第 4 层图像 LBP 直方图熵	f81	第 1 层图像 L5R5 矩阵能量	f114	第 3 层图像 L5E5 矩阵方差	f147	第 4 层图像 E5E5 矩阵能量
f16	第 3 层图像灰度直方图峰态	f49	第 1 层图像 Tamura 纹理粗糙度	f82	第 1 层图像 L5R5 矩阵方差	f115	第 3 层图像 L5S5 矩阵能量	f148	第 4 层图像 E5E5 矩阵方差
f17	第 3 层图像灰度直方图能量	f50	第 1 层图像 Tamura 纹理对比度	f83	第 1 层图像 S5R5 矩阵能量	f116	第 3 层图像 L5S5 矩阵方差	f149	第 1 层图像三阶矩
f18	第 3 层图像灰度直方图熵	f51	第 1 层图像 Tamura 纹理方向度	f84	第 1 层图像 S5R5 矩阵方差	f117	第 3 层图像 L5R5 矩阵能量	f150	第 1 层图像三阶累积量
f19	第 4 层图像灰度直方图均值	f52	第 2 层图像 Tamura 纹理粗糙度	f85	第 1 层图像 E5S5 矩阵能量	f118	第 3 层图像 L5R5 矩阵方差	f151	第 1 层图像四阶矩
f20	第 4 层图像灰度直方图方差	f53	第 2 层图像 Tamura 纹理对比度	f86	第 1 层图像 E5S5 矩阵方差	f119	第 3 层图像 S5R5 矩阵能量	f152	第 1 层图像四阶累积量
f21	第 4 层图像灰度直方图偏斜度	f54	第 2 层图像 Tamura 纹理方向度	f87	第 1 层图像 E5R5 矩阵能量	f120	第 3 层图像 S5R5 矩阵方差	f153	第 2 层图像三阶矩
f22	第 4 层图像灰度直方图峰态	f55	第 3 层图像 Tamura 纹理粗糙度	f88	第 1 层图像 E5R5 矩阵方差	f121	第 3 层图像 E5S5 矩阵能量	f154	第 2 层图像三阶累积量
f23	第 4 层图像灰度直方图能量	f56	第 3 层图像 Tamura 纹理对比度	f89	第 1 层图像 R5R5 矩阵能量	f122	第 3 层图像 E5S5 矩阵方差	f155	第 2 层图像四阶矩
f24	第 4 层图像灰度直方图熵	f57	第 3 层图像 Tamura 纹理方向度	f90	第 1 层图像 R5R5 矩阵方差	f123	第 3 层图像 E5R5 矩阵能量	f156	第 2 层图像四阶累积量
f25	第 1 层图像 LBP 直方图均值	f58	第 4 层图像 Tamura 纹理粗糙度	f91	第 1 层图像 S5S5 矩阵能量	f124	第 3 层图像 E5R5 矩阵方差	f157	第 3 层图像三阶矩

续表

编号	含义	编号	含义	编号	含义	编号	含义	编号	含义
f26	第 1 层图像 LBP 直方图方差	f59	第 4 层图像 Tamura 纹理对比度	f92	第 1 层图像 S5S5 矩阵方差	f125	第 3 层图像 R5R5 矩阵能量	f158	第 3 层图像三阶累积量
f27	第 1 层图像 LBP 直方图偏斜度	f60	第 4 层图像 Tamura 纹理方向度	f93	第 1 层图像 E5E5 矩阵能量	f126	第 3 层图像 R5R5 矩阵方差	f159	第 3 层图像四阶矩
f28	第 1 层图像 LBP 直方图峰态	f61	第 1 层图像 GLCM 纹理角二阶矩	f94	第 1 层图像 E5E5 矩阵方差	f127	第 3 层图像 S5S5 矩阵能量	f160	第 3 层图像四阶累积量
f29	第 1 层图像 LBP 直方图能量	f62	第 1 层图像 GLCM 纹理对比度	f95	第 2 层图像 L5E5 矩阵能量	f128	第 3 层图像 S5S5 矩阵方差	f161	第 4 层图像三阶矩
f30	第 1 层图像 LBP 直方图熵	f63	第 1 层图像 GLCM 纹理相关性	f96	第 2 层图像 L5E5 矩阵方差	f129	第 3 层图像 E5E5 矩阵能量	f162	第 4 层图像三阶累积量
f31	第 2 层图像 LBP 直方图均值	f64	第 1 层图像 GLCM 纹理熵	f97	第 2 层图像 L5S5 矩阵能量	f130	第 3 层图像 E5E5 矩阵方差	f163	第 4 层图像四阶矩
f32	第 2 层图像 LBP 直方图方差	f65	第 2 层图像 GLCM 纹理角二阶矩	f98	第 2 层图像 L5S5 矩阵方差	f131	第 4 层图像 L5E5 矩阵能量	f164	第 4 层图像四阶累积量
f33	第 2 层图像 LBP 直方图偏斜度	f66	第 2 层图像 GLCM 纹理对比度	f99	第 2 层图像 L5R5 矩阵能量	f132	第 4 层图像 L5E5 矩阵方差		

附录 C

$n_{tree}=50$		预测值				$n_{tree}=100$		预测值				$n_{tree}=200$		预测值			
		1	2	3	4			1	2	3	4			1	2	3	4
真实值	1	48				真实值	1	48				真实值	1	47			
	2		45		3		2		43		5		2		46		2
	3			47	1		3			48			3			48	
	4			3	45		4		3		45		4		3		45

(a) 方案 1

$n_{tree}=50$		预测值				$n_{tree}=100$		预测值				$n_{tree}=200$		预测值			
		1	2	3	4			1	2	3	4			1	2	3	4
真实值	1	48				真实值	1	46		2		真实值	1	48			
	2		1	41	6		2		43		5		2		46		2
	3				48		3			48			3		1	47	
	4		1		47		4		1		47		4		4		44

(b) 方案 2

$n_{tree}=50$		预测值				$n_{tree}=100$		预测值				$n_{tree}=200$		预测值			
		1	2	3	4			1	2	3	4			1	2	3	4
真实值	1	48				真实值	1	46		2		真实值	1	48			
	2		42		6		2		44		4		2		43		5
	3		1		47		3			48			3		2		46
	4				48		4		3		45		4		4		44

(c) 方案 3

$n_{tree}=50$		预测值				$n_{tree}=100$		预测值				$n_{tree}=200$		预测值			
		1	2	3	4			1	2	3	4			1	2	3	4
真实值	1	45		1	2	真实值	1	46		2		真实值	1	46		2	
	2		42		6		2		44		4		2		43		5
	3				48		3			48			3			48	
	4		2		46		4		2	3	43		4		2	1	45

(d) 方案 4

$n_{tree}=50$		预测值				$n_{tree}=100$		预测值				$n_{tree}=200$		预测值			
		1	2	3	4			1	2	3	4			1	2	3	4
真实值	1	48				真实值	1	48				真实值	1	48			
	2		43		5		2		46		2		2		47		1
	3		2	1	45		3			48			3		1	47	
	4		2		46		4		5		43		4		3		45

(e) 方案 5

$n_{tree}=50$		预测值				$n_{tree}=100$		预测值				$n_{tree}=200$		预测值			
		1	2	3	4			1	2	3	4			1	2	3	4
真实值	1	45		3		真实值	1	48				真实值	1	47		1	
	2		1	44	3		2		45		3		2		47		1
	3				48		3			46	2		3		1	17	
	4		2		46		4		3		45		4		2		46

(f) 方案 6

$n_{tree}=50$		预测值				$n_{tree}=100$		预测值				$n_{tree}=200$		预测值			
		1	2	3	4			1	2	3	4			1	2	3	4
真实值	1	47		1		真实值	1	47		1		真实值	1	48			
	2		42		6		2		46		2		2		46		2
	3				48		3			48			3			48	
	4		1		47		4		1		47		4		1	1	46

(g) 方案 7

图 C1 随机森林混淆矩阵

Fig.C2 Random forest confusion matrix

表 C1 gini 指数排序

Table C1 Sorting of gini index

序号	编码	gini 指数降低比例	序号	编码	gini 指数降低比例	序号	编码	gini 指数降低比例
1	f136	0.02383	12	f146	0.01716	23	f21	0.01375
2	f58	0.02144	13	f132	0.017	24	f163	0.01369
3	f145	0.01969	14	f45	0.01687	25	f161	0.01363
4	f112	0.01896	15	f73	0.01657	26	f142	0.01352
5	f134	0.01878	16	f43	0.01551	27	f141	0.0135
6	f54	0.01822	17	f111	0.01528	28	f133	0.01263
7	f76	0.01822	18	f48	0.01515	29	f19	0.0124
8	f47	0.01815	19	f164	0.0147	30	f75	0.01206
9	f162	0.0178	20	f148	0.01449	31	f44	0.01166
10	f147	0.01747	21	f20	0.01447	32	f140	0.01084
11	f59	0.01737	22	f135	0.01399	33	f60	0.01057