

# 用于局部放电模式的深度置信网络方法

张新伯<sup>1</sup>, 唐炬<sup>1</sup>, 潘成<sup>1</sup>, 张晓星<sup>1</sup>, 金森<sup>1</sup>, 杨东<sup>1</sup>, 郑建<sup>2</sup>, 汪挺<sup>2</sup>

(1. 武汉大学 电气工程学院, 湖北省 武汉市 430072;

2. 国网山东省电力公司电力科学研究院, 山东省 济南市 250002)

## Research of Partial Discharge Recognition Based on Deep Belief Nets

ZHANG Xinbo<sup>1</sup>, TANG Ju<sup>1</sup>, PAN Cheng<sup>1</sup>, ZHANG Xiaoxing<sup>1</sup>, JIN Miao<sup>1</sup>,  
YANG Dong<sup>1</sup>, ZHENG Jian<sup>2</sup>, WANG Ting<sup>2</sup>

(1. School of Electrical Engineering, Wuhan University, Wuhan 430072, Hubei Province, China; 2. Shandong Electric Power Research Institute, State Grid Shandong Electric Power Company, Jinan 250002, Shandong Province, China)

**ABSTRACT:** Partial discharge (PD) caused by GIS internal insulation defects has complicated and highly dispersed characteristics, susceptible to operation environment. Traditional methods of PD pattern recognition based on statistical characteristics are strongly subjective in feature extraction, easy to lose some characteristic information and have low recognition rate of free metal particle. Therefore, a PD recognition method based on deep belief nets (DBN) is proposed that can automatically capture PD spectrum high-order characteristics, avoiding subjective influence in feature extraction. Also, this method can recognize type flaws of free metal particle with recognition time far less than those of support vector machine (SVM) and back propagation neural networks (BPNN), and therefore has practical values.

**KEY WORDS:** GIS; PD; deep belief nets; pattern recognition; recognition accuracy

**摘要:** 气体绝缘电器(gas insulated switchgear, GIS)内部绝缘缺陷产生的局部放电(partial discharge, PD), 特征表现较复杂, 分散性大, 易受运行环境影响, 而基于PD统计特征模式识别的传统方法, 特征量选取主观性较强, 且容易丢失部分特征信息, 尤其对自由金属微粒类型缺陷识别率较低。因此, 提出了一种基于深度置信网络(deep belief nets, DBN)的GIS设备内部PD模式识别方法, DBN能从数据中自主学习出高阶特征, 避免了特征量选取的主观影响, 能较好识别自由金属微粒类型缺陷, 且识别用时远低于支持向量机(support vector machine, SVM)和BP神经网络(back propagation neural networks, BPNN)算法, 作为对GIS设备PD模式识别的新方法具有一定的实用价值。

**关键词:** 气体绝缘电器; 局部放电; 深度置信网络; 模式识别; 识别准确率

**DOI:** 10.13335/j.1000-3673.pst.2016.10.048

基金项目: 国家863高技术基金项目(2015 AA050204)。

Project Supported by the National High Technology Research and Development of China (863 Program) (2015 AA050204)。

## 0 引言

气体绝缘电器(gas insulated switchgear, GIS)具有占地面积小、安全稳定性高、电磁污染低等优点, 得到了越来越广泛的应用<sup>[1-4]</sup>。然而在生产、运输、安装和长期运行的过程中, GIS设备内部不可避免存在的各种绝缘缺陷是诱发绝缘故障的主要因素。

绝缘故障早期常以局部放电(partial discharge, PD)形式表现, PD既是绝缘劣化的主要原因, 也是表征设备绝缘状况的重要特征量<sup>[5-8]</sup>。GIS内部绝缘缺陷形式多种多样, 不同缺陷类型引发的PD具有不同的表现形式, 对设备安全运行的影响和绝缘的危害程度也是不同的。利用不同绝缘缺陷下的PD产生机理的差异性, 通过对PD信号检测和特征分析, 可以识别绝缘缺陷类型, 评估设备的绝缘状态, 及时发现故障征兆, 实现故障预警, 为制定合理的检修计划提供科学依据<sup>[9]</sup>。

国内外学者对GIS设备PD模式识别做了大量研究工作, 其中BP神经网络(back propagation neural networks, BPNN)和支持向量机(support vector machine, SVM)得到了广泛应用。但BPNN在训练中存在过度拟合、易陷入局部最优解陷阱以及收敛速度慢等至今尚未完全解决的问题<sup>[10-11]</sup>。SVM借助二次规划来求解支持向量, 二次规划的过程涉及 $m$ 阶矩阵的计算,  $m$ 为样本数量, 运算量和运算时间随样本量的增大急剧攀升。PD特征提取通常采用统计特征法、分形特征法和矩特征法等<sup>[12-14]</sup>。但在特征量选取上具有一定主观性, 信息丢失严重, 导致识别率降低, 尤其经常对自由金属微粒缺陷错误识别。深度学习多隐层的神经网络具有优异的特征学习能力, 能从海量数据中自动学习

出特征信息，避免了特征量人为选择的主观性，自2006年提出之后在图像识别和语音识别等很多领域取得了良好的效果<sup>[15-17]</sup>，但将深度学习应用于PD模式识别的研究很少，未见用于实际的成功案例。作者尝试将深度学习理论应用于GIS设备PD模式识别，建立一种基于深度置信网络的局部放电模式识别方法。

本文结合GIS设备在线监测与故障诊断的现有技术，在实验室模拟了GIS设备内4类典型绝缘缺陷产生的PD信号，并获取了大量的实验数据，用于建立PD图谱数据库，采用受限玻尔兹曼机构建深度置信网络(deep belief nets, DBN)，通过所构建网络从放电数据中自主学习特征信息，实现放电类型划分。另一方面，从放电图谱中提取8个统计特征量，输入SVM和BP神经网络分类器进行识别，将识别准确率与前面DBN的识别准确率进行对比，结果显示将DBN应用于PD模式识别领域取得了令人满意的效果。

### 1 受限玻尔兹曼机

玻尔兹曼机(Boltzmann machine, BM)起源于统计物理学，它是一种基于能量函数的概率建模方法，所建模型具有比较完备的物理解释和严格的数理统计理论作支撑。BM网络节点分为可见单元(visible unit)和隐藏单元(hidden unit)，不同节点间通过权值表达单元之间的相关性。虽然玻尔兹曼机具有强大的无监督学习能力，但层间及层内单元间关联错综复杂，训练时间太长，计算量偏大，很难准确得到BM所表示的分布<sup>[18]</sup>。

受限玻尔兹曼机(restricted Boltzmann machine, RBM)是对BM的一种改进<sup>[19-20]</sup>，其模型如图1所示，具有一个可见层和隐藏层，神经元是随机的，一般用二进制的0、1分别表示未激活和激活2种状态，节点状态根据能量概率统计法则决定。与BM的区别是RBM同一层内单元相互独立无连接。因此，当可见层状态确定时，各隐藏层单元的状态条件独立；同理，隐藏层状态确定时，可见层单元状态也条件独立，从而降低了计算复杂性。




图1 RBM模型的结构  
Fig.1 Structure of RBM model

一个有  $n$  个可见单元  $\mathbf{v}=[v_1, v_2, \dots, v_n]$ 和  $m$  个隐藏单元  $\mathbf{h}=[h_1, h_2, \dots, h_m]$ 的RBM，能量函数定义为

$$E(\mathbf{v}, \mathbf{h}, \boldsymbol{\theta}) = -\mathbf{h}^T \mathbf{w} \mathbf{v} - \mathbf{c}^T \mathbf{v} - \mathbf{b}^T \mathbf{h} = \sum_k c_k v_k - \sum_j b_j h_j - \sum_{jk} w_{jk} v_k h_j \quad (1)$$

$$\boldsymbol{\theta} = \{W, a, b\} \quad (2)$$

式中： $v_i$ 为可见层第  $i$  个单元的状态； $h_j$ 为隐藏层第  $j$  个单元的状态； $w_{ij}$ 为可见单元  $i$  与隐藏单元  $j$  之间的连接权重参数； $a_i, b_j$ 分别为可见单元  $i$  和隐藏单元  $j$  上的偏置。RBM的状态概率服从正则分布，其处于  $\mathbf{v}, \mathbf{h}$  状态的概率为

$$p(\mathbf{v}, \mathbf{h}) = \frac{e^{-E(\mathbf{v}, \mathbf{h})}}{z} \quad (3)$$

$$z = \sum_{\mathbf{h}, \mathbf{v}} \exp[-E(\mathbf{v}, \mathbf{h})] \quad (4)$$

式中  $z = \sum_{\mathbf{h}, \mathbf{v}} \exp[-E(\mathbf{v}, \mathbf{h})]$  为配分函数，起归一化因子的作用。当可见单元状态确定时，各隐藏单元的状态相互间呈条件独立关系，第  $j$  个隐藏单元激活的概率为

$$p(h_j = 1 | \mathbf{v}) = f_{\text{sigmoid}}(b_j + \sum_k w_{jk} h_k) \quad (5)$$

$$P(\mathbf{h} | \mathbf{v}) = \prod_j P(h_j | \mathbf{v}) \quad (6)$$

式中：激活函数  $f_{\text{sigmoid}}$  为 Sigmoid 型，表达式为  $y=(1+e^{-x})^{-1}$ 。当隐层状态确定时，同样可以计算出第  $i$  个可见单元的激活概率为

$$p(v_i = 1 | \mathbf{h}) = f_{\text{sigmoid}}(a_i + \sum_j w_{ij} h_j) \quad (7)$$

$$P(\mathbf{v} | \mathbf{h}) = \prod_i P(v_i | h_i) \quad (8)$$

训练样本集合为

$$S = \{\mathbf{v}^1, \mathbf{v}^2, \dots, \mathbf{v}^{n_s}\} \quad (9)$$

式中  $n_s$  为训练样本的数目，训练的目标是使如下似然函数最大化：

$$L(\boldsymbol{\theta}) = \prod_{i=1}^{n_s} P(\mathbf{v}^i) \quad (10)$$

对于连乘式  $\prod_{i=1}^{n_s} P(\mathbf{v}^i)$  处理较为麻烦，通过对该式取对数化简，由  $\log x$  的严格单调性可知， $\log(\theta)$  的最大化与  $L(\theta)$  的最大化等效，有：

$$\log L(\boldsymbol{\theta}) = \log \prod_{i=1}^{n_s} P(\mathbf{v}^i) = \sum_{i=1}^{n_s} \log P(\mathbf{v}^i) \quad (11)$$

为训练一个RBM，计算相对于RBM参数的对数似然负梯度。给定一个输入  $\mathbf{v}_0$ ，参数  $\boldsymbol{\theta}$  的负梯度为

$$\frac{\partial}{\partial \boldsymbol{\theta}} [-\log p(\mathbf{v}_0)] = E_{p(\mathbf{h}|\mathbf{v}_0)} \left[ \frac{\partial E(\mathbf{v}, \mathbf{h})}{\partial \boldsymbol{\theta}} \right] - E_{p(\mathbf{v}, \mathbf{h})} \left[ \frac{\partial E(\mathbf{v}, \mathbf{h})}{\partial \boldsymbol{\theta}} \right] \quad (12)$$

式中：等式右边第 1 项表示在概率分布  $p(h|v_0)$  下  $\frac{\partial E(v,h)}{\partial \theta}$  的期望；第 2 项表示在概率分布  $p(v,h)$  下  $\frac{\partial E(v,h)}{\partial \theta}$  的期望。对于给定的 RBM，第 1 个期望值可以直接计算出来，但是第 2 项其对应着  $v$  和  $h$  的所有可能性取值，其组合数目呈指数关系，很难直接计算得到。为解决这一问题，Hinton 发明了比散度(contrastive divergence, CD)算法<sup>[21]</sup>，可实现对第 2 个期望项的一种近似估计。

对比散度算法即对于一个给定的 RBM，根据条件概率分布进行吉布斯采样(Gibbs sampling)，首先使用  $v_0$  作为可见层初始的状态。采样过程可由下式表示：

$$v^0 \xrightarrow{p(h^0|v^0)} h^0 \xrightarrow{p(v^1|h^0)} v^1 \xrightarrow{p(h^1|v^1)} h^1$$

其中， $\xrightarrow{p(h^i|v^i)}$  和  $\xrightarrow{p(v^{i+1}|h^i)}$  分别表示从概率  $p(h^i|v^i)$  和  $p(v^{i+1}|h^i)$  上进行采样过程。大量实践经验表明，迭代一次的马尔科夫链在实际中表现就比较好了。上述对梯度进行估计的方法即所谓的 CD-1 方法，当迭代的次数变为  $k$  时即所谓 CD- $k$  方法。

对  $w_{jk}$  权值矩阵中梯度的估计通过计算化简有：

$$\frac{\partial E(v,h)}{\partial w_{jk}} = -h_j v_k \quad (13)$$

于是基于 CD-1 采样估计的梯度公式可以写成：

$$\frac{\partial}{\partial \theta} [-\log p(v^0)] = -p(h_j|v_0)v_k^0 + p(h_j|v^1)v_k^1 \quad (14)$$

本文采用 CD-1 方法实现对 RBM 参数的无监督训练。

## 2 深度置信网络

深度置信网络是由多层 RBM 叠加扩展而成的网络结构模型<sup>[22]</sup>，图 2 为一个具有 3 层隐藏层结构的 DBN 模型图， $W_1 \sim W_4$  为各层间连接参数。

DBN 将网络分为每一单层来处理，对每一层 RBM 进行无监督的训练使其达到能量平衡。由下至上，底层 RBM 训练完成后的隐藏层状态作为下一层 RBM 的输入，逐层传递生成更高级的特征<sup>[23-24]</sup>。整个网络无监督的预训练结束后，对可视单元状态以目标输出作为监督信号，构造损失函数，采用梯度下降法，用监督学习方式对网络参数进行调优。

DBN 利用 RBM 先进行无监督训练，使得模型能够学习到数据本身的结构信息。在监督地训练之前，DBN 的参数已经通过无监督训练靠近最优区域。相比传统神经网络的初始参数随机设置的方

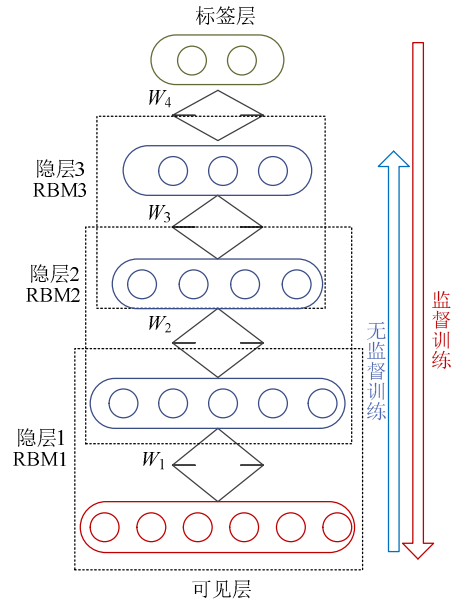


图 2 DBN 模型的结构

Fig. 2 Structure of DBN model

法，DBN 可避免陷入局部最优，而且减少了有监督训练的时间。

本文中，可视层单元的初始状态对应归一化处理后的 360 维的放电数据信息，首先无监督训练连接权重参数  $w_1$  和偏置参数  $a_1, b_1$ ，使得隐藏层 1 能最大概率重构可见层放电信息。使用同样的训练方法，使隐藏层 2 能最大概率重构隐藏层 1 的特征信息，逐层向上抽象出放电图谱的高阶特征，直至最高隐藏层形成最终的特征向量。

## 3 实验设计与数据采集

### 3.1 实验设计

本文设计了 4 种放电模型，对应 GIS 内 4 类常见的典型绝缘缺陷，即金属突出物放电模型(简称 N 类缺陷)、自由金属微粒放电模型(简称 P 类缺陷)、绝缘子表面金属污秽放电模型(简称 M 类缺陷)和绝缘子内气隙放电模型(简称 G 类缺陷)。缺陷模型如图 3 所示，图中长度单位均为 mm，铜屑尺寸为  $1 \times 2 \text{ mm}^2$  或  $2 \times 2 \text{ mm}^2$ ，数量 20~50 个。

分别将每一种缺陷模型置于研制的 GIS 模拟罐体中，并充以 0.1~0.4 MPa 的 SF<sub>6</sub> 气体进行 PD 实验，实验原理如图 4 所示。T1 为调压器操作平台，输入电压为 380 V；T2 为无局放工频试验变压器(YDTCW-1000/2×500)；C1/C2 为工频分压器(TAWF-1000/600)，R 为阻值 10 kΩ 的工频试验保护电阻(GR1000-1/6)，用来限制试品发生击穿时的短路电流；示波器型号为 TekDPO7104，其模拟带宽为 1 GHz，最大采样率为 20 GS/s，存储深度为 48 MB；特高频(ultra high frequency, UHF)传感器采






图3 GIS内部4种典型绝缘缺陷模型  
Fig. 3 Physical model of 4 typical defects in GIS

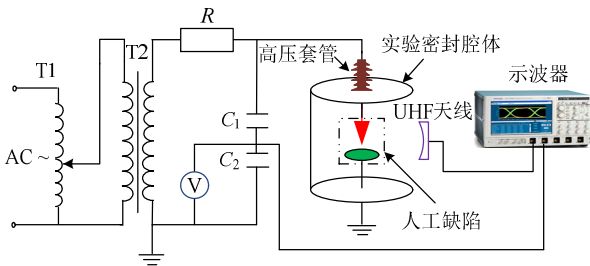


图4 实验接线示意图  
Fig. 4 Test wiring diagram

用自主研发的UHF微带天线,中心频率为390 MHz,带宽为340~440 MHz,通带增益实测达到了5.38 dB;实验室平均气温约为15℃。

### 3.2 实验数据

UHF PD信号经传感器接收后,再通过波阻抗50Ω的同轴电缆传导至示波器,并引入分压电容上的工频相位信息作为参考相位。连续采集1 s(50个工频周期)的PD信号,构建一个PRPD(phase resolved pulse sequence)三维谱图样本(放电相位 $\varphi$ ,放电信号测量幅值 $u$ ,放电次数 $n$ )。实测各类典型绝缘缺陷的PRPD图谱分别如图5所示。每类绝缘缺陷包含120个样本,其中训练样本40个,测试样本80个。

由图5的图谱可见,由于金属微粒在电场作用下发生随机性跳跃,P类放电模型下的PD脉冲相位分布比较分散;N类放电模型下PD脉冲多发生在工频负半周;G类放电模型下PD脉冲主要发生

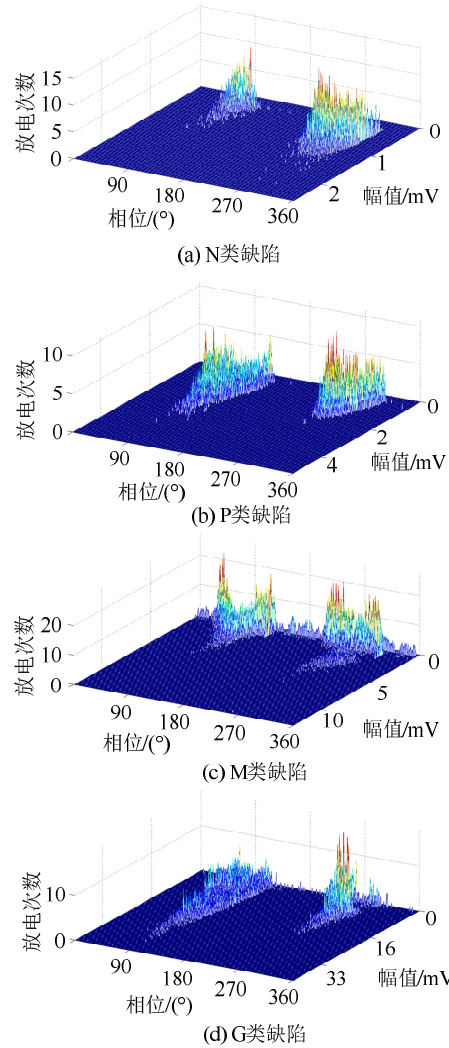


图5 4类典型缺陷UHF PD信号 $\varphi-u-n$ 谱图  
Fig. 5 PRPD spectrogram of the four typical insulation defects

在工频正负半周的上升沿处;M类放电模型下PD脉冲主要发生在正负半周峰值处。GIS设备内部绝缘缺陷类型多样,由于不同缺陷下诱发PD的机理不同,PD信号表现特征也有差异,同种缺陷下PD产生机理和PD信号特征具有相似性。

## 4 PD仿真识别实现

本文在Intel Core i7-4700HQ内存8 GB的CPU平台上,利用Matlab对N、P、G和M4类典型绝缘缺陷模型的PRPD图谱样本进行识别。

### 4.1 基于DBN法PD模式识别

构建5层DBN,可见层单元数量360个,3个隐藏层单元数量分别是100、50、36,逐层压缩,从每个样本中抽象出36个特征量。具体处理流程如下:

1) 对所有谱图样本数据进行归一化处理,每个谱图分辨率为360×50,360个相位区间的放电幅值对应360个可见层单元的初始输入状态。

2) 无监督训练过程, 首先训练第 1 个 RBM 网络, 即 360 个可见层单元和 100 个隐藏层单元构成的 RBM 网络结构, 采用 CD-1 算法, 计算 RBM 达到稳定的状态。

3) 将上一层得到的 RBM 的隐层单元状态作为下一层 RBM 的可见层的初始输入值, 用与 2) 同样的训练方法, 逐层向上计算出余下 2 个 RBM 的稳定状态。

4) 然后进行监督训练调优过程, 将上面 3 个 RBM 网络扩展连接成 DBN 网络, 对 4 类缺陷类型进行编码, 将类型编码作为目标输出值, 采用梯度下降法, 构建损失函数, 微调整个网络的参数。重复 2)、3)、4) 的步骤, 直至完成 40 个训练样本的训练。

5) 训练完成后, 导入 80 个测试样本对 DBN 进行测试, 统计各类缺陷识别准确率, 分析识别结果。

#### 4.2 基于统计特征的 PD 模式识别

另一方面提取 PRPD 图谱统计特征量, 用 SVM 分类器和 BP 神经网络对 PD 进行模式识别, 用作 DBN 网络识别效果的对比。本文参照文献[25]方法提取 PRPD 图谱整体及正负半周的偏斜度  $S_k$ 、突出度  $K_n$ 、图谱正负半周的不对称度  $Q$  和相关度  $c_c$  共 8 个特征量。

BP 神经网络是一种模仿人类神经网络行为特征的机器学习算法, 其主要思想是: 导入学习样本后, 用监督学习方式对网络的权值和偏差进行大量的训练, 当网络输出层误差平方和小于目标误差时完成训练, 使目标向量与输出向量间的差值尽可能小, 实现模式识别。

支持向量机(support vector machine, SVM), 通过非线性映射将输入数据转换到高维空间, 在高维空间上通过构造线性判别函数对数据进行二分, 对高维数问题具有较好的适应性。SVM 是建立在结构风险最小化基础上的机器学习理论, 能降低样本维数之间的关联性。

SVM 算法中的核函数常见有多项式核函数、Sigmoid 核函数和高斯径向基核函数 3 种, 后者只需要确定一个参数, 而前 2 种分别有 2 个参数需要确定, 参数的优化计算较为复杂。大量实践表明, SVM 分类器中采用高斯径向基核函数的训练结果通常较优<sup>[26]</sup>。因此, 本文 SVM 分类器选用高斯径向基核函数。

本文需要对 4 类绝缘缺陷进行识别, 而支持向量机是二分类器, 因此本文利用 3 个 SVM 分类器,

将 SVM 二分类器拓展成 SVM 四分类器。为提高计算效率, 先对识别难度较低的缺陷进行识别, 再余下的依次识别, 即先识别出 N 类缺陷和其余 3 种缺陷的基础上, 再识别 P 类缺陷和余下的 2 种绝缘缺陷, 最后识别余下的 2 种绝缘缺陷。

## 5 识别结果及分析

### 5.1 收敛性能比较

本文分别采取 2 种训练方法, 对深层神经网络进行训练, 训练步数为 100 步。第 1 种采用对比散度算法对网络参数进行无监督训练, 然后再进行监督训练微调; 第 2 种采用传统初始参数随机设置的方法直接训练。训练结果对比如图 6 所示。

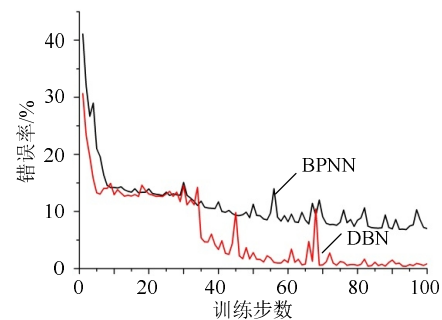


图 6 收敛性能比较

Fig. 6 Comparison of convergence performance

由图 6 可见, 第 1 种训练方法的初始识别错误率为 30%左右, 训练 70 步后网络参数趋近于收敛, 识别错误率逐渐趋近于 0。第 2 种训练方法初始识别错误率略高于 40%, 训练 50 步后, 识别错误率逐渐趋近于 10%, 但波动幅度依然较大。相比传统 BP 神经网络初始参数随机设置, DBN 通过无监督预训练得到合适的参数初值, 可以克服传统网络易陷入局部最优解且训练时间长等缺点。

### 5.2 DBN 识别混淆矩阵

混淆矩阵(confusion matrix)又称错误矩阵, 它的每一行是样本的真实分类, 每一列是样本的预测分类, 反映了分类结果的混淆程度。混淆矩阵  $i$  行  $j$  列表示类别  $i$  却被误分为类别  $j$  的概率, DBN 识别结果的混淆矩阵如表 1 所示。

由表 1 可知, P 类缺陷是误识别的主要来源, 自由金属微粒的随机性跳跃而造成局部放电的随机性, 是误识别的主要原因。该类缺陷最容易被误

表 1 DBN 识别混淆矩阵

Tab. 1 Confusion matrix of DBN %

混淆程度	目标 N	目标 P	目标 G	目标 M
输出 N	98.9	0.0	0.0	0.0
输出 P	1.1	94.7	1.3	6.4
输出 G	0.0	1.0	98.7	0.4
输出 M	0.0	4.3	0.0	93.2

识别为M类缺陷和G类缺陷,其中M类缺陷和P类缺陷相互间的误识别尤为严重。有4.3%的P类缺陷被识别为M类缺陷,6.4%的M类缺陷被识别为P类缺陷,很大程度上降低了M类缺陷的识别准确率。4类缺陷中,N类缺陷和其他3类缺陷表现形式差异最大,识别准确率达到了98.9%。

### 5.3 识别准确率与识别时间比较

本文还提取了8个统计特征量,利用SVM和BPNN 2种方法对GIS内的4种典型缺陷类型进行了识别,识别效果如表2所示。

放电模型	识别率/%		
	DBN	SVM	BPNN
N类缺陷	98.9	98.2	90.3
P类缺陷	94.7	88.2	84.1
G类缺陷	98.7	87.2	86.4
M类缺陷	93.2	90.0	87.3
总体	96.4	90.9	87.0
用时/s	55.7	89.2	109.3

3种方法中,DBN总体识别准确最高,达到了96.4%;SVM其次,总体识别准确率为90.9%;BPNN最差,总体识别准确率仅为87.0%。相对SVM和BPNN 2种方法,DBN方法总体识别准确率分别提高了5.5%和9.4%。DBN对N、P、G、M 4类典型缺陷的识别准确率分别是98.9%、94.7%、98.7%和93.2%,比较SVM和BPNN对各类缺陷识别准确率相对提高值,如图7所示。

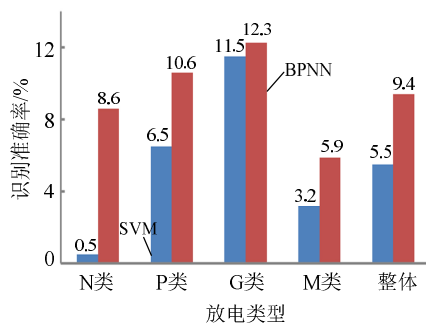


图7 识别准确率提高值

Fig. 7 Improvement of recognition accuracy value

由于N类缺陷PD信号正负半周相位分布差异明显,比较容易识别。而P类缺陷分散性大,识别难度相对较高。DBN能自动从数据中学习特征信息,避免了人为选择特征量的主观性,并能良好捕捉PRPD图谱中的细节信息,对P类缺陷的识别准确率达到了94.7%,相对SVM和BPNN识别方法,分别提高了6.5%和10.6%,对于传统的局部放电模式识别方法具有重要补充性。

整个识别过程,DBN方法用时最短,耗时55.7s;

SVM用时居中,耗时89.2s;BPNN用时最长,耗时109.3s。DBN网络无监督训练阶段采用的对比散度算法,对参数梯度进行良好的预估计,使其接近最优解,在监督学习阶段只需少量的迭代便能达到收敛,缩短了计算时间。

## 6 结论

针对传统的基于统计特征的PD模式识别方法在特征量选取上主观性较强、对自由金属微粒类型缺陷识别率偏低、识别效果欠佳的问题,本文构建了GIS设备内4类典型绝缘缺陷,将深度置信网络应用于绝缘缺陷产生的PD模式识别,并与传统方法的识别效果进行比较,得出以下结论:

1) DBN的隐藏层单元可以捕捉可视层数据表现的高阶相关性,在顶层形成更具有表征能力的特征向量,可从数据中客观学习出特征量。相比基于统计特征的SVM和BPNN算法,总体识别准确率分别提高了5.5%和9.4%。

2) DBN在无监督学习阶段,对比散度算法能对参数进行良好的预估计,解决了识别过程中过度拟合、易陷入局部最优解陷阱和收敛速度慢等问题,相比基于统计特征的SVM和BPNN算法,识别时间分别缩短了38%和49%。

3) DBN多隐层的神经网络具有优异的特征学习能力,可以捕捉图谱的细节特征,信息丢失较少,解决了特征量主观选取过程中特征信息遗漏的问题。同时,自由金属微粒类型缺陷的识别准确率提高到97.4%,相比基于统计特征的SVM和BPNN算法,对该类缺陷的识别准确率分别提高了6.5%和10.6%。

## 参考文献

- [1] Kopejtkova D, Molony T, Kobayashi S, et al. A twenty-five year review of experience with SF<sub>6</sub> gas insulated substations(GIS) [C]//CIGRE, Paris, France, 1992: 23-101.
- [2] 段韶峰,李志兵,詹花茂,等. 252 kV GIS中特快速瞬态过电压和特快速瞬态电流特性试验研究[J]. 电网技术, 2015, 39(7): 2046-2051.  
Duan Shaofeng, Li Zhibing, Zhan Huamao, et al. Experimental study on the characteristics of VFTO and VFTC in 252 kV GIS[J]. Power System Technology, 2015, 39(7): 2046-2051(in Chinese).
- [3] 詹花茂,姚林志,李志兵,等. 252 kV GIS隔离开关特快速暂态过电压试验中触头间隙重复击穿过程研究[J]. 电网技术, 2014, 38(9): 2570-2574.  
Zhan Huamao, Yao Linzhi, Li Zhibing, et al. Research on repeated breakdown process of disconnector contact gap during very fast transient overvoltage test of overall switching process of disconnector in 252kV GIS[J]. Power System Technology, 2014, 38(9): 2570-2574(in Chinese).
- [4] 王亮,郑书生,李成榕,等. GIS浇注孔传播内部局部放电 UHV



- 电磁波的特性[J]. 电网技术, 2014, 38(1): 241-247.
- Wang Liang, Zheng Shusheng, Li Chengrong, et al. Distribution of electric field strength and spectral characteristic of UHF signal of partial discharge inside GIS at resin sprue of metal ring[J]. Power System Technology, 2014, 38(1): 241-247(in Chinese).
- [5] 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): 1161-1166.
- 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): 1161-1166(in Chinese).
- [6] Xu C M, Zhang H, Peng D G, et al. Study of fault diagnosis of integrate of D-S evidence theory based on neural network for turbine [J]. Energy Proceed, 2012(16): 2027-2032.
- [7] 孙文星, 李朝晖, 程时杰, 等. 一种发电机故障放电信号特征实时在线自动识别方法及其应用[J]. 电网技术, 2015, 39(2): 543-549.
- Sun Wenxing, Li Zhaohui, Cheng Shijie, et al. A real time on-line method for automatic signal feature recognition of fault discharge in generator and its application[J]. Power System Technology, 2015, 39(2): 543-549(in Chinese).
- [8] 刘化龙, 胡钊. 序列二次规划-遗传算法及其在变压器局部放电超声定位中的应用[J]. 电网技术, 2015, 39(1): 130-135.
- Liu Hualong, Hu Po. Sequential quadratic programming-genetic algorithm and its application in ultrasonic localization of partial discharge in power transformers[J]. Power System Technology, 2015, 39(1): 130-135(in Chinese).
- [9] 王晓蓉, 杨敏中. 电力设备局部放电测量中抗干扰研究的现状和展望[J]. 电网技术, 2000, 24(6): 42-45.
- Wang Xiaorong, Yang Minzhong. Situation and outlook of anti-interference technology in partial discharge measurement in Electrical equipment[J]. Power System Technology, 2000, 24(6): 42-45(in Chinese).
- [10] 杨延西, 刘丁. 基于小波变换和最小二乘支持向量机的短期电力负荷预测[J]. 电网技术, 2005, 29(13): 61-64.
- Yang Yanxi, Liu Ding. Short-term load forecasting based on wavelet transform and least square support vector machines[J]. Power System Technology, 2005, 29(13): 61-64(in Chinese).
- [11] Schaik N V, Czaszejko T. Conditions of discharge-free operation of xlpe insulated power cable systems[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2008, 15(4): 1120-1130.
- [12] 唐炬, 陈长杰, 刘帆, 等. 局部放电下 SF<sub>6</sub> 分解组分检测与绝缘缺陷编码识别[J]. 电网技术, 2011, 35(1): 110-116.
- Tang Ju, Chen Changjie, Liu Fan, et al. Detection of constituents from SF<sub>6</sub> decomposition under partial discharge and recognition of insulation defect coding[J]. Power System Technology, 2011, 35(1): 110-116(in Chinese).
- [13] Satish L, Zaengl W S. Can fractal features be used for recognition 3-D partial discharge patterns[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 1995, 2(3): 352-359.
- [14] 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(in Chinese).
- [15] Baker J, Deng L, Glass J, et al. Developments and directions in speech recognition and understanding, Part1[J]. IEEE Signal Processing Magazine, 2009, 26(3): 75-80.
- [16] Zhang Lijing, Liang Yingli. A fast method of face detection in video images[C]//The 2 nd IEEE International Conference on Advanced Computer Control(ICACC2010). Shenyang, China, 2010: 490-494.
- [17] Collobert R, Weston J. A unified architecture for natural language processing: deep neural networks with multitask learning [C]//Proceedings of the 25 th International Conference on Machine Learning, New York, 2008: 160-167.
- [18] Smolensky P. Information processing in dynamical systems: foundations of harmony theory[M]. Parallel Distributed Processing, Foundations, Cambridge: MIT Press, 1986: 194-281.
- [19] Ackley D H, Hinton G E, Sejnowski T J. A learning algorithm for Boltzmann machines[J]. Cognitive Science, 1985, 9(1): 147-169.
- [20] 刘建伟, 刘媛. 玻尔兹曼机研究进展[J]. 计算机研究与发展, 2014, 51(1): 1-16.
- Liu Jianwei, Liu Yuan. Research and development on Boltzmann machine[J]. Journal of Computer Research and Development, 2014, 51(1): 1-16(in Chinese).
- [21] Hinton G E. Training products of experts by minimizing contrastive divergence[J]. Neural Computation, 2002, 14(8): 1771-1800.
- [22] 胡洋. 基于马尔可夫链蒙特卡罗方法的 RBM 学习算法改进[D]. 上海: 上海交通大学, 2012.
- [23] 姚明海, 李洁, 王宪保. 基于 RPCA 的太阳能电池片表面缺陷检测[J]. 计算机学报, 2013, 36(9): 1943-1952.
- Yao Minghai, Li Jie, Wang Xianbao. Solar cells surface defects detection using RPCA method[J]. Chinese Journal of Computers, 2013, 36(9): 1943-1952(in Chinese).
- [24] Hinton G E, Dayan P, Frey B J, et al. The "wake-sleep" algorithm for unsupervised neural networks[J]. Science, 1995(268): 1158-1161.
- [25] 杨钟瑾. 核函数支持向量机[J]. 计算机工程与应用, 2008, 44(33): 1-6, 24.
- Yang Zhongjin. Support vector machine of kernel function[J]. Computer Engineering and Applications, 2008, 44(33): 1-6, 24(in Chinese).
- [26] Wolf A, Swift J B, Swinney H L, et al. Determining lyapunov exponents from time series[J]. Physical, 1985, 16(3): 285-317.



张新伯

收稿日期: 2016-04-18。

作者简介:

张新伯(1990), 男, 硕士研究生, 从事 GIS 绝缘故障诊断研究, E-mail: 2010301580317@whu.edu.cn;

唐炬(1960), 男, 博士, 教授, 博士生导师, 973 计划首席科学家, 主要从事高压电气设备绝缘在线监测及故障诊断研究, E-mail: cqtangju@sina.com.

(责任编辑 马晓华)