

DOI:10.12158/j.2096-3203.2020.05.007

# 基于 Kohonen 网络的典型绝缘缺陷局部放电模式识别

江杰波<sup>1</sup>, 陈珂<sup>1</sup>, 施永贵<sup>1</sup>, 张航伟<sup>2</sup>, 李洪杰<sup>2</sup>(1. 福建和盛高科技产业有限公司,福建 福州 350003;  
2. 西安交通大学电气工程学院,陕西 西安 710049)

**摘要:**针对变电站环境局部放电识别面临的不可控干扰多、初始参数确定难的问题,提出将具有自组织竞争识别、抗干扰性强的 Kohonen 网络用于干扰环境下绝缘缺陷的局部放电识别。首先,通过设计变电站放电典型绝缘缺陷获取多个样本数据,提取统计特征用于 Kohonen 网络训练。其次,分析 Kohonen 网络竞争层节点数对识别效果的影响,得出针对样本数据的最佳识别参数。最后,将 Kohonen 网络与常用的模式识别算法在同等条件下进行对比,验证其在多种放电识别时具有高稳定性与高识别率,及用于变电站环境局部放电识别的优越性。

**关键词:**Kohonen 网络;典型绝缘缺陷;局部放电;模式识别;统计特征参数

中图分类号:TM855

文献标志码:A

文章编号:2096-3203(2020)05-0043-06

## 0 引言

局部放电监测能有效反映开关设备的绝缘状态,对于配电网中变电站设备绝缘状态评估有着重要作用。在电力设备的实际监测中,仅通过局部放电频次和强度很难诊断出潜在故障的种类及具体位置,不利于后续检修工作高效进行。而通过模式识别可对监测到的局部放电进行识别分类,有助于检修人员结合变电站设备自身结构更快发现故障,在实际工作中意义重大<sup>[1-4]</sup>。

在识别局部放电的过程中,需要通过合适的分类方法对提取出的特征值进行分类,这直接影响识别的准确程度。目前,局部放电识别研究中常见的分类方法包括:统计识别,如 Bayes 分类、Fisher 分类;人工神经网络,如误差方向传播(back propagation, BP)神经网络、径向基函数(radial basis function, RBF)神经网络、对偶传播神经网络(counter propagation networks, CPN);支持向量机等<sup>[5-7]</sup>。神经网络因其优异的并行处理、自适应、非线性求解能力而应用广泛,但在可靠性及实用性方面存在缺陷。以 BP 神经网络为例,其存在易受非典型数据干扰、初始权值阈值难确定、算法计算收敛慢等缺陷,限制了其在实际工程中的应用<sup>[8-11]</sup>。

由于变电站设备工作环境复杂,不可控干扰多,传统的神经网络识别测得的局放信号往往效果不佳<sup>[12]</sup>。因此,文中引入 Kohonen 网络来解决变电站的局部放电识别问题。Kohonen 网络属于自组织竞争型神经网络,由 Teuvo Kohonen 提出,以无导师方式进行自组织训练和判断,在其他领域的聚类分

析中已有广泛应用<sup>[13-17]</sup>。此外,Kohonen 网络具有良好的抗干扰能力,对变电站环境局部放电信号识别具有较大优势。

文中首先研究 Kohonen 网络的工作原理特征,并构建 Kohonen 网络;其次,模拟变电站环境的典型绝缘缺陷,获得充足的局部放电数据,提取统计特征用于 Kohonen 网络的训练识别;最后,研究 Kohonen 网络竞争层节点数对识别效果的影响,并将 Kohonen 网络与其他分类算法在同一特征量下的识别效果进行对比,验证其用于变电站环境局部放电识别的优越性。

## 1 Kohonen 网络基本原理

生物的神经结构中有一种“侧抑制”现象,即某一神经元开始活跃时,其周围神经元的活跃度受到抑制。这种现象显示了不同神经元之间的相互竞争,活跃度最强的神经元产生的抑制作用会基本消除周围其他细胞的作用。Kohonen 网络通过模拟此类生物结构及现象进行自组织特征映射,调整网络权值,使网络达到收敛效果。Kohonen 网络中的神经元通过无监督竞争学习,对不同的输入模式产生不同的敏感特性,因此,特定的神经元可以充当某一输入模式的检测器。Kohonen 网络通过此方式实现数据集的聚类<sup>[18-19]</sup>。

在结构上,Kohonen 网络一般由输入和竞争 2 层网络构成,如图 1 所示。输入层神经元个数同输入样本向量维数一致;竞争层也称输出层,其节点呈二维阵列分布。输入层和竞争层之间的神经单元实现双向连接,同时竞争层各个神经元之间还有横向连接。

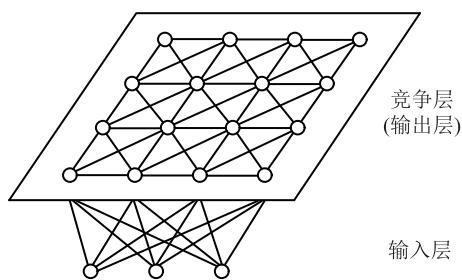


图 1 Kohonen 网络结构

Fig.1 Structure of Kohonen network

Kohonen 网络工作机理为：当提取出的样本特征向量进入输入层时，网络会计算特征向量与竞争层各节点在初始权重下的欧几里得距离，距离最小的节点成为获胜节点；由此调整获胜节点及其周围节点的连接权值，使得获胜节点及周边权值更靠近输入特征向量；通过反复训练，各节点之间的连接权值变得稳定，这一过程将数据之间的相似性表达到不同节点间的连接权值上，使得同类节点之间的权系数相近，而不同类别节点的权系数则差别明显。Kohonen 网络算法具体步骤为：

(1) 连接权值初始化。对  $n$  个输入节点到  $m$  个输出节点的连接权值进行赋值，取值为较小的随机数，此时时间  $t=0$ 。

(2) 网络输入。在输入数据归一化后，从输入层提取第  $k$  个局部放电特征向量  $\mathbf{x}_k$ 。

$$\mathbf{x}_k = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i, \dots, \mathbf{x}_n) \quad (1)$$

式中： $n$  为输入向量维数。

(3) 距离计算。计算输入与全部输出节点连接权值的距离：

$$d_j = \sum_{i=1}^n (\mathbf{x}_i - \mathbf{w}_{ij})^2 \quad j = 1, 2, \dots, m \quad (2)$$

式中： $\mathbf{x}_i$  为第  $i$  个输入节点的输入值； $\mathbf{w}_{ij}$  为节点  $i, j$  之间的权重； $m$  为竞争层节点数。

(4) 得出获胜节点。比较输出节点，得出获胜节点  $C$  为具有最小距离的节点，即：

$$\mathbf{d}_c = \arg \min_{j \in \{1, 2, \dots, m\}} \{d_j\} \quad (3)$$

(5) 权值调整。调整节点  $C$  所连接的权向量及其几何邻域  $N_c(t)$  内的节点连接权值，即：

$$\Delta \mathbf{w}_{ij} = h(t)(\mathbf{x}_i - \mathbf{w}_{ij}) \quad (4)$$

式中： $i=1, 2, \dots, m; j \in N_c(t)$ 。

可变学习速度  $\eta_t$  为：

$$\eta_t = \eta_0(1-t/T) \quad (5)$$

式中： $\eta_0$  为初始值； $T$  为充分大的收敛周期。

$\eta_t$  随时间推移而衰减，表明权值调整的幅度随着学习过程的进行越来越小，获胜节点所连接的权向量更能代表模式的本质属性。邻域  $N_c(t)$  也随学

习过程收缩，并在  $t$  充分大时收敛到节点  $C$ ，此时只训练获胜节点以实现权值调整。

(6) 输入下一个样本数据，且  $t=t+1$ ，转入第 2 步循环训练，直到训练完所有样本。

## 2 Kohonen 网络用于变电站环境局部放电识别

### 2.1 缺陷设置及实验环境

变电站电力设备产生局部放电的原因主要有：

(1) 制造工艺不良引起的产品质量缺陷，绝缘件(绝缘子、套管等)内部留有气隙、杂质等；

(2) 制造工艺不良或安装过程中引起擦划，使导体表面存在金属尖刺；

(3) 安装或维修过程中导致悬浮电位等放电；

(4) 绝缘器件表面受潮、污秽、凝露等<sup>[20-21]</sup>。

文中设计了针板放电、空穴放电、沿面放电以及悬浮放电 4 种典型绝缘缺陷模型，如图 2 所示。其中，针板放电模型采用一端金属尖端、一端平板电极，模拟变电站设备中金属凸起造成的绝缘缺陷；空穴放电模型则将具有通孔的环氧树脂板与普通环氧树脂板叠加粘合，模拟具有内部气隙的缺陷；沿面放电模型则采用将一定厚度的环氧树脂板夹在铜电极之间的方式模拟变电站设备的沿面缺陷；悬浮放电模型则通过在两极板之间放置一个悬浮的金属块来模拟悬浮电位缺陷。实验时，在上述放电模型的两极施加工频电压，并通过脉冲电流法获得放电数据。

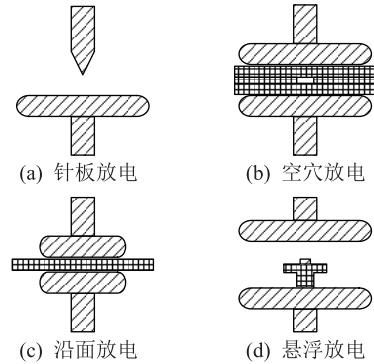


图 2 绝缘缺陷模型

Fig.2 Insulation defect models

通过更换各个缺陷中的相关部件，可以改变针板模型的尖端尖锐程度、空穴模型的空穴大小、沿面模型的环氧板厚度和悬浮模型的悬浮金属块位置，从而获得不同缺陷样本。同时，改变同一缺陷样本的外施电压，也可获得多组实验数据。根据缺陷样本产生有别于环境噪声的局部放电信号以及接近击穿时的外施电压，可以划分电压设置区间，

即进行四等分,得到 5 个等级的外施电压。以针板缺陷为例,在 3.2 kV 出现起始局部放电,在 14.6 kV 左右接近击穿,故将 4 kV, 6.5 kV, 9 kV, 10.5 kV, 14 kV 作为 5 个采集电压,模拟局部放电发展的不同阶段。随着放电阶段发展,统计特征发生改变,获取同一放电类型不同放电阶段的统计特征,验证识别算法不同统计特征下的识别效果。

实验环境方面,考虑变电站环境的特殊性,缺陷的局部放电数据选择在变电站强噪声条件下获取。局部放电获取过程中,实验设备未加外施电压时示波器的电压干扰峰值为 75~110 mV,且测量过程中的异常放电点均未除去,便于更好地验证干扰条件下 Kohonen 网络的有效性。

实验中共 4 种缺陷模型,每种缺陷模型设置 10 个不同的缺陷样本,每个样本分别在 5 个等级的外施电压下进行数据采集,共得到 200 个样本数据。除去 2 个无效样本(空穴样本 1 个、悬浮样本 1 个),共获得 198 组局部放电样本数据。

## 2.2 特征参数提取

将工频电压施加在缺陷上获得放电波形、频次等信息,此类信息不能直接作为神经网络的输入,需要通过特征参数提取将其转化为数值参数。局部放电二维谱图的形状统计特征是使用最为广泛的一种特征参数,通过定义的统计计算公式,以数值信息将放电峰值随相位分布  $H_{q\max}(\varphi)$ 、放电均值随相位分布  $H_{q\text{mean}}(\varphi)$ 、放电数随相位分布  $H_n(\varphi)$  及放电量随放电数分布  $H_q(n)$  等谱图形状表达出来。谱图中可提取的特征参数很多,但只有关键统计参数会影响识别正确率,参数设置过多反而影响神经网络训练识别速度。文中基于实际识别效果,设立 21 个特征参数,如表 1 所示。

表 1 统计特征参数设置

Table 1 Setting of statistical feature parameter

参数	$H_{q\max}(\varphi)$		$H_{q\text{mean}}(\varphi)$		$H_n(\varphi)$		$H_q(n)$
	+	-	+	-	+	-	
$Sk$	$Sk_1$	$Sk_2$	$Sk_3$	$Sk_4$	$Sk_5$	$Sk_6$	$Sk_7$
$Ku$	$Ku_1$	$Ku_2$	$Ku_3$	$Ku_4$	$Ku_5$	$Ku_6$	$Ku_7$
$Q$	$Q_1$		$Q_2$		$Q_3$		
$cc$	$cc_1$		$cc_2$		$cc_3$		
$\Phi$			$\Phi$				

表 1 中,  $Sk$ ,  $Ku$  分别为谱图相较正态分布的形状偏斜水平和陡峭水平;  $Q$ ,  $cc$  分别为谱图正负半周的放电量不对称程度和相关性;  $\Phi$  为正负半周起始放电相位的不对称度; “+”, “-” 符号下的参数值分别对应谱图的正、负半周;  $H_q(n)$  不分正、负半周,只

提取偏斜度及陡峭度 2 个参数。

局部放电的谱图可按照放电相位正、负分为 2 个部分,每一部分均可视作一个概率密度分布函数,进而提取出 2 类统计参数。一类可由正态分布特征量直接得出,如偏斜度  $Sk$ 、陡峭度  $Ku$ ;另一类为衡量正、负半周谱图关联程度的参数,如互相关系数  $cc$ 、放电量因数  $Q^{[22-23]}$ 。

## 2.3 Kohonen 网络的初始化及学习算法

Kohonen 网络算法流程如图 3 所示。Kohonen 网络按照设置的学习次数迭代学习,在每次迭代中,根据迭代次数及上次迭代参数(或初始参数)计算此次学习的速率及临域半径;之后随机从训练数据中抽取 1 组,依次找出优胜节点,并找出其邻域内节点;由 Kohonen 网络调整节点之间的连接权值,完成此次学习进程。

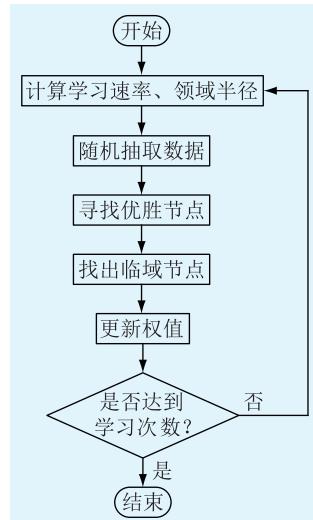


图 3 Kohonen 网络算法流程

Fig.3 Algorithm flow of Kohonen network

对 Kohonen 网络进行初始化。由于文中设置的特征参数为 21 个,故确定 Kohonen 网络的输入层节点个数为 21。Kohonen 网络的竞争层节点数为  $n^2$  ( $n > 0$ ),取  $n=5$ ,即竞争层节点数为 25。同时,设置网络最大学习速率为 0.1,最小学习速率为 0.01,节点的临域半径则处于区间(0.6,2)。

## 3 Kohonen 网络识别效果

### 3.1 Kohonen 网络竞争层节点数对识别效果的影响

在实验样本识别中发现,Kohonen 网络的权重、可变学习率初始值除影响收敛速度外,对 Kohonen 网络的最终识别效果基本无影响。Kohonen 网络的自身竞争层节点数直接关系计算参数,对识别效果影响较大。故主要针对竞争层节点数进行分析。

为使 Kohonen 网络识别样本数据时获得最佳性能,对竞争层节点数分别为 9,16,25,36 的 Kohonen 网络识别效果进行对比。实验中共获得 198 组样本数据,为保证训练及识别效果,每次从中随机抽取 150 组数据进行训练,48 组用于验证学习效果。为保证 150 个样本分布均匀,每种缺陷的样本个数为 30~40,否则将重新抽取直至满足训练要求。150 个训练样本中各 Kohonen 网络共重复训练及分类 10 次,每次之间互不干扰,且单次训练识别使用同样的随机数据,除节点数外,迭代次数等参数均一致,保证了对比的可信性。识别结果及正确率如表 2、表 3 所示。

表 2 Kohonen 网络不同竞争层节点数的识别数

Table 2 Identified number of Kohonen network under different competition layer number

竞争层 节点数	正确识别数/识别总数				
	针板放电	空穴放电	沿面放电	悬浮放电	总体
9	102/126	104/117	111/122	93/115	410/480
16	109/126	108/117	109/122	98/115	424/480
25	119/126	112/117	113/122	108/115	452/480
36	115/126	113/117	110/122	104/115	442/480

表 3 Kohonen 网络不同竞争层节点数的识别正确率

Table 3 Identification accuracy rate of Kohonen network under different competition node number

竞争层 节点数	识别正确率/%				
	针板放电	空穴放电	沿面放电	悬浮放电	总体
9	81.0	88.9	91.0	80.9	85.4
16	86.5	92.3	89.3	85.2	88.3
25	94.4	95.7	92.6	93.9	94.2
36	91.3	96.6	90.2	90.4	92.1

由表 3 可知,4 种竞争层节点的平均总识别率分别为 85.4%,88.3%,94.2%,92.1%;10 次识别的总识别率方差分别为 0.012 6,0.002 4,0.002 1,0.006 4;平均单次计算时间为 0.243 s,0.268 s,0.290 s,0.741 s。分析得出:

- (1) 对于沿面放电,表中各网络的识别效果均在 90% 左右,浮动较小,识别效果较稳定;
- (2) 对于空穴放电,随着竞争层节点增加,其识别率逐渐上升,后趋于稳定;
- (3) 对于针板放电和悬浮放电,其识别正确率随着竞争层节点的增加,先显著上升,再小幅下降;
- (4) 竞争层节点数为 25,36 时,对各类放电的识别方差较小,识别率较稳定,识别速度较快,整体识别效果较好,竞争层节点数为 25 时效果更佳。

竞争层节点数为 25 时的优胜节点分布如图 4 所示。图中①,②,③,④ 分别代表针板放电、空穴

放电、沿面放电和悬浮放电 4 类放电数据对应的所属节点,空白节点则不属于任何类。由图 4 可知,不同类别的优胜节点基本按块分布,说明训练后不同类别的样本数据能明显区分聚类。

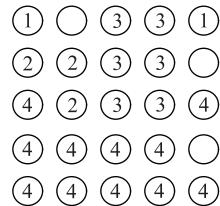


图 4 优胜节点分布

Fig.4 Distribution of winning nodes

### 3.2 不同识别算法效果对比

为验证 Kohonen 网络在识别变电站干扰环境局部放电特征参数时的优越性,选取常见模式识别算法与 Kohonen 网络进行对比分析。选取的算法包括统计识别技术中的 Bayes 分类器(基于最小错误率)、Fisher 分类器及人工神经网络中的 BP 算法、RBF 算法。在识别时各网络已调试到针对样本数据的最佳性能,Bayes 和 Fisher 分类器无外设参数。BP 算法采用弹性梯度下降法,主要参数包括:输入层节点数为 21;输出层节点数为 4;隐含层节点数为 25;最大训练次数为 1 000;最大失败次数为 5;学习速率为 0.01;最小梯度要求为  $10^{-10}$ 。RBF 算法主要参数:输入层节点数为 21;输出层节点数为 4;隐含层节点数为 23;RBF 扩展速度为 2;神经元最大数目为 198;2 次显示之间添加的神经元数目为 25。所取 Kohonen 网络竞争节点数为 25,各算法的训练识别过程与 3.1 节一致。

识别结果如表 4、表 5 所示。5 种算法的平均总识别率分别为 80.2%,77.9%,80.8%,87.9%,93.8%;10 次识别的总识别率方差分别为 0.009 6,0.057 8,0.472 1,0.031 8,0.002 2;平均单次计算时间分别为 0.067 s,0.052 s,1.013 s,0.980 s,0.291 s。

表 4 不同识别算法的识别数

Table 4 Identified number of different identification algorithms

识别 方法	正确识别数/识别总数				
	针板放电	空穴放电	沿面放电	悬浮放电	总体
Bayes	93/121	105/123	93/112	94/125	385/480
Fisher	85/121	111/123	86/112	92/125	374/480
BP	110/121	104/123	81/112	93/125	388/480
RBF	103/121	109/123	104/112	106/125	422/480
Kohonen	114/121	116/123	103/112	117/125	450/480

由表 4、表 5 识别结果可知:

- (1) Bayes 分类器对各类放电的识别效果较稳

表 5 不同识别算法的识别正确率  
Table 5 Identification accuracy rate of different identification algorithms

识别方法	识别正确率/%				
	针板放电	空穴放电	沿面放电	悬浮放电	总体
Bayes	76.9	85.4	83.0	80.9	80.2
Fisher	70.2	90.2	76.8	73.6	77.9
BP	90.9	84.6	72.3	74.4	80.8
RBF	85.1	88.6	92.9	84.8	87.9
Kohonen	94.2	94.3	92.0	93.6	93.8

定,识别速度快,但整体识别率较低;

(2) Fisher 分类器识别速度快,对空穴放电的识别效果较好,但对其他放电识别效果较差;

(3) BP 算法对针板放电识别正确率较高,但识别速度慢,且对沿面放电和悬浮放电识别较差;

(4) RBF 算法识别速度较慢,但整体识别效果较好,在沿面放电的识别中表现突出;

(5) Kohonen 网络整体识别效果较稳定,识别速度快,正确率也更高。

以上结论证明了 Kohonen 网络在识别放电样本数据时的优越性,这与其自组织识别、抗干扰性强的特点相符。

#### 4 结语

文中引入具有自组织学习能力和良好抗干扰特性的 Kohonen 网络算法,解决变电站环境干扰下局部放电识别困难的问题。通过设置符合变电站缺陷特点的典型绝缘缺陷模型,改变不同参数,在实际强干扰环境中进行实验,获得符合要求的样本数据,并通过统计特征提取方法,获得有效反映变电站局部放电特点的形状统计参数。

分析竞争层节点数对识别效果的影响,发现竞争层节点数为 25 时,各类放电的识别方差较小,识别效果较稳定,整体识别效果最好。此时,不同类别放电的优胜节点基本按块分布,识别方差小,稳定性好,正确率高。Kohonen 网络与常用的模式识别算法在识别效果上的对比分析表明,在强干扰条件下,Kohonen 网络仍具有稳定、识别率高的特点,且整体识别效果佳、放电类型识别敏感。

#### 参考文献:

- [1] KREUGER F H, GULSKI E. Classification of partial discharges [J]. IEEE Transactions on Electrical Insulation, 1993, 28(6): 917-931.
- [2] WU Y, WANG C, CHEN Y, et al. Influence of spacer insulator material temperature characteristics on its electric properties [J]. Global Energy Interconnection, 2019, 2(1): 71-77.
- [3] BAUG A, CHOUDHURY N R, GHOSH R, et al. Identification of

single and multiple partial discharge sources by optical method using mathematical morphology aided sparse representation classifier[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2017, 24(6): 3703-3712.

- [4] 李通,薛峰. UHF 局放检测技术在 GIS 故障诊断中应用与分析[J]. 供用电, 2018, 35(12): 80-88.
- LI Tong, XUE Feng. Application and analysis of UHF partial discharge detection technology in GIS fault diagnosis[J]. Distribution & Utilization, 2018, 35(12): 80-88.
- [5] SAHOO N C, SALAMA M M A, BARTNIKAS R. Trends in partial discharge pattern classification:a survey[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2005, 12(2): 248-264.
- [6] RAYMOND W J K, ILLIAS H A, BAKAR A H A, et al. Partial discharge classifications: review of recent progress[J]. Measurement, 2015, 68: 164-181.
- [7] 唐志国,唐铭泽,李金忠,等. 电气设备局部放电模式识别研究综述[J]. 高电压技术, 2017(7): 173-187.
- TANG Zhiguo, TANG Mingze, LI Jinzhong, et al. Review on partial discharge pattern recognition of electrical equipment [J]. High Voltage Engineering, 2017(7): 173-187.
- [8] 代杰杰,滕莹冰,龚越明. 基于区间集聚类分析的电力设备状态异常检测方法[J]. 电力信息与通信技术, 2019, 17(11): 1-6.
- DAI Jiejie, TENG Yingbing, GONG Yueming. Power equipment state anomaly detection method based on interval set theory and clustering analysis[J]. Electric Power Information and Communication Technology, 2019, 17(11): 1-6.
- [9] GUDISE V G, VENAYAGAMOORTHY G K. Comparison of particle swarm optimization and backpropagation as training algorithms for neural networks[C]//Proceedings of the 2003 IEEE Swarm Intelligence Symposium. IEEE, 2003.
- [10] 王嵘冰,徐红艳,李波,等. BP 神经网络隐含层节点数确定方法研究[J]. 计算机技术与发展, 2018, 28(4): 37-41.
- WANG Rongbing, XU Hongyan, LI Bo, et al. Research on method of determining hidden layer nodes in BP neural network [J]. Computer Technology and Development, 2018, 28(4): 37-41.
- [11] LIU W, WANG Z, LIU X, et al. A survey of deep neural network architectures and their applications [J]. Neurocomputing, 2017, 234: 11-26.
- [12] KOHONEN T. Self-organization and associative memory[M]. Berlin: Springer-Verlag, 1984.
- [13] 李宗福,邓琼波,李桓. Kohonen SOFM 神经网络及其演化研究[J]. 计算机工程与设计, 2004, 25(10): 1729-1730.
- LI Zongfu, DENG Qiongbo, LI Huan. Research on Kohonen SOFM neural network and its evolution [J]. Computer Engineering and Design, 2004, 25(10): 1729-1730.
- [14] 李燕青,杜莹莹. 基于双维度顺序填补框架与改进 Kohonen 天气聚类的光伏发电短期预测[J]. 电力自动化设备, 2019, 39(1): 60-65.
- LI Yanqing, DU Yingying. Short-term photovoltaic power fore-

- casting based on double-dimensional sequential imputation framework and improved Kohonen clustering [ J ]. Electric Power Automation Equipment, 2019, 39(1) :60-65.
- [ 15 ] DLUGOSZ R, KOLASA M, PEDRYCZ W, et al. Parallel programmable asynchronous neighborhood mechanism for WTM Kohonen network implemented in CMOS technology[ J ]. IEEE Transactions on Neural Networks, 2011, 22(12) :2091-2104.
- [ 16 ] SINGH U P, TIWARI A, SINGH R K, et al. Kohonen neural network model reference for nonlinear discrete time systems [ C ]//International Conference on Computational Intelligence & Communication Technology. IEEE, 2017.
- [ 17 ] PAL N R, BEZDEK J C, TSAO C K. Generalized clustering networks and Kohonen's self-organizing scheme [ J ]. IEEE Transactions on Neural Networks, 1993, 4(4) :549-557.
- [ 18 ] KOHONEN T, OJA E, SIMULA O, et al. Engineering applications of the self-organizing map[ J ]. Proceedings of the IEEE, 1996, 84(10) :1358-1384.
- [ 19 ] 钱家驷,袁大陆. 高压开关柜:结构、计算、运行、发展[ M ]. 北京:中国电力出版社,2006.  
QIAN Jiali, YUAN Dalu. High voltage switchgear; structure, calculation, operation, development [ M ]. Beijing: China Electric Power Press, 2006.
- [ 20 ] SEO I J, KHAN U A, HWANG J S, et al. Identification of insulation defects based on chaotic analysis of partial discharge in HVDC superconducting cable[ J ]. IEEE Transactions on Applied Superconductivity, 2015, 25(3) :1-5.
- [ 21 ] GULSKI E, KREUGER F H. Computer-aided recognition of discharge sources[ J ]. IEEE Transactions on Electrical Insulation, 1992, 27(1) :82-92.
- [ 22 ] 周沙,景亮. 基于矩特征与概率神经网络的局部放电模式识别[ J ]. 电力系统保护与控制, 2016, 44(3) :98-102.  
ZHOU Sha, JING Liang. Pattern recognition of partial discharge based on moment features and probabilistic neural network [ J ]. Power System Protection and Control, 2016, 44 (3) :98-102.
- [ 23 ] 褚鑫,张建文,韩刚,等. 统计特征参数及多分类 SVM 的局部放电类型识别[ J ]. 电测与仪表, 2015, 52(7) :35-39.  
CHU Xin, ZHANG Jianwen, HAN Gang, et al. Partial discharge pattern recognition based on statistical parameters and multi-classifications SVM [ J ]. Electrical Measurement & Instrumentation, 2015, 52(7) :35-39.

作者简介:



江杰波

江杰波(1984),男,学士,工程师,从事电力设备在线监测与故障诊断相关工作(E-mail:1132997248@qq.com);

陈珂(1985),男,学士,工程师,从事电力泛在物联网感知设备及电力设备故障诊断相关工作;

施永贵(1981),男,硕士,高级工程师,从事电力设备在线监测及状态评估相关工作。

## Partial discharge recognition of typical insulation defect based on Kohonen network

JIANG Jiebo<sup>1</sup>, CHEN Ke<sup>1</sup>, SHI Yonggui<sup>1</sup>, ZHANG Hangwei<sup>2</sup>, LI Hongjie<sup>2</sup>

( 1. Fujian Hoshing Hi-Tech Industrial Co., Ltd., Fuzhou 350003, China;

2. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** Aim at the problem that the uncontrollable interference faced by the partial discharge identification in substation, and the initial parameters of the existing identification method are difficult to determine. Design defects that meet the discharge characteristics of the substation. Multiple sample datas are collected combined with the statistical characteristic parameters extraction method. Based on the Kohonen network with self-organizing competition recognition and strong anti-interference characteristics, new method suitable for partial discharge identification in substation is presented. By exploring the influence of the Kohonen network's parameters on its recognition effect, the recognition effect is optimized. Then by comparing the network with the commonly used pattern recognition algorithm under the same conditions, high stability and high recognition rate of Kohonen network are proved, and excellent performance in partial discharge identification of substation is verified.

**Keywords:** Kohonen network; typical insulation defects; partial discharge; pattern recognition; statistical feature parameter

(编辑 吴楠)