

DOI: 10.7667/PSPC180598

## 基于 DTCWT-DBN 的配电网内部过电压类型识别

高伟<sup>1</sup>, 杨耿杰<sup>1</sup>, 郭谋发<sup>1</sup>, 杨川<sup>2</sup>

(1. 福州大学电气工程与自动化学院, 福建 福州 350108;

2. 中国能源建设集团云南省电力设计院有限公司, 云南 昆明 350002)

**摘要:** 提出一种基于双树复小波变换(DTCWT)-深度信念网络(DBN)的配电网内部过电压识别方法。将 10 kV 母线三相过电压信号进行双树复小波变换, 再通过奇异值分解降维, 将所得奇异值作为特征值输入训练好的深度信念网络分类器, 实现对 7 种典型的内部过电压的类型识别。利用 ATP/EMTP 仿真数据和物理实验平台上的故障波形对所提算法进行训练和测试, 并将之与其他分类算法进行对比。结果表明, 相较于所列举的其他方法, 所提算法具有更强的特征提取能力和更高的识别准确率。

**关键词:** 配电网; 内部过电压; 类型识别; 双树复小波; 深度信念网络

### Internal overvoltage type identification for distribution network based on DTCWT-DBN algorithm

GAO Wei<sup>1</sup>, YANG Gengjie<sup>1</sup>, GUO Moufa<sup>1</sup>, YANG Chuan<sup>2</sup>

(1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China;

2. China Energy Construction Group Yunnan Electric Power Design Institute Co., Ltd., Kunming 350002, China)

**Abstract:** A method based on Double Tree Complex Wavelet Transform (DTCWT)-Deep Belief Network (DBN) for overvoltage identification in distribution network is proposed. The three-phase overvoltage signal of the 10 kV bus is subjected to the dual-tree complex wavelet transform, and then the singular value is reduced by the singular value decomposition. The resulting singular value is input into the trained deep belief network classifier as the eigenvalue, and the seven typical internal overvoltage type identification types are realized. The proposed algorithm is trained and tested using ATP/EMTP simulation data and fault waveforms on the physics experiment platform, and compared with other classification algorithms. The results show that compared with other methods listed in this paper, the proposed algorithm has stronger feature extraction capability and higher recognition accuracy.

This work is supported by National Natural Science Foundation of China (No. 51677030) and Natural Science Foundation of Fujian Province (No. 2016J01218).

**Key words:** distribution network; internal overvoltage; type identification; double tree complex wavelet; deep belief network

## 0 引言

据统计, 电力系统中大约 70% 的过电压发生于配电网, 因过电压导致的绝缘损坏可进一步引发各类短路故障, 对系统的正常运行造成严重影响<sup>[1]</sup>。因此, 对危害配电网系统的内部过电压进行检测和分类, 是抑制和消除过电压, 保障电力系统安全稳定运行的先决条件。

过电压类型识别大致分为两阶段: 特征值提取和模式识别。故障信号特征值提取方法有很多, 如小波变换、S 变换、希尔伯特-黄变换等, 主要是对三相电压或零序电压信号提取电压波形的暂态故障特征。小波变换继承和发展了短时傅立叶变换局部化的思想, 同时又克服了窗口大小不随频率变化等缺点, 提供一个随频率改变的“时间-频率”窗口, 是一种多尺度的信号分析方法, 在信号处理、去噪等方面表现出强大的优越性<sup>[2]</sup>。文献[3]利用小波变换对零序电压进行分解, 以能量最大原则确定特征频段, 并根据特征频段的差异识别过电压。但小波

**基金项目:** 国家自然科学基金项目资助 (51677030); 福建省自然科学基金项目资助 (2016J01218)

变换的二抽取过程会引发较大的混叠, 影响小波的表征能力。S 变换结合了小波变换和短时傅里叶变换的特点, 时频窗可根据信号自身特点调节大小, 且能同时分辨信号中的高低频成分<sup>[4]</sup>。文献[5]对零序电压进行 S 变换, 在频率和时间上平均划分变换后的模值矩阵, 得到 9 个子矩阵, 分别计算 9 个子矩阵, 将每个子矩阵的最大奇异值作为构造特征值的基础, 但在较高频带部分存在分辨率不够精确的缺点。希尔伯特黄变换(HHT)由经验模式分解和希尔伯特谱分解两部分组成, 其目的是获得信号中具有实际物理意义的瞬时频率分量, 实现高分辨率的时频分析<sup>[6-8]</sup>。文献[9]利用雷击过电压暂态信号和 HHT 时频谱提取特征量, 实现 4 种雷电过电压和普通短路过电压的分类。但所分解的 IMF 分量之间的正交性是通过筛分迭代算法近似实现的, 并没有完整的理论解释与较好的解决方案。

目前应用于各个领域的分类工具极多, 如神经网络、支持向量机、模糊聚类分析、极限学习机等。神经网络<sup>[10]</sup>最突出的特点是大规模并行分布式处理能力、非线性映射能力以及自学习、自训练能力, 但存在收敛速度慢甚至无法收敛、易收敛到局部极小值和过拟合等缺陷; 支持向量机对线性分类问题具有优异的区分能力, 对于非线性分类问题则通过非线性变换将向量映射到高维特征空间中进行分类<sup>[11-13]</sup>, 从整体上看具有鲁棒性、有效性和计算简单等优点, 但当处理多类问题时需要经过复杂的计算过程或设置多个分类器; 聚类分析根据样本隶属度将每个聚类对象划分归类<sup>[14]</sup>, 但在样本量较大时, 要获得准确的结论有一定困难; 极限学习机<sup>[15-16]</sup>是一种新的单隐含层前馈神经网络, 算法随机产生并固定网络参数, 只需设置隐含层神经元个数即可获得唯一最优解, 与传统神经网络相比, 极限学习机具有学习速度快、泛化性能好等优点, 但在样本较复杂或噪声干扰较大时, 学习能力不足。

针对前述算法的特点和缺点, 提出一种基于双树复小波变换-深度信念网络的配电网内部过电压的识别算法。双数复小波变换(Dual-tree Complex Wavelet Transform, DTCWT)<sup>[17]</sup>具有优良的抗频率混叠性和平移不变性等优点。深度信念网络(Deep Belief Network, DBN)是一种深度学习算法, 它克服了 BP 神经网络因随机初始化的权值参数而易陷入局部最优和训练时间长的局限性。经实验验证, 所提特征值提取方法能充分表征过电压特性, 所提识别算法抗干扰能力强、准确性高。文章的结构包括: 第一部分前言, 第二部分介绍过电压特征值的提取方法, 第三部分介绍 DBN 分类器的构建方法, 第

四部分介绍配电网内部过电压的分类过程, 第五部分通过仿真软件生成过电压故障数据进行验证, 第六部分通过配电网物理仿真平台获得物理数据进行验证, 第七部分结论。

## 1 过电压特征值的提取方法

### 1.1 双树复小波变换

DTCWT 是一种具有完全重构性、近似平移不变性、抗混叠等特性的小波变换。结构上分成两路采用二叉树结构的离散小波变换, 树 a 和树 b 分别生成实部和虚部, 并行实现实部和虚部的运算。图 1 是 DTCWT 二层分解与重构的过程, 其中“ $\downarrow 2$ ”表示隔点下采样;  $g_0(n)$ 、 $g_1(n)$  以及  $g'_0(n)$ 、 $g'_1(n)$  表示共轭积分滤波器对;  $h_0(n)$ 、 $h_1(n)$  以及  $h'_0(n)$ 、 $h'_1(n)$  表示共轭正交滤波器对。第一层分解中, 为了保证树 a 第一层中因隔点采样所丢掉的数据在树 b 第一层的隔点采样中取得, 将两树的滤波器之间的延迟设置为一个采样间隔。该行为相当于没有进行二抽取, 使数据的丢失减少, 消除了平移敏感性。而之后各层分解中, a 树和 b 树所对应的滤波器相频响应之间的群延迟设定为半个采样周期, 确保两树在本层和之前各层上的延迟差总和相对输入刚好一个采样周期, 两组滤波器的幅频相同。

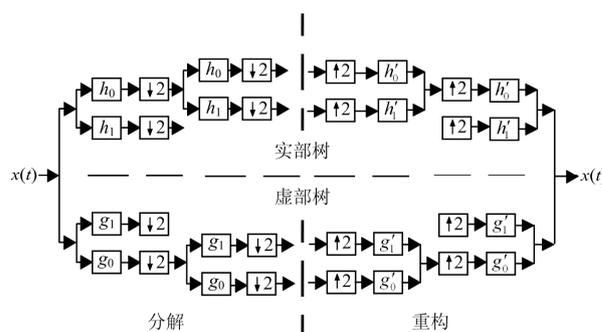


图 1 双树复小波变换的分解与重构过程

Fig. 1 Decomposition and reconstruction of double tree complex wavelet transform

复小波表示为

$$\psi(t) = \psi_h(t) + j\psi_g(t) \quad (1)$$

式中,  $\psi_h(t)$ 、 $\psi_g(t)$  分别为复小波的实数部分和虚数部分。根据小波分析的理论, 实数部的小波系数和尺度系数可表示为

$$d_j^{\text{Re}}(n) = 2^{\frac{j}{2}} \int_{-\infty}^{+\infty} x(t)\psi_h(2^j t - n)dt, \quad j = 1, 2, \dots, J \quad (2)$$

$$c_j^{\text{Re}}(n) = 2^{\frac{j}{2}} \int_{-\infty}^{+\infty} x(t)\psi_g(2^j t - n)dt$$

虚数部小波系数与尺度系数为

$$d_j^{lm}(n) = 2^{\frac{j}{2}} \int_{-\infty}^{+\infty} x(t) \psi_g(2^j t - n) dt, \quad j = 1, 2, \dots, J \quad (3)$$

$$c_j^{lm}(n) = 2^{\frac{j}{2}} \int_{-\infty}^{+\infty} x(t) \psi_g(2^j t - n) dt$$

则小波系数与尺度系数为

$$\begin{cases} d_j^o(n) = d_j^{Re}(n) + id_j^{lm}(n), j = 1, 2, \dots, J \\ c_j^o(n) = c_j^{Re}(n) + ic_j^{lm}(n) \end{cases} \quad (4)$$

分别对小波系数与尺度系数进行重构:

$$d_j(t) = 2^{(j-1)/2} \left[ \sum_{n=-\infty}^{+\infty} d_j^{Re}(n) \psi_h(2^j t - n) + \sum_{n=-\infty}^{+\infty} d_j^{lm}(n) \psi_g(2^j t - n) \right] \quad (5)$$

$$c_j(t) = 2^{(j-1)/2} \left[ \sum_{n=-\infty}^{+\infty} c_j^{Re}(n) \psi_h(2^j t - n) + \sum_{n=-\infty}^{+\infty} c_j^{lm}(n) \psi_g(2^j t - n) \right]$$

重构后的信号为

$$\hat{x}(t) = \sum_{j=1}^J d_j(t) + c_j(t) \quad (6)$$

上述过程减少了采样过程中数据的丢失, 降低了伪频率成分, 具有突出的抗混叠特性<sup>[17]</sup>。设计一个含多频率成分的仿真信号  $x(t)$  (如式(7)), 采样率为 2 kHz, 采样点数 512。信号波形图及 FFT 频谱图如图 2 所示。

$$x(t) = 1.5 \cos 100\pi t + 1.1 \cos 200\pi t + 0.6 \cos 400\pi t + \cos 800\pi t + \cos 1600\pi t \quad (7)$$

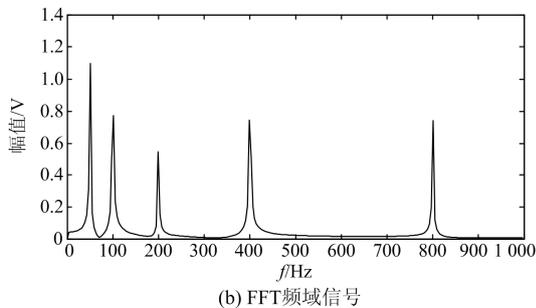
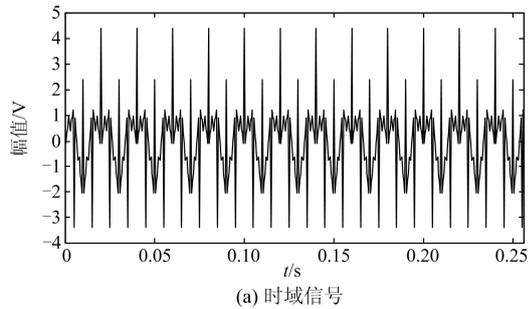


图 2 验证信号波形和频谱图

Fig. 2 Verification signal waveforms and spectrograms

分别对前述信号进行离散小波变换(Discrete Wavelet Transform, DWT)及双树复小波变换。由结果(图 3、图 4)可知: DWT 重构后的频带信号 d3、d4、a4 中除了应有的频率成分外, 都存在较严重的频率混叠现象; DTCWT 尽管在个别频带仍存在混叠现象, 但频率分量的泄漏现象已得到了极大的改善, 处理效果优于传统小波变换。

DTCWT 所得到的细节分量和近似分量含有丰富的信息, 可作为故障判别的特征值。但由于该特征值数据量较大, 不宜直接放入分类器辨识, 需要进一步降维处理。

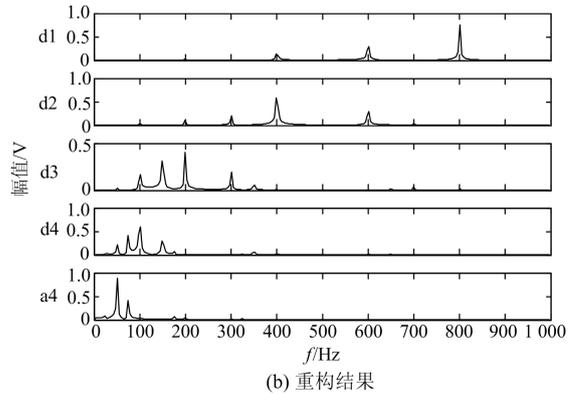
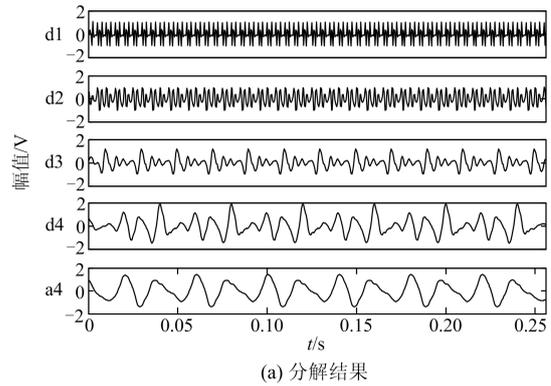
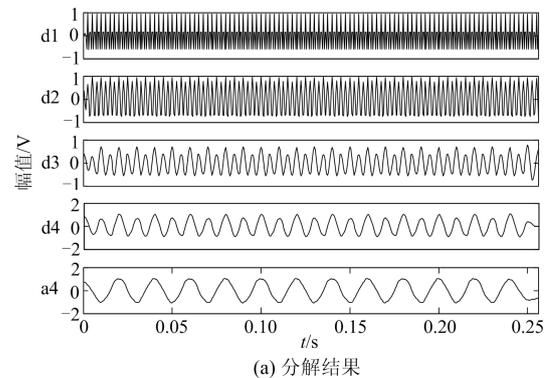
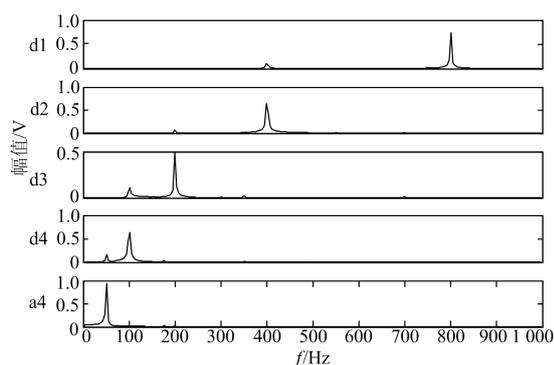


图 3 DB4 小波变换结果

Fig. 3 Result of DB4 wavelet transform





(b) 重构结果

图 4 双树复小波变换结果

Fig. 4 Result of double tree complex wavelet transform

## 1.2 奇异值分解基本原理

奇异值分解(Singular Value Decomposition, SVD)<sup>[18]</sup>是一种提取矩阵重要特征的有效方法, 对应着矩阵中隐含的重要信息, 且重要性和奇异值大小正相关。根据奇异值理论, 对于任何一个实矩阵  $A_{m \times n}$  (假设  $m < n$ ), 必定存在两个正交矩阵  $U_{m \times m}$ 、 $V_{n \times n}$  与一个对角阵  $A_{m \times n}$ , 使得

$$\begin{cases} A=UAV^T \\ A=\text{diag}\{\lambda_1, \dots, \lambda_i, \dots, \lambda_k, 0, \dots\} \\ k = \text{rank}(A) = \min(m, n) \end{cases} \quad (8)$$

其中,  $\lambda_i$  为矩阵  $AA^T$  的特征值,  $i=1, 2, \dots, k, \lambda_1 > \lambda_2 > \lambda_{k-1} > \lambda_k > 0, k$  为奇异值阶数,  $\text{rank}$  为求秩公式。

奇异值分解等同于将秩为  $k$  的  $m \times n$  矩阵分解为  $k$  个秩为 1 的  $m \times n$  矩阵的加权和, 而奇异值则衡量了这些秩为 1 的矩阵  $A_i$  对于原矩阵  $A$  的权重。设  $u_i$  和  $v_i$  分别为矩阵  $U$  和矩阵  $V$  第  $i$  列向量, 则每个矩阵由  $u_i$  和  $v_i$  相乘得到, 即

$$A=UAV^T = \sum_{i=1}^k \lambda_i u_i v_i^T = \sum_{i=1}^k \lambda_i A_i \quad (9)$$

这样, 通过奇异值分解, 可以将  $m \times n$  矩阵分解成  $k$  个特征向量, 使得经双树复小波变换后的特征信息数据大为减少。

## 2 基于深度信念网络的分类器构建

DBN 由 Geoffrey Hinton 在 2006 年提出, 是首个被提出的深度学习算法, 也是目前应用较为广泛的模型。如图 5 所示, 由一系列无监督的受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)堆叠而成, 且含有一层有监督的 BP 网络<sup>[19-20]</sup>。结构与神经网络相似, 是一个包含输入层、隐含层、输出层的多层网络, 且相邻层单元之间有连接, 同一层或

跨层的单元之间无连接。RBM 是基于能量生成模型的一个特例<sup>[21-22]</sup>, 是构成 DBN 的基本单位。每个 RBM 网络包含一个可见层和一个隐含层, 下层网络的隐含层同时也是上层网络的可见层, 结构如图 6 所示。 $w_{ij}$  为可见层节点  $i$  与隐含层节点  $j$  间的权值矩阵元素,  $a_i$  为可见层节点的偏置,  $b_j$  为隐含层节点的偏置。深度信念网络的训练过程包括预训练和微调两阶段。

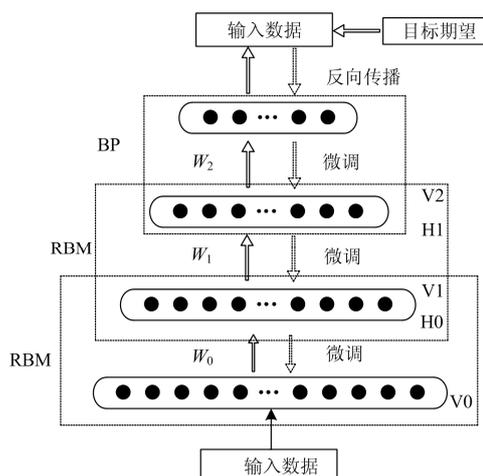


图 5 深度信念网络结构

Fig. 5 Deep belief network structure

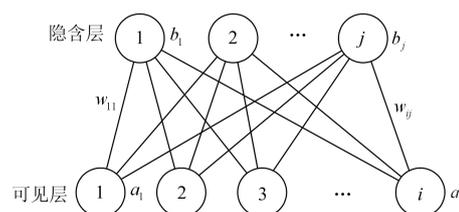


图 6 RBM 网络结构

Fig. 6 RBM network structure

### 2.1 预训练过程

预训练实质上是通过自下而上训练每层 RBM 网络获得网络参数初始值, 确保特征向量映射到不同特征空间时, 尽可能多地保留特征信息。过程如下。

Step 1: 用无标签数据训练第  $i(i=1)$  层 RBM 网络(称为无监督训练), 得到第  $i$  层网络的权值和偏置;

Step 2: 固定第  $i$  个 RBM 的权值和偏置, 然后将训练完的第  $i$  层 RBM 网络的隐含层  $H_{i-1}$  作为可见层  $V_i$ , 与第  $i+1$  层隐含层  $H_i$  一起组成第  $i+1$  层 RBM 网络, 训练得到第  $i+1$  层网络的权值和偏置;

Step 3:  $i=i+1$ ; 反复执行 Step2—Step3 直到所有 RBM 网络都训练完毕。

每一层 RBM 网络的训练结果只能保证本层网络的权值和偏置达到最优,并非使整个 DBN 特征向量的映射达到最优。此过程可看成是对 BP 网络参数的非随机初始化,使 DBN 克服了 BP 神经网络因随机初始化的权值参数而易陷入局部最优和训练时间长的局限性。

$w_{ij}$  为可见层节点  $i$  与隐含层节点  $j$  间的权值矩阵元素,可视层节点的偏置  $a_i$ , 隐含层节点的偏置  $b_j$ , 假设可视层单元  $v_i$  与隐含层单元  $h_j$  都为二值化信号  $\{0,1\}$ ,  $0 \leq i \leq m, 0 \leq j \leq n$ , 则可求得给定的 RBM 的能量函数:

$$E(v, h) = -\sum_{i=1}^m a_i v_i - \sum_{j=1}^n b_j v_j - \sum_{j=1}^n \sum_{i=1}^m w_{ij} v_i h_j \quad (10)$$

可视层和隐含层之间的联合概率分布为

$$p(v, h) = \frac{e^{-E(v, h)}}{Z} = \frac{e^{-E(v, h)}}{\sum_v \sum_h e^{-E(v, h)}} \quad (11)$$

通过式(11)可得输入向量  $v$  的独立分布为

$$p(v) = \frac{\sum_h e^{-E(v, h)}}{\sum_v \sum_h e^{-E(v, h)}} \quad (12)$$

其中,  $Z$  是归一化因子。无论是隐含层还是可见层,在同层之间的单元都是没有连线的,它们在概率上都保持独立性,因此根据式(11)可得出在给定可视层  $v$  的条件下隐含层  $h$  的概率,以及给定隐含层  $h$  的条件下可视层  $v$  的概率,公式如式(13)所示。

$$\begin{cases} p(h|v) = \prod_j p(h_j|v) \\ p(v|h) = \prod_i p(v_i|h) \end{cases} \quad (13)$$

当激活函数定义为 sigmoid 函数  $\text{sig}(x) = 1/(1+e^{-x})$  时,激活概率为

$$\begin{cases} p(h_j = 1|v) = \text{sig}(a_j + \sum_{i=1}^m v_i w_{ij}) \\ p(v_i = 1|h) = \text{sig}(b_i + \sum_{j=1}^n h_j w_{ij}) \end{cases} \quad (14)$$

RBM 网络训练的本质就是使 RBM 模型满足输入样本分布概率最大。由式(10)可知,通过调节权重矩阵  $w$ 、可视层单元阈值  $a$ 、隐含层单元阈值  $b$  可减小能量函数  $E$ , 从而使  $p(v)$  的值最大。

## 2.2 微调过程

预训练完成后,为了使模型具有更好的表现能力,利用 BP 网络有监督地训练最顶层的分类器:BP 网络接收最上层 RBM 网络的输出信号,有监督地将 RBM 学习到特征进行分类;同时自顶而下反

向传播网络的误差信息至每一层 RBM 网络,利用梯度下降法微调所有 RBM 网络层间的相关参数,当最大迭代次数或下降梯度小于设定值,则结束微调过程,认为 DBN 的参数达到最优。通过对 DBN 进行有监督的训练进一步减少训练误差,提高 DBN 模型的分类准确率。

## 3 配电网内部过电压分类过程

选取过电压发生前后 6 个工频周期(前 1 后 5)的三相电压信号作为研究对象,采样频率为 20 kHz。为了得到频率范围为 23~24 Hz 的分频谐振的电压信号,需要进行 8 层的双树复小波变换。以 A 相电压为例,假设 A 相信号为  $A_{1 \times n}$ , 对  $A_{1 \times n}$  进行 8 层双树复小波变换,并将分解得到的 9 个单支重构频带信号(8 个细节分量和 1 个近似分量)组成 1 个特征矩阵  $B_{9 \times n}$ ; 再对特征矩阵进行奇异值分解,得到对角阵  $A_{9 \times n}$ , 将对角阵上的元素依序排列成行,构成奇异值特征值  $C_{1 \times 9}$ 。B、C 两相的处理方式与 A 相一致,最后再将 A、B、C 三相电压信号分解后的奇异值特征值首尾相接,得到分类器的输入向量  $x_{1 \times 27}$ 。

当神经网络的输入数据中存在量级差别较大的样本时,可能导致网络无法收敛,识别精度下降。对输入数据进行归一化,可取消数据间数量级差别,归一化方法如式(15)所示,其中  $x_{\min}$ 、 $x_{\max}$  分别代表待归一化数据中的最大值和最小值。

$$\bar{x} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (15)$$

将处理完的数据分成两组,一组用于训练分类器,另一组用于测试分类器的识别效果。当测试结果与预先设置的输出期望一致时,认为识别正确,反之则错误。输出期望用二进制序列表示(见表 1)。

表 1 内部过电压对应的输出期望

Table 1 Output expectations corresponding to internal overvoltages

类型	分频谐振	单相接地	基频谐振	切电容器组
期望	0000001	0000010	0000100	0001000
类型	切空线	间歇弧光接地	高频谐振	
期望	0010000	0100000	1000000	

## 4 仿真数据验证

### 4.1 仿真模型

利用 ATP/EMTP 软件搭建了一个中性点不接地的 10 kV 配电网仿真系统,如图 7 所示,系统参数同文献[23]。过电压样本选取条件如表 2 所示。每种过电压样本数都为 300 个,各包含过电压发生前后的 A、B、C 三相电压,总样本数 2 100 个。

表 2 内部过电压样本选取条件

Table 2 Selection conditions for internal overvoltage samples

过电压类型	过电压相别	过电压位置或线路长度	初相角	故障电阻/ $\Omega$	样本数
弧光接地	A、B、C	F1、F4、F5	$30^\circ$ 、 $90^\circ$ 、 $150^\circ$ 、 $270^\circ$ 、 $330^\circ$	1~100	300
切空线	A、B、C	F1~F5	$30^\circ$ 、 $60^\circ$ 、 $90^\circ$ 、 $120^\circ$ 、 $150^\circ$	—	300
切电容器组	A、B、C	F1~F5	$90^\circ$ 、 $270^\circ$	—	300
高频铁磁谐振	A、B、C	1.3~20	$30^\circ$ 、 $90^\circ$ 、 $150^\circ$ 、 $210^\circ$	5~100	300
基频铁磁谐振	A、B、C	0.25~1.3	$30^\circ$ 、 $90^\circ$ 、 $150^\circ$ 、 $210^\circ$	5~100	300
分频铁磁谐振	A、B、C	0.01~0.12	$30^\circ$ 、 $90^\circ$ 、 $150^\circ$ 、 $210^\circ$	5~100	300
单相接地故障	A、B、C	F1~F5	$30^\circ$ 、 $90^\circ$ 、 $150^\circ$ 、 $210^\circ$ 、 $330^\circ$	1~20	300

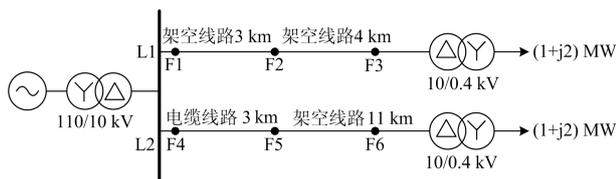


图 7 10 kV 配电网仿真系统网络结构

Fig. 7 Network structure of 10 kV distribution network simulation system

#### 4.2 网络训练参数设置

随机选取训练集 1 800 个, 测试集 300 个, 通过单变量寻优方法, 选定 DBN 的参数: (1) 保持学习率为 0.04、神经元个数为 60, 分别设置网络隐含层数为 2、3、4, 对应的识别效果如表 3 所示。可以看出当隐含层个数为 3 时识别准确率最高, 故设置网络隐含层数为 3。(2) 保持学习率为 0.04, 隐含层数为 3, 设置不同的网络神经元个数, 比较识别效果(如图 8)。可以发现当神经元为 60 个时, 识别错误率最低, 故选择神经元个数为 60。(3) 保持隐含层数为 3, 神经元个数为 60, 改变网络学习率, 对比识别效果(如图 9)。当学习率为 0.02、0.04、0.07 时识别错误率为 0, 由于学习率选择不宜过大或过小, 因此折中选择 0.04 作为学习率。(4) 权重初始值一般随机选取一个较小的值, 通常是从方差为 0.1、均值为 0 的高斯分布中选取。(5) 隐含层和输出层偏置初始化为 0, 可视单元的偏置用  $\log(p_i/(1-p_i))$  表示。

#### 4.3 实验结果

##### 4.3.1 抗混叠效果分析

随机选取 7 个内部过电压样本(每类一个), 求取故障特征值。图 10 中 7 种颜色数据点分别代表 7 种类型过电压的特征值: 蓝色为单相接地, 黄色为基频谐振, 红色为分频谐振, 青色为切空载线路,

表 3 不同隐含层数的识别准确率

Table 3 Recognition accuracy rate of different hidden layers

隐含层个数	2	3	4
识别成功率/%	98.6	100	99
耗时/s	44.63	82.23	147.73

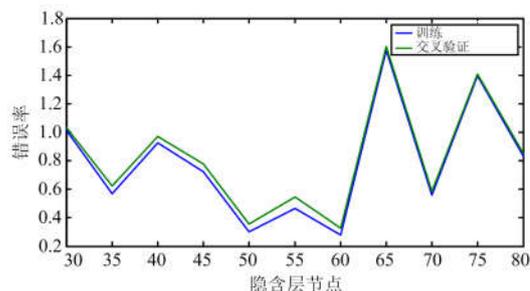


图 8 DBN 隐含层选用不同神经元的错误率

Fig. 8 Failure rate for the selection of different neurons in the hidden layer of DBN

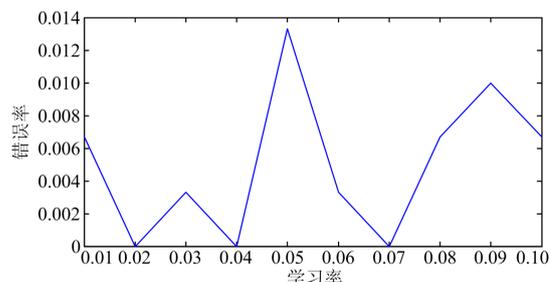


图 9 DBN 隐含层选用不同学习率时的错误率

Fig. 9 Failure rate of different learning rates in the hidden layer of DBN

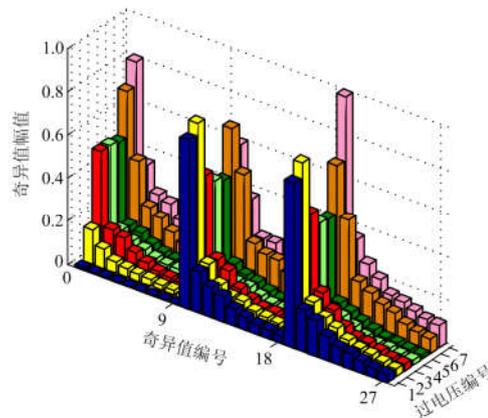


图 10 不同过电压的奇异值分布

Fig. 10 Singular value distribution of different overvoltages

绿色为切电容器组，土黄色为高频谐振，粉色为弧光接地。不同类型的内部过电压的特征差异性较为明显。

为了验证算法的抗混叠效果，以间歇性弧光接地为例，随机选取5个样本，分别用DWT和DTCWT提取特征信息，再进行奇异值降维。图11是特征值分布的箱形图，可以看出，DWT获得的特征值的分布相对分散，而DTCWT获得的各阶奇异值排列更为密集、集中，说明DTCWT所提取的过电压特征受频率混叠的影响较小，特征表示具有普遍性。

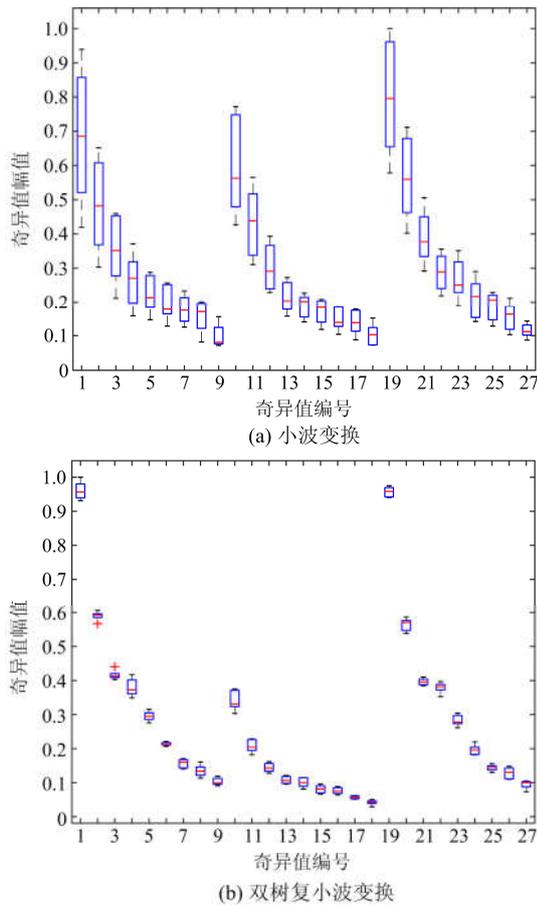


图 11 间歇性弧光接地的奇异值箱形图分布  
Fig. 11 Box plot distribution of intermittent arc grounding singular value

在识别成功率方面，方法1为双树复小波变换后进行奇异值降维，方法2是小波变换后进行奇异值降维，分类器均采用DBN网络。在无噪声的情况下，方法1和方法2的识别准确率都为100%。但在-10 dB的白噪声下，DTCWT的识别准确度明显优于DWT(识别结果见表4)，这是因为DTCWT抗干扰能力强，既保留了信号的主要频率特征，又减少了伪频率的影响。

表 4 DBN 算法的识别准确率

特征提取方法	过电压类型	识别准确率/%	
DTCWT	分频谐振	100	97.33
	单相接地	100	
	基频谐振	100	
	切电容器组	86	
	切空线	100	
	间歇弧光接地	95	
	高频谐振	100	
DWT	分频谐振	100	93.33
	单相接地	100	
	基频谐振	100	
	切电容器组	92	
	切空线	87.8	
	间歇弧光接地	69.4	
	高频谐振	100	

#### 4.3.2 算法对比

为了对所提方法的性能进行评估，深度信念网络的样本划分为训练集和测试集，比例为1800:300，分类器的最大训练次数为2000次，最小梯度设为 $10^{-7}$ 。算法运行环境：CPU为Intel(R) Core(TM) i5-3210 M, 2.50 GHz；内存为8 GB；操作系统为Windows10, 64位；软件为Matlab2014a。特征值提取方法分别是：DTCWT+SVD(简称DTCWT)、DWT+SVD(简称DWT)和EMD+SVD(简称EMD)，分类器分别是：BP神经网络、DBN、极限学习机(Extreme Learning Machine, ELM)。样本数据加入-10 dB白噪声，测试结果见表5。

从识别准确率上看，同一分类器下DTCWT提取的特征值都优于其他两种方法；三种分类器的分类准确率优劣明显，DBN优于BP神经网络和ELM。BP神经网络因训练时网络误差不再连续减少次数超过限值，过早退出了网络训练，因此训练所得的分类器极不稳定；且数据所加噪声较大，导致BP神经网络无法学习到较为深层的特征差异而陷入局部最优解，因此识别准确率较低。ELM由于随机产生层间阈值和隐含层神经元权值，且训练中无需调整，因此学习速度快，但在强噪声干扰环境下学习效果也不理想。DBN学习能力较强，在梯度下降小于 $10^{-7}$ 时结束训练，所得分类器的识别效果远高于BP神经网络。综上所述，DBN拥有较稳定的结构，克服了传统神经网络的缺陷，具有较强的学习能力和抗干扰能力，训练完成的分类器具有较高的识别效果。

表 5 算法的识别效果对比

Table 5 Comparison of recognition effect of algorithm

特征值提取算法	训练耗时/s			测试耗时/(s/sample)			识别准确率/%			模型复杂度		
	BP	DBN	ELM	BP	DBN	ELM	BP	DBN	ELM	BP	DBN	ELM
DTCWT+SVD	1 127.06	1 188.91	1 103.2	0.612 6	0.612 9	0.612 7	86.7	97.33	74.67			
DWT+SVD	911.74	976.46	888.72	0.493 6	0.493 8	0.493 6	81.3	93.33	73.67	复杂	较复杂	简单
EMD+SVD	3 306.69	3 377.07	3 283.76	1.824 1	1.824 3	1.824 2	80	94.67	72.33			

在特征值提取的时间上, 由于 DTCWT 需执行两路的离散小波变换, 所以时间较 DWT 长, EMD 因需不停地迭代筛分具有正交性的 IMF 分量, 故执行的时间最长; 在模型分类训练的时间上, DBN 较 BP 和 ELM 稍长一点, 这是因为它的模型比后两者复杂, 通过深度学习提高模型的精度; 然而从单个样本的测试时间上看, 所提的方法在保证准确率的同时, 也有较快的执行速度。

## 5 在配电网物理仿真平台的验证

从 10 kV 配电网物理仿真系统采集单相接地时的过电压数据, 对所提算法进行验证。该平台模拟的配网结构如图 12 所示, 实物见图 13。系统参数见文献[24]。

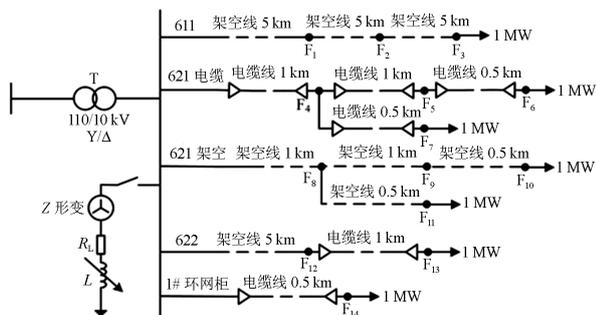


图 12 物理仿真系统网络结构

Fig. 12 Network structure of physical simulation system



图 13 物理仿真系统实物

Fig. 13 Physical simulation system object

由于采集的样本有限, 用仿真数据来训练模型, 将物理仿真系统采集的 70 组单相接地实验数据作为测试样本, 结果如表 6 所示。可以看出, 在所有的算法中, 所提的算法对单相接地样本依然得到最高的识别准确率。

表 6 算法识别准确率对比

Table 6 Comparison of recognition accuracy rate of algorithm

特征提取算法	识别准确率/%		
	BP	DBN	ELM
DTCWT+SVD	80	95.71	78.57
DWT+SVD	75.71	85.71	68.57
EMD+SVD	77.14	82.86	75.71

## 6 结论

1) 所提的 DTCWT 在配电网内部过电压信号的时频矩阵构造中具有优于传统算法的抗混叠特性。采用奇异值分解方法对时频矩阵特征降维处理, 减少计算量, 提高识别算法的速度。

2) 将 DBN 作为配电网内部过电压的分类器, 避免了传统神经网络易陷入局部最优的现象, 且在白噪声环境下也有较强的学习能力。

3) 通过实验证明, 所提方法相对于传统算法有更好的特征提取能力、识别效果以及更强的适应能力, 可较好地应用于配电网内部过电压的识别。

## 参考文献

- [1] 刘专, 郭泉辉, 刘娟, 等. 基于统计数据的配网故障修复时长分析[J]. 中国电力, 2017, 50(5): 84-87.  
LIU Zhuan, GUO Quanhui, LIU Juan, et al. Analysis on distribution network fault repair time based on statistical data[J]. Electric Power, 2017, 50(5): 84-87.
- [2] 郑志宇, 蔡翀, 张昭丞, 等. 基于小波域相子的电压暂降特征提取与成因辨识[J]. 电力系统保护与控制, 2018, 46(1): 16-22.  
ZHENG Zhiyu, CAI Chong, ZHANG Zhaocheng, et al. Wavelet-based phasor to detect and identify the voltage sag characteristics[J]. Power System Protection and Control, 2018, 46(1): 16-22.
- [3] 杜林, 李欣, 吴高林, 等. 采用 3 类特征参量比值法的

- 铁磁谐振过电压识别[J]. 高电压技术, 2011, 37(9): 2241-2249.
- DU Lin, LI Xin, WU Gaolin, et al. Ferro-resonance overvoltage identification using three feature parameter of ratio method[J]. High Voltage Engineering, 2011, 37(9): 2241-2249.
- [4] 覃星福, 龚仁喜. 基于广义 S 变换与 PSO-PNN 的电能质量扰动识别[J]. 电力系统保护与控制, 2016, 44(15): 10-17.
- QIN Xingfu, GONG Renxi. Power quality disturbance classification based on generalized S-transform and PSO-PNN[J]. Power System Protection and Control, 2016, 44(15): 10-17.
- [5] 杜林, 戴斌, 陆国俊, 等. 基于 S 变换局部奇异值分解的过电压特征提取[J]. 电工技术学报, 2010, 25(12): 147-153.
- DU Lin, DAI Bin, LU Guojun, et al. Overvoltage features extraction based on S-Transform and local singular value decomposition[J]. Transactions of China Electrotechnical Society, 2010, 25(12): 147-153.
- [6] 朱永利, 贾亚飞, 王刘旺, 等. 基于改进变分模态分解和 Hilbert 变换的变压器局部放电信号特征提取及分类[J]. 电工技术学报, 2017, 32(9): 225-239.
- ZHU Yongli, JIA Yafei, WANG Liuwang, et al. Feature extraction and classification on partial discharge signals of power transformers based on improved variational mode decomposition and Hilbert transform[J]. Transactions of China Electrotechnical Society, 2017, 32(9): 225-239.
- [7] 郭谋发, 游林旭, 洪翠, 等. 基于 LCD-Hilbert 谱奇异值和多级支持向量机的配电网故障识别方法[J]. 高电压技术, 2017, 43(4): 1239-1247.
- GUO Moufa, YOU Linxu, HONG Cui, et al. Identification method of distribution network faults based on singular value of LCD-Hilbert spectrums and multilevel SVM[J]. High Voltage Engineering, 2017, 43(4): 1239-1247.
- [8] 司马文霞, 王荆, 杨庆, 等. Hilbert-Huang 变换在电力系统过电压识别中的应用[J]. 高电压技术, 2010, 36(6): 1480-1486.
- SIMA Wenxia, WANG Jing, YANG Qing, et al. Application of Hilbert-Huang transform to power system over-voltage recognition[J]. High Voltage Engineering, 2010, 36(6): 1480-1486.
- [9] 陈炜, 方志广. 输电线路的雷电过电压的识别方法[J]. 自动化与仪器仪表, 2016(6): 69-72.
- CHEN Wei, FANG Zhiguang. Lightning overvoltage identification method for transmission lines[J]. Automation and Instrumentation, 2016(6): 69-72.
- [10] 任子晖, 王琦. 基于优化 DDAGSVM 多类分类策略的电能质量扰动识别[J]. 电力系统保护与控制, 2018, 46(5): 82-88.
- REN Zihui, WANG Qi. Power quality disturbance recognition based on improved DDAGSVM multi-class classification strategy[J]. Power System Protection and Control, 2018, 46(5): 82-88.
- [11] HOU K, SHAO G, WANG H, et al. Research on practical power system stability analysis algorithm based on modified SVM[J]. Protection and Control of Modern Power Systems, 2018, 3(3): 119-125. DOI: 10.1186/s41601-018-0086-0.
- [12] 郭森. 基于 BN 分解和 ALO 优化 LSSVM 模型的风电出力预测[J]. 智慧电力, 2017, 45(7): 92-99.
- GUO Sen. Wind power forecasting based on BN decomposition and LSSVM model optimized by ALO[J]. Smart Power, 2017, 45(7): 92-99.
- [13] 宋宗耘, 牛东晓, 肖鑫利, 等. 基于改进萤火虫算法优化 SVM 的变电工程造价预测[J]. 中国电力, 2017, 50(3): 168-173.
- SONG Zongyun, NIU Dongxiao, XIAO Xinli, et al. Substation engineering cost forecasting method based on modified firefly algorithm and support vector machine[J]. Electric Power, 2017, 50(3): 168-173.
- [14] 薛阳, 杜新纲, 张蓬鹤, 等. 电能表故障与地域气候、行业负荷关系研究[J]. 中国电力, 2017, 50(8): 98-105.
- XUE Yang, DU Xingang, ZHANG Penghe, et al. Research on the relationship between electric energy meter fault and regional climate & load in different industries[J]. Electric Power, 2017, 50(8): 98-105.
- [15] 齐郑, 张惠汐, 饶志, 等. 基于极限学习机的多信息融合区段定位方法[J]. 电力系统保护与控制, 2014, 42(19): 74-80.
- QI Zheng, ZHANG Huixi, RAO Zhi, et al. Multi-information fusion fault location based on extreme learning machine[J]. Power System Protection and Control, 2014, 42(19): 74-80.
- [16] 冯义, 刘慧文, 张宝平, 等. 基于集合经验模态分解和特征选择极端学习机的风速预测[J]. 智慧电力, 2018, 46(12): 30-37.
- FENG Yi, LIU Huiwen, ZHANG Baoping, et al. Short-term wind speed forecasting using ensemble empirical mode decomposition and extreme learning machine with feature selection[J]. Smart Power, 2018, 46(12): 30-37.
- [17] 张淑清, 胡永涛, 姜安琦, 等. 基于双树复小波和自适

- 应权重和时间因子的粒子群优化支持向量机的轴承故障诊断[J]. 中国机械工程, 2017, 28(3): 327-333.
- ZHANG Shuqing, HU Yongtao, JIANG Anqi, et al. Bearing fault diagnosis based on DTCWT and AWT-FPSO-optimized SVM[J]. China Mechanical Engineering, 2017, 28(3): 327-333.
- [18] 卢其威, 王涛, 李宗睿, 等. 基于小波变换和奇异值分解的串联电弧故障检测方法[J]. 电工技术学报, 2017, 32(17): 208-217.
- LU Qiwei, WANG Tao, LI Zongrui, et al. Detection method of series arcing fault based on wavelet transform and singular value decomposition[J]. Transactions of China Electrotechnical Society, 2017, 32(17): 208-217.
- [19] 石鑫, 朱永利, 萨初日拉, 等. 基于深度信念网络的电力变压器故障分类建模[J]. 电力系统保护与控制, 2016, 44(1): 71-76.
- SHI Xin, ZHU Yongli, SA Churila, et al. Power transformer fault classifying model based on deep belief network[J]. Power System Protection and Control, 2016, 44(1): 71-76.
- [20] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2014, 18(7): 1527-1554.
- [21] 单外平, 曾雪琼. 基于深度信念网络的信号重构与轴承故障识别[J]. 电子设计工程, 2016, 24(4): 67-71.
- SHAN Waiping, ZENG Xueqiong. Signal reconstruction and bearing fault identification based on deep belief network[J]. Electronic Design Engineering, 2016, 24(4): 67-71.
- [22] 毛勇华, 桂小林, 李前, 等. 深度学习应用技术研究[J]. 计算机应用研究, 2016, 33(11): 3201-3205.
- MAO Yonghua, GUI Xiaolin, LI Qian, et al. Study on application technology of deep learning[J]. Application Research of Computer, 2016, 33(11): 3201-3205.
- [23] 高伟, 陈伟凡, 杨耿杰, 等. 基于奇异值分解和多级支持向量机的配电网故障类型识别[J]. 电子测量与仪器学报, 2018, 32(2): 62-71.
- GAO Wei, CHEN Weifan, YANG Gengjie, et al. Fault type identification for distribution network based on singular value decomposition and multi-level support vector machine[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(2): 62-71.
- [24] GUO M F, YANG N C. Features-clustering-based earth fault detection using singular-value decomposition and fuzzy c-means in resonant grounding distribution systems[J]. International Journal of Electrical Power & Energy Systems, 2017, 93: 97-108.

收稿日期: 2018-05-19; 修回日期: 2018-07-11

作者简介:

高伟(1983—), 男, 博士, 讲师, 研究方向为配电网过电压识别、光伏故障诊断; E-mail: gaowei0203@fzu.edu.cn

杨耿杰(1966—), 男, 通信作者, 教授, 研究方向为电力系统分析; E-mail: 80201931@qq.com

郭谋发(1973—), 男, 教授, 研究方向为配电网自动化、单相接地故障诊断、配电网故障柔性消弧。

(编辑 葛艳娜)