

DOI: 10.19783/j.cnki.pspc.210955

基于卡尔曼滤波和深度置信网络的复合电能质量扰动分类

陈子璇, 席燕辉, 沈 银

(长沙理工大学电气与信息工程学院, 湖南 长沙 410114)

摘要: 针对实际电能质量扰动数据大、识别多重扰动精度不高的问题, 提出了一种基于自适应最大似然卡尔曼滤波和深度置信网络相结合的电能质量扰动识别方法。首先, 该方法使用自适应最大似然卡尔曼滤波对含有噪声的原始扰动信号进行去噪。然后, 通过深度置信网络对去除噪声的扰动信号进行训练、分类, 以此实现电能质量扰动类型的识别。最后, 在 20 类不同噪声水平下的电能质量扰动信号上进行测试。由仿真结果可知, 在不同的噪声水平下, 该方法都具有较高的分类正确率, 表明了该方法的有效性以及对噪声的强鲁棒性。

关键词: 电能质量扰动; 卡尔曼滤波; 深度置信网络; 扰动分类

Recognition of multiple power quality disturbances based on a Kalman filter and deep belief network

CHEN Zixuan, XI Yanhui, SHEN Yin

(School of Electrical and Information Engineering, Changsha University of Science and Technology, Changsha 410114, China)

Abstract: In order to solve the problems of large actual power quality disturbance data and low accuracy in identifying multiple power quality disturbances, a method of power quality disturbance recognition based on an adaptive Kalman filter based on maximum likelihood (KF-ML) and a deep belief network is proposed. First, the adaptive Kalman filter based on maximum likelihood is used to denoise the original disturbance signal with noise. Then the deep belief network is used to train and recognize the clean signal so that the type of power quality disturbance can be recognized. Finally, it is tested on power quality disturbance signals under 20 types of different noise levels. From the simulation results, it can be seen that the method in this paper has a higher classification accuracy rate under different noise levels. This shows the effectiveness of the method and is very robust to noise.

This work is supported by the National Natural Science Foundation of China (No. 51507015).

Key words: power quality disturbance; Kalman filter; deep belief network; disturbance classification

0 引言

随着智能电网的发展以及电力电子设备的广泛应用, 实际电力系统的电能质量扰动(Power Quality Disturbance, PQD)复杂多变, 不仅包含单一扰动, 还包含由不同类型、不同幅度、不同持续时间的多种单一扰动结合而成的复合扰动^[1-5]。由于不同扰动特征的结合, 使得识别变得更加困难和复杂^[6]。为了减小 PQD 造成的经济损失, 对其进行准确的识别是解决电能质量问题的基础^[7]。

电能质量扰动分类主要包括特征提取和扰动识别。特征提取是指对信号波形进行变换, 从中提取能反映扰动过程的有效特征量, 然后采用多标签分类器对复合扰动进行分类识别。常用的特征提取方

法有: 傅里叶变换^[8]、小波变换^[9]、S 变换^[10]、希尔伯特黄变换(Hilbert Huang Transform, HHT)^[11]、卡尔曼滤波^[12]等。扰动识别是采用人工神经网络、支持向量机、决策树、聚类法、模糊逻辑等分类方法来确定扰动信号的类型^[13-16]。

由于实际电力系统中各种电子器件的使用、信号传输过程中的电磁干扰以及采样误差等因素, 使得检测到的扰动信号中夹杂着大量的噪声信号。其使得原有的信号波形发生严重畸变, 严重时可能会淹没扰动信号的重要特征, 降低电能质量扰动分析的可靠性和有效性, 有时甚至使检测结果完全失效, 因此进行分类前, 需要先去除原始扰动信号中含有的噪声。卡尔曼滤波器(Kalman Filter, KF)具有算法简单、精度高且对噪声鲁棒性较强等特性, 它适用于线性、离散和有限维系统, 是控制、信号处理与通信等领域最基本、最重要的计算方法和工具之

基金项目: 国家自然科学基金项目资助(51507015)

一^[17]。目前,卡尔曼滤波器广泛应用于谐波检测^[18]、目标跟踪估计^[19]、GPS 监测、无人机作业等方面。基于此本文提出一种自适应最大似然卡尔曼滤波算法对含有噪声的原始扰动信号进行去噪。

近年来,对单个和少数多个电能质量扰动的智能分类已经有了大量的研究。文献[20]提出了一种基于卷积神经网络(Convolution Neural Network, CNN)的电能质量扰动分类算法,利用 CNN 从原始扰动图像中自适应地提取特征并加以分类,该方法对八种单一扰动进行实验并准确分类,具有较好的鲁棒性。文献[21]提出了一种将变分模式分解和两层多标记极端学习机神经网络相结合的复合电能质量扰动检测和分类新方法。文献[22]提出一种基于交叉小波变换的 Fischer 线性判别分析方法,用于复合电能质量扰动的特征选择和分类。文献[23]提出基于不完全 S 变换和梯度提升树的特征选择和分类器构建方法。上述研究大多是单个或双重扰动的情况,但由于电网结构的复杂性以及电网负荷的多样性等原因,实际应用中往往会出现三种甚至四种的扰动,导致精度大幅降低。

为此,本文提出了一种自适应卡尔曼滤波和深度置信网络(Deep belief network, DBN)相结合的混合方法,用于实际噪声环境下多个电能质量扰动的分类。本文的主要工作有:通过自适应最大似然卡尔曼滤波去除原始失真的电能质量扰动信号中的噪声;在单一和多重扰动的情况下,利用深度置信网络对去除噪声后的扰动信号进行分类。

1 自适应最大似然卡尔曼滤波

1.1 空间状态模型

考虑到被噪声污染的电能质量扰动信号包括基频分量和一定数量的谐波,其模型可表示为

$$y_k = A_{1,k} \cos(\omega k T_s + \varphi_1) + \sum_{r=2}^M A_{r,k} \cos(r\omega k T_s + \varphi_r) + v_k \quad (1)$$

式中: y_k 是观测信号; $A_{1,k}$ 、 ω 、 φ_1 分别表示基波分量的幅值、角频率和初相角; $A_{r,k}$ ($r=2, \dots, M$) 和 φ_r 表示第 r 次谐波分量的幅值和初相角; v_k 是均值为零协方差 $E(v_k v_k^T) = R_k$ 的高斯白噪声; M 是谐波的最高次数; T_s 是采样间隔,可以得到采样频率 f_s 。

以 $\mathbf{X}_k = [x_{1,k}, x_{2,k}, \dots, x_{2r-1,k}, x_{2r,k}, \dots, x_{2M-1,k}, x_{2M,k}]^T$ 为二维状态向量,表示如下:

$$\begin{aligned} x_{1,k} &= A_{1,k} \cos(\omega k T_s + \varphi_1), & x_{2,k} &= A_{1,k} \sin(\omega k T_s + \varphi_1) \\ & \vdots & & \vdots \\ x_{2r-1,k} &= A_{r,k} \cos(r\omega k T_s + \varphi_r), & x_{2r,k} &= A_{r,k} \sin(r\omega k T_s + \varphi_r) \\ & \vdots & & \vdots \\ x_{2M-1,k} &= A_{M,k} \cos(M\omega k T_s + \varphi_M), & x_{2M,k} &= A_{M,k} \sin(M\omega k T_s + \varphi_M) \end{aligned} \quad (2)$$

因此,模型(1)表示的离散观测信号以状态空间形式建模为

$$\begin{cases} \mathbf{X}_k = \mathbf{F}\mathbf{X}_{k-1} + \boldsymbol{\eta}_k = \\ \begin{bmatrix} \mathbf{F}_1 & 0 & \dots & 0 & 0 \\ 0 & \ddots & 0 & \dots & 0 \\ 0 & \dots & \mathbf{F}_r & 0 & 0 \\ 0 & \dots & 0 & \ddots & 0 \\ 0 & \dots & \dots & 0 & \mathbf{F}_M \end{bmatrix} \begin{bmatrix} x_{1,k-1} \\ x_{2,k-1} \\ \vdots \\ x_{2r-1,k-1} \\ x_{2r,k-1} \\ \vdots \\ x_{2M-1,k-1} \\ x_{2M,k-1} \end{bmatrix} + \boldsymbol{\eta}_k, \boldsymbol{\eta}_k \sim N(0, \mathbf{Q}_k) \\ y_k = \mathbf{H}\mathbf{X}_k + v_k \quad v_k \sim N(0, R_k) \end{cases} \quad (3)$$

式中: \mathbf{F} 和 \mathbf{H} 分别表示系统矩阵和观测矩阵; $\boldsymbol{\eta}_k$ 和 v_k 分别表示过程噪声和观测噪声; \mathbf{Q}_k 为 $\boldsymbol{\eta}_k$ 的协方差, R_k 为 v_k 的协方差; 矩阵 \mathbf{Q}_k 、 R_k 分别定义为

$$\begin{cases} \mathbf{Q}_k = \text{diag}([\gamma_1^2, \gamma_2^2, \dots, \gamma_{2r-1}^2, \gamma_{2r}^2, \dots, \gamma_{2M-1}^2, \gamma_{2M}^2]) \\ R_k = [\varepsilon^2] \end{cases} \quad (4)$$

式中,参数 $[\gamma_1, \gamma_2, \dots, \gamma_{2M-1}, \gamma_{2M}, \varepsilon]$ 是未知量,需要在进行 KF 滤波时在线估计得出。

为得到系统矩阵和观测矩阵,可将状态变量 $x_{2r-1,k+1}$ 在 $k+1$ 时刻展开得

$$\begin{aligned} x_{2r-1,k+1} &= A_{r,k} \cos[r\omega(k+1)T_s + \varphi_r] = \\ & A_{r,k} \cos[r\omega k T_s + \varphi_r] + r\omega T_s = \\ & A_{r,k} \cos(r\omega k T_s + \varphi_r) \cos r\omega T_s - A_{r,k} \sin(r\omega k T_s + \varphi_r) \sin r\omega T_s = \\ & [\cos r\omega T_s \quad -\sin r\omega T_s] \begin{bmatrix} A_{r,k} \cos(r\omega k T_s + \varphi_r) \\ A_{r,k} \sin(r\omega k T_s + \varphi_r) \end{bmatrix} = \\ & [\cos r\omega T_s \quad -\sin r\omega T_s] \begin{bmatrix} x_{2r-1,k} \\ x_{2r,k} \end{bmatrix} \end{aligned} \quad (5)$$

同理可将状态变量 $x_{2r-1,k+1}$ 在 $k+1$ 时刻展开得

$$\begin{aligned} x_{2r,k+1} &= A_{r,k} \sin[r\omega(k+1)T_s + \varphi_r] = \\ & A_{r,k} \sin[r\omega k T_s + \varphi_r] + r\omega T_s = \\ & A_{r,k} \sin(r\omega k T_s + \varphi_r) \cos r\omega T_s + A_{r,k} \cos(r\omega k T_s + \varphi_r) \sin r\omega T_s = \\ & [\sin r\omega T_s \quad \cos r\omega T_s] \begin{bmatrix} A_{r,k} \cos(r\omega k T_s + \varphi_r) \\ A_{r,k} \sin(r\omega k T_s + \varphi_r) \end{bmatrix} = \\ & [\sin r\omega T_s \quad \cos r\omega T_s] \begin{bmatrix} x_{2r-1,k} \\ x_{2r,k} \end{bmatrix} \end{aligned} \quad (6)$$

于是,可以得到矩阵 \mathbf{F}_r 、 \mathbf{H} , 分别定义为

$$\begin{cases} \mathbf{F}_r = \begin{bmatrix} \cos(r\omega T_s) & -\sin(r\omega T_s) \\ \sin(r\omega T_s) & \cos(r\omega T_s) \end{bmatrix} \quad (r=1, \dots, M) \\ \mathbf{H} = [1 \quad 0 \quad \dots \quad 1 \quad 0 \quad \dots \quad 1 \quad 0] \end{cases} \quad (7)$$

因此, 每个频率分量的幅度可以计算为

$$A_{r,k} = \sqrt{(x_{2r-1,k})^2 + (x_{2r,k})^2} \quad (8)$$

式中, $x_{2r-1,k}$ 、 $x_{2r,k}$ 可以从模型(3)中作为估计状态获得。

1.2 自适应 KF-ML 算法

设 $\hat{\mathbf{X}}_{k|k-1}$ 、 $\mathbf{S}_{k|k-1}$ 分别表示 \mathbf{X}_k 给定 $y_{1:k-1} = \{y_1, \dots, y_{k-1}\}$ 的条件均值和条件协方差, e_k 是预测的新息序列, 则卡尔曼滤波的预测方程为

$$\begin{cases} \hat{\mathbf{X}}_{k|k-1} = \mathbf{E}\{\mathbf{X}_k | y_{1:k-1}\} = \mathbf{F}\hat{\mathbf{X}}_{k-1|k-1} \\ e_k = y_k - \mathbf{H}\hat{\mathbf{X}}_{k|k-1} \\ \mathbf{S}_{k|k-1} = \mathbf{E}\{(\mathbf{X}_k - \hat{\mathbf{X}}_{k|k-1})(\mathbf{X}_k - \hat{\mathbf{X}}_{k|k-1})^T\} = \mathbf{F}\mathbf{S}_{k-1|k-1}\mathbf{F}^T + \mathbf{Q}_k \end{cases} \quad (9)$$

设 $\hat{\mathbf{X}}_{k|k}$ 、 $\mathbf{S}_{k|k}$ 分别表示 \mathbf{X}_k 给定 $y_{1:k} = \{y_1, \dots, y_k\}$ 的条件均值和条件协方差; Ψ_k 是 e_k 的协方差; \mathbf{K}_k 为增益; 则更新方程为

$$\begin{cases} \hat{\mathbf{X}}_{k|k} = \mathbf{E}\{\mathbf{X}_k | y_{1:k}\} = \hat{\mathbf{X}}_{k|k-1} + \mathbf{K}_k e_k \\ \mathbf{S}_{k|k} = \mathbf{E}\{(\mathbf{X}_k - \hat{\mathbf{X}}_{k|k})(\mathbf{X}_k - \hat{\mathbf{X}}_{k|k})^T\} = [\mathbf{I} - \mathbf{K}_k \mathbf{H}] \mathbf{S}_{k|k-1} \\ \Psi_k = \mathbf{E}\{e_k e_k^T\} = \mathbf{H} \mathbf{S}_{k|k-1} \mathbf{H}^T + \mathbf{R}_k \\ \mathbf{K}_k = \mathbf{S}_{k|k-1} \mathbf{H}^T \Psi_k^{-1} \end{cases} \quad (10)$$

通过递推 KF, 可以得到估计的状态变量 $\hat{\mathbf{X}}_{k|k}$, 并且可以消除噪声干扰的影响。根据估计的状态变量在任意时刻 k 计算去除噪声后的干扰信号 $\hat{y}_{k|k}$ 为

$$\hat{y}_{k|k} = \mathbf{H}\hat{\mathbf{X}}_{k|k} \quad (11)$$

在模型(9)-(10)中, 除了常数参数 $\gamma_1, \gamma_2, \dots, \gamma_{2M-1}, \gamma_{2M}, \varepsilon$ 外, 还需要估计初始状态 \mathbf{X}_{00} 和初始条件方差 $\mathbf{S}_{00} = \text{diag}([s_1 \ s_2 \ \dots \ s_{2M-1} \ s_{2M}])$, 所以要估计的参数 $\theta = (\gamma_1, \dots, \gamma_{2M}, \varepsilon, x_{1,0}, \dots, x_{2M,0}, s_1, \dots, s_{2M})$ 。假设 e_k 为具有协方差 Ψ_k 的高斯白噪声向量, 则其联合条件概率密度为

$$p(e_k | y_{k-1}, \dots, y_1, \theta) = \frac{1}{2\pi |\Psi_k|^{1/2}} \exp\left(-\frac{1}{2} e_k^T \Psi_k^{-1} e_k\right) \quad (12)$$

式中, $|\cdot|$ 表示行列式。因此, 模型(9)的(-2)对数似然函数可以从式(12)中导出, 如下:

$$\begin{aligned} (-2) \log p(y_N, \dots, y_1 | \theta) &= \\ \sum_{k=1}^N (-2) \log p(y_k | y_{k-1}, \dots, y_1, \theta) &= \\ \sum_{k=1}^N (-2) \log p(e_k | y_{k-1}, \dots, y_1, \theta) &= \\ \sum_{k=1}^N \left\{ \log |\Psi_k| + e_k^T \Psi_k^{-1} e_k \right\} + N \log 2\pi & \end{aligned} \quad (13)$$

其中, N 表示取样长度。

根据新息序列 e_k 及其协方差 Ψ_k , 通过式(13)可得到 θ 的最优参数为

$$\theta^* = \arg \min_{\theta} \sum_{k=1}^N \left\{ \log |\Psi_k(\theta)| + (e_k(\theta))^T (\Psi_k(\theta))^{-1} (e_k(\theta)) \right\} + N \log 2\pi \quad (14)$$

2 深度置信网络的复合电能质量扰动分类

深度置信网络(DBN)由多个受限玻尔兹曼机(Restricted Boltzmann Machines, RBM)堆叠而成, 在最后一个 RBM 的基础上增加一层反向传播(Back-Propagation, BP), DBN 实现了 RBM 各层的无监督训练和特征向量在不同空间的映射^[24-25]。特征提取在 DBN 中进行, 将去噪后的训练数据输入其中以提取其固有特征。虽然没有明确的提取过程, 但 DBN 能够自动从数据中学习各种扰动的特征, 避免了人工提取繁琐且容易丢失信息等缺陷。

2.1 受限玻尔兹曼机(RBM)

RBM 的原理图如图 1 所示, 它是一种无向图模型, 由可见层和隐藏层组成。两层均是由若干个互不相连的神经元构成, 两层的神经元通过权值 w 连接。可见层 v 用于输入训练数据, 隐藏层 h 提取特征。

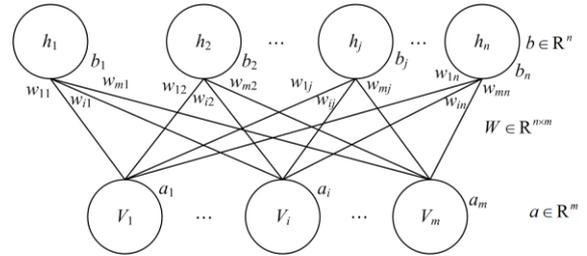


图 1 RBM 原理图

Fig. 1 Schematic diagram of RBM

假设每个节点为二元变量, 即 v 和 h 的取值仅为 0 或 1, m 、 n 分别为可见层 v 和隐藏层 h 包含的神经元数目, $a = (a_1, a_2, \dots, a_m)$ 为可见层单元的偏置, $b = (b_1, b_2, \dots, b_n)$ 为隐藏层单元的偏置, RBM 能量函数可以定义为

$$E(v, h) = -\sum_{i=1}^m a_i v_i - \sum_{j=1}^n b_j h_j - \sum_{i=1}^m \sum_{j=1}^n v_i w_{ij} h_j \quad (15)$$

式中: v_i 和 h_j 分别表示可见层的第 i 个节点和隐藏层的第 j 个节点; w_{ij} 为两个节点之间的权重值。

可见层和隐藏层之间的联合概率分布为

$$p(v, h) = \frac{1}{Z} \exp(-E(v, h)) \quad (16)$$

式中, Z 为归一化系数, 它是将所有可见层和隐藏

层的向量相加获得的, 定义为

$$Z = \sum_{v,h} e^{-E(v,h)} \quad (17)$$

同时还可以得到关于 v 和 h 的概率分布分别为

$$p(v) = \frac{1}{Z} \sum_h e^{-E(v,h)} \quad (18)$$

$$p(h) = \frac{1}{Z} \sum_v e^{-E(v,h)} \quad (19)$$

RBM 的学习目标是为了让网络表示的分布尽可能地拟合输入数据, 然后通过微调网络结构参数使得概率 $p(v)$ 达到最大值^[26]。

RBM 同一层中的任何两个神经元之间没有连接, 而每一层之间的神经元全连接, 于是当可见层神经元的状态被给定时, 各隐藏层神经元的激活是条件独立的, 反之也成立。因此, 可见层和隐藏层的神经元被激活的条件概率分别描述为

$$p(h_j = 1 | v) = \sigma \left(b_j + \sum_{i=1}^m v_i w_{ij} \right) \quad (20)$$

$$p(v_i = 1 | h) = \sigma \left(a_i + \sum_{j=1}^n h_j w_{ji} \right) \quad (21)$$

式中, σ 为 Sigmoid 激活函数, 定义为 $\sigma(x) = \frac{1}{1+e^{-x}}$ 。

2.2 深度置信网络(DBN)

DBN 的原理图如图 2 所示, 本文是用三层 RBM 堆叠而成。可见层主要用于接收输入数据向量, 并通过 RBM 将输入数据转换到隐藏层, 即高层 RBM 的可见层输入来自于低层 RBM 的隐藏层输出。DBN 的训练主要由两个过程组成: 无监督地由低到高逐层预训练和 BP 神经网络有监督地对网络参数

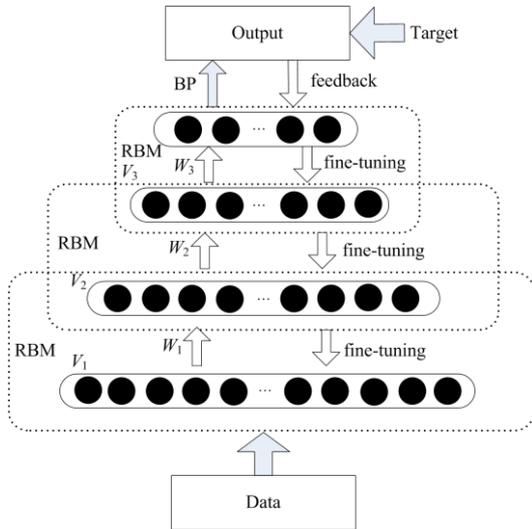


图 2 DBN 原理图

Fig. 2 Schematic diagram of DBN

进行微调^[27]。首先使用对比散度算法预训练第一层 RBM 得到该层的网络参数, 将其隐藏层输出作为高一层的可见层输入训练后的 RBM, 重复此操作, 直至完成 DBN 中所有 RBM 层的训练。然后将训练获得的网络参数作为初始值, 通过反向传播(BP)算法有监督地对其进行微调, 从而得到合适的复合电能质量扰动特征提取及分类识别系统。这里使用的是训练获得的参数来初始化网络而不是随机初始化, 避免了训练过程中的局部最优, 因此 DBN 可以获得更高的预测精度。整体原理方案如图 3 所示。

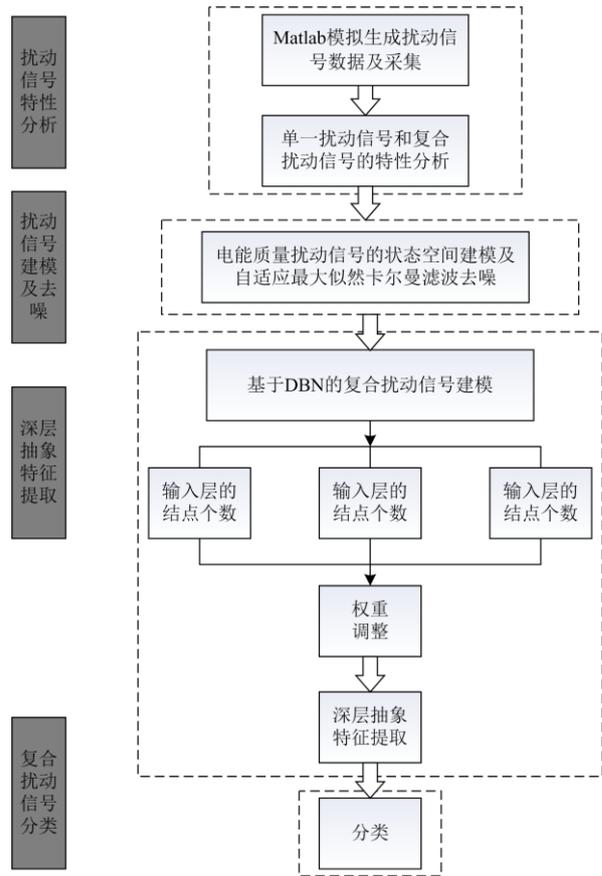


图 3 整体原理方案

Fig. 3 Total principle scheme

3 实验结果和分析

3.1 数据产生

本研究使用 Matlab 生成了 20 种不同类别的电能质量复合扰动信号, 如表 1 所示, 包括 7 种单一扰动和 13 种复合扰动。为了模拟各种实际情况, 在产生的扰动信号中分别加入了 20 dB、30 dB 和 40 dB 的高斯白噪声。对于每一类扰动, 通过随机改变幅值、角频率和相位, 生成 1 500 组样本信号。每个采样信号长度为 5 个周期, 采样频率为 10 kHz, 即每个信号有 1 000 个采样点。

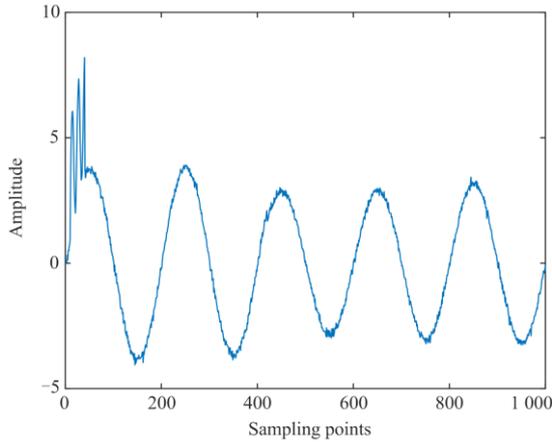
表 1 20 种不同类型电能质量失真的参数和模型

Table 1 Parameters and models of 20 different types of power quality distortion

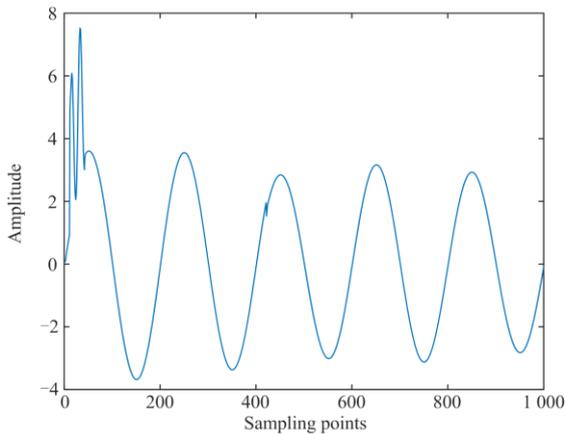
标签	扰动	模型	参数变化
C1	暂升	$x(t) = A\{1 + \alpha[u(t-t_1) - u(t-t_2)]\} \sin(\omega t)$	$\alpha = 0.1 \square 0.9, T < t_1 - t_2 < 8T$
C2	中断	$x(t) = A\{1 - \alpha[u(t-t_1) - u(t-t_2)]\} \sin(\omega t)$	$\alpha = 0.9 \square 1.0, T < t_1 - t_2 < 8T$
C3	暂降	$x(t) = A\{1 - \alpha[u(t-t_1) - u(t-t_2)]\} \sin(\omega t)$	$\alpha = 0.1 \square 0.9, T < t_1 - t_2 < 8T$
C4	谐波	$x(t) = A\{a_1 \sin(\omega t) + a_3 \sin(3\omega t) + a_5 \sin(5\omega t) + a_7 \sin(7\omega t)\}$	$\alpha_1 = 0.1 \square 0.9, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 1.0$
C5	振荡	$x(t) = A\{\sin \omega t + \lambda e^{-(t-t_1)} \sin \mu \omega t [u(t-t_1) - u(t-t_2)]\}$	$\lambda = 0.1 \square 0.8, \mu = 10 \square 40$ $0.5T < t_1 - t_2 < 3T$
C6	脉冲	$x(t) = A\{\sin(\omega t) + \alpha[u(t-t_1) - u(t-t_2)]\}$	$\alpha = 1 \square 3, 1 \text{ ms} \leq t_1 - t_2 \leq 3 \text{ ms}$
C7	波动	$x(t) = A\{1 + \alpha_f \sin(\beta_f \omega t)\} \sin(\omega t)$	$\alpha_f = 0.1 \square 0.3, \beta_f = 0.1 \square 0.5$
C8	暂降+谐波	$x(t) = A\{1 - \alpha[u(t-t_1) - u(t-t_2)] + \alpha_1\} \sin(\omega t) + A\{a_3 \sin(3\omega t) + a_5 \sin(5\omega t) + a_7 \sin(7\omega t)\}$	$\alpha = 0.1 \square 0.9, T < t_1 - t_2 < 8T$ $\alpha_1 = 0.1 \square 0.9, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 1.0$
C9	中断+谐波	$x(t) = A\{1 - \alpha[u(t-t_1) - u(t-t_2)] + \alpha_1\} \sin(\omega t) + A\{a_3 \sin(3\omega t) + a_5 \sin(5\omega t) + a_7 \sin(7\omega t)\}$	$\alpha = 0.9 \square 1.0, T < t_1 - t_2 < 8T$ $\alpha_1 = 0.1 \square 0.9, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 1.0$
C10	暂降+振荡	$x(t) = A\{1 - \alpha[u(t-t_1) - u(t-t_2)]\} \sin(\omega t) + A\lambda e^{-(t-t_3)} \sin \mu \omega t [u(t-t_3) - u(t-t_4)]$	$\alpha = 0.1 \square 0.9, T < t_1 - t_2 < 8T$ $\lambda = 0.1 \square 0.8, \mu = 10 \square 40$ $0.5T < t_3 - t_4 < 3T$
C11	脉冲+谐波	$x(t) = A\{a_1 \sin(\omega t) + a_3 \sin(3\omega t) + a_5 \sin(5\omega t) + a_7 \sin(7\omega t) + \alpha[u(t-t_1) - u(t-t_2)]\}$	$\alpha_1 = 0.1 \square 0.9, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 1.0$ $\alpha = 1 \square 3, 1 \text{ ms} \leq t_1 - t_2 \leq 3 \text{ ms}$
C12	振荡+谐波	$x(t) = A\{a_1 \sin(\omega t) + a_3 \sin(3\omega t) + a_5 \sin(5\omega t) + a_7 \sin(7\omega t) + \lambda e^{-(t-t_1)} \sin \mu \omega t [u(t-t_1) - u(t-t_2)]\}$	$\alpha_1 = 0.1 \square 0.9, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 1.0$ $\lambda = 0.1 \square 0.8, \mu = 10 \square 40$ $0.5T < t_1 - t_2 < 3T$
C13	波动+谐波	$x(t) = A\{1 + \alpha_f \sin(\beta_f \omega t)\} \{a_1 \sin(\omega t) + a_3 \sin(3\omega t) + a_5 \sin(5\omega t) + a_7 \sin(7\omega t)\}$	$\alpha_f = 0.1 \square 0.3, \beta_f = 0.1 \square 0.5$ $\alpha_1 = 0.1 \square 0.9, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 1.0$
C14	脉冲+振荡	$x(t) = A\{\sin \omega t + \alpha[u(t-t_1) - u(t-t_2)] + \lambda e^{-(t-t_3)} \sin \mu \omega t [u(t-t_3) - u(t-t_4)]\}$	$\alpha = 1 \square 3, 1 \text{ ms} \leq t_1 - t_2 \leq 3 \text{ ms}$ $\lambda = 0.1 \square 0.8, \mu = 10 \square 40$ $0.5T < t_3 - t_4 < 3T$
C15	脉冲+波动	$x(t) = A\{[1 + \alpha_f \sin(\beta_f \omega t)] \sin(\omega t) + \alpha[u(t-t_1) - u(t-t_2)]\}$	$\alpha_f = 0.1 \square 0.3, \beta_f = 0.1 \square 0.5$ $\alpha = 1 \square 3, 1 \text{ ms} \leq t_1 - t_2 \leq 3 \text{ ms}$
C16	振荡+波动	$x(t) = A\{[1 + \alpha_f \sin(\beta_f \omega t)] \sin \omega t + \lambda e^{-(t-t_1)} \sin \mu \omega t [u(t-t_1) - u(t-t_2)]\}$	$\alpha_f = 0.1 \square 0.3, \beta_f = 0.1 \square 0.5$ $\lambda = 0.1 \square 0.8, \mu = 10 \square 40$ $0.5T < t_1 - t_2 < 3T$
C17	谐波+振荡+脉冲	$x(t) = A\{a_1 \sin(\omega t) + a_3 \sin(3\omega t) + a_5 \sin(5\omega t) + a_7 \sin(7\omega t) + \alpha[u(t-t_1) - u(t-t_2)] + \lambda e^{-(t-t_3)} \sin \mu \omega t [u(t-t_3) - u(t-t_4)]\}$	$\alpha_1 = 0.1 \square 0.9, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 1.0$ $\alpha = 1 \square 3, 1 \text{ ms} \leq t_1 - t_2 \leq 3 \text{ ms}$ $\lambda = 0.1 \square 0.8, \mu = 10 \square 40$ $0.5T < t_3 - t_4 < 3T$
C18	谐波+脉冲+波动	$x(t) = A\{1 + \alpha_f \sin(\beta_f \omega t)\} \{a_1 \sin(\omega t) + a_3 \sin(3\omega t) + a_5 \sin(5\omega t) + a_7 \sin(7\omega t) + \alpha[u(t-t_1) - u(t-t_2)]\}$	$\alpha_f = 0.1 \square 0.3, \beta_f = 0.1 \square 0.5$ $\alpha_1 = 0.1 \square 0.9, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 1.0$ $\alpha = 1 \square 3, 1 \text{ ms} \leq t_1 - t_2 \leq 3 \text{ ms}$
C19	振荡+脉冲+波动	$x(t) = A\{1 + \alpha_f \sin(\beta_f \omega t)\} \{[\sin \omega t + \alpha[u(t-t_1) - u(t-t_2)] + \lambda e^{-(t-t_3)} \sin \mu \omega t [u(t-t_3) - u(t-t_4)]]\}$	$\alpha_f = 0.1 \square 0.3, \beta_f = 0.1 \square 0.5$ $\alpha = 1 \square 3, 1 \text{ ms} \leq t_1 - t_2 \leq 3 \text{ ms}$ $\lambda = 0.1 \square 0.8, \mu = 10 \square 40$ $0.5T < t_3 - t_4 < 3T$
C20	暂升+振荡+脉冲+波动	$x(t) = A\{1 + \alpha_f \sin(\beta_f \omega t)\} \{[1 + \alpha[u(t-t_1) - u(t-t_2)]] \sin \omega t + \alpha_1 [u(t-t_3) - u(t-t_4)] + \lambda e^{-(t-t_5)} \sin \mu \omega t [u(t-t_5) - u(t-t_6)]\}$	$\alpha_f = 0.1 \square 0.3, \beta_f = 0.1 \square 0.5$ $\alpha_1 = 1 \square 3, 1 \text{ ms} \leq t_3 - t_4 \leq 3 \text{ ms}$ $\lambda = 0.1 \square 0.8, \mu = 10 \square 40$ $0.5T < t_5 - t_6 < 3T$

3.2 自适应最大似然卡尔曼滤波去噪

为了减少噪声带来的影响, 将 3.1 节产生的原始数据通过本文第 1 节提出的自适应最大似然卡尔曼滤波进行去噪。本文状态变量初始值设置为 $\begin{bmatrix} \hat{x}_{1,k}(0) \\ \hat{x}_{2,k}(0) \end{bmatrix} = \begin{bmatrix} 1 \\ 0.03 \end{bmatrix}$, 初始协方差 $\hat{S}(0) = \begin{bmatrix} 10^{-6} & 0 \\ 0 & 10^{-6} \end{bmatrix}$, $Q = \text{diag}[10^{-6}, 10^{-6}]$, $R = [2.5 \times 10^{-5}]$ 。图 4 为 C20(暂升+振荡+脉冲+波动)加入 20 dB 高斯白噪声的原始波形和去噪后的波形, 证明了该方法的有效性。



(a) 原始波形



(b) 去噪后波形

图 4 C20 去噪前后对比

Fig. 4 Comparison before and after denoising of C20

3.3 分类结果

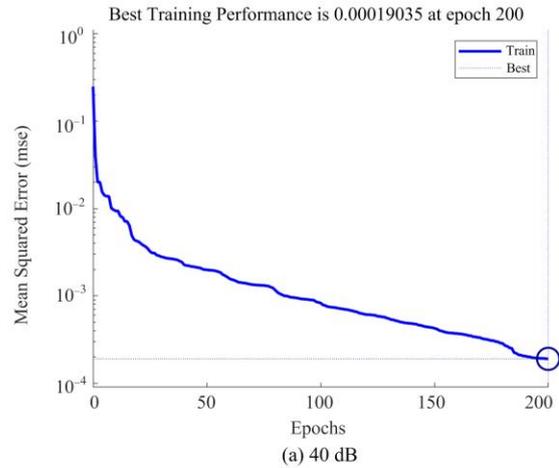
为了测试电能质量扰动的分类结果, 每种类别有 1 500 个样本信号, 其中 1 000 个用于 DBN 训练, 500 个用于测试。本文采用的扰动识别方法为直接多分类法, 将 20 类扰动用于训练的样本信号同时输入 DBN 中, 生成 C1~C20 这 20 种标签类型, 训练完毕后, 进行测试。由于在实际扰动数据中含有高斯白噪声, 并且训练数据和测试数据之间的噪声水

平不同, 因此采用不同的噪声干扰对 DBN 进行训练和测试。

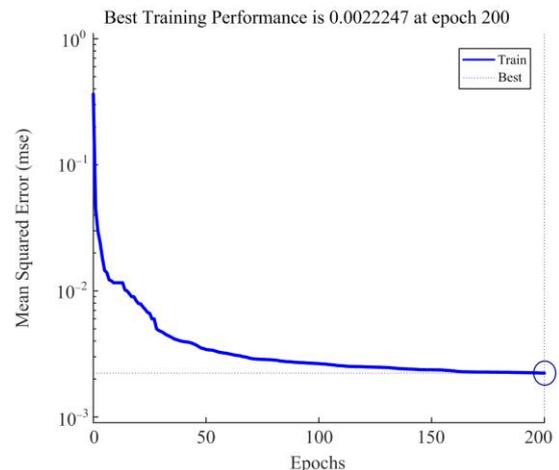
网络结构的好坏直接影响到分类的准确性, 网络结构包括隐含层数和每层节点数。如果网络规模太大, 可能会出现过拟合, 在训练过程中梯度容易消失; 如果网络规模太小, 可能会出现拟合不足, 分类精度不高。因此, 有必要选择合适的网络结构。

本文在 DBN 中堆叠 3 个 RBM, 每个隐藏层的神经元数量都是通过试验来确定的。此外, 网络拓扑结构随不同噪声水平的训练数据而变化。因此, 对于不同的噪声水平, 有不同的网络结构: 当噪声为 40 dB 时, 每个隐藏层的神经元个数分别为 1 000、100、200; 当噪声为 30 dB 时, 每个隐藏层的神经元个数分别为 1 000、500、200; 当噪声为 20 dB 时, 每个隐藏层的神经元个数分别为 1 000、100、200。

采用 Sigmoid 函数作为激励函数, 用比例共轭梯度法更新网络参数。在训练过程中, 学习率设置为 0.1, 迭代次数设置为 200 次。训练过程的损失曲线如图 5 所示, 测试数据在不同噪声水平下的测试精度如表 2—表 4 所示。



(a) 40 dB



(b) 30 dB

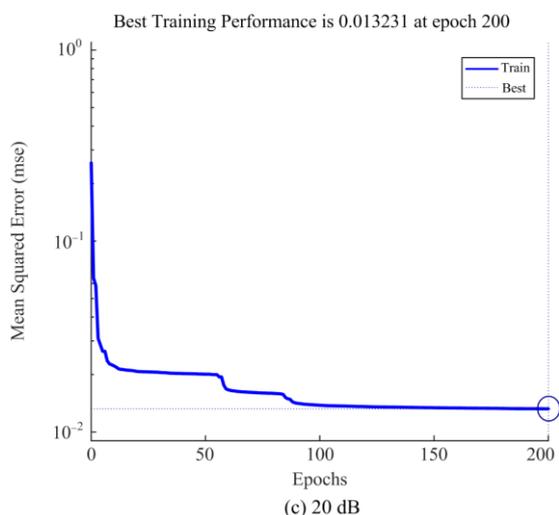


图 5 不同噪声水平下训练过程的损失曲线

Fig. 5 Loss curve of training process under different noise levels

表 2 训练数据受 40 dB 噪声干扰情况下的分类精度

Table 2 Classification accuracy of training data under 40 dB noise disturbance

扰动类别	分类精度/%			
	无噪声	SNR=40 dB	SNR=30 dB	SNR=20 dB
C1	100	100	99.6	81.8
C2	99.4	100	100	98.4
C3	100	100	100	66.2
C4	100	100	100	100
C5	99.8	100	99.4	90.8
C6	100	100	98.6	81
C7	100	100	100	100
C8	96.2	98.6	97.6	94.2
C9	100	100	98	90.6
C10	99.6	98.8	99.2	98.2
C11	100	100	100	94.6
C12	100	100	100	100
C13	100	100	100	99.6
C14	100	100	100	97.6
C15	100	100	100	100
C16	99.6	99.6	99.4	94.8
C17	100	100	100	95
C18	100	100	100	100
C19	100	100	100	100
C20	100	100	100	100
Average	99.73	99.85	99.59	94.14

表 3 训练数据受 30 dB 噪声干扰情况下的分类精度

Table 3 Classification accuracy of training data under 30 dB noise disturbance

扰动类别	分类精度/%			
	无噪声	SNR=40 dB	SNR=30 dB	SNR=20 dB
C1	100	100	100	95.6
C2	98	100	99.8	99.6
C3	100	100	100	99.6
C4	100	100	100	100
C5	71.8	76.2	75.2	76.2
C6	100	100	100	93.8
C7	100	100	100	100
C8	96	99	100	99.6
C9	100	99.8	99.8	86.6
C10	99.2	98.2	99.4	98
C11	100	100	100	98.4
C12	100	100	100	100
C13	100	100	100	100
C14	100	100	100	98.4
C15	100	100	100	100
C16	99.6	99.4	99.6	91.8
C17	100	100	100	98.4
C18	100	100	100	100
C19	100	100	100	100
C20	100	100	100	100
Average	98.23	98.63	98.69	96.8

表 4 训练数据受 20 dB 噪声干扰情况下的分类精度

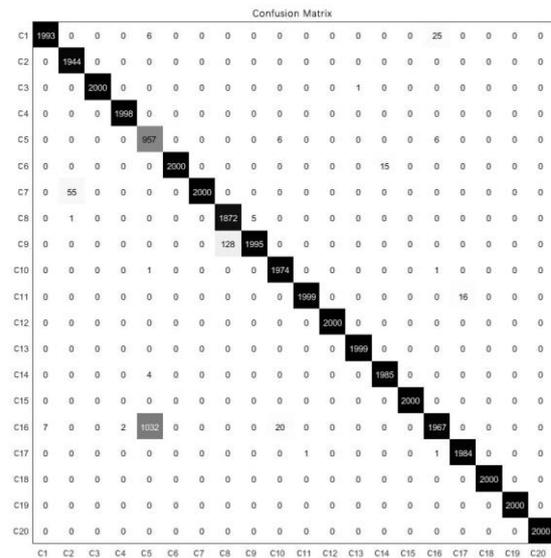
Table 4 Classification accuracy of training data under 20 dB noise disturbance

扰动类别	分类精度/%			
	无噪声	SNR=40 dB	SNR=30 dB	SNR=20 dB
C1	100	100	100	99.4
C2	96.8	97.4	96.8	98.8
C3	99.2	100	100	100
C4	100	100	100	100
C5	47	45.6	55.8	69.6
C6	100	100	100	99.6
C7	100	100	100	100
C8	92.6	91.2	92.4	96
C9	100	100	100	99.6
C10	97.8	97.2	97.6	97
C11	100	100	100	99.6
C12	100	100	100	100
C13	100	100	100	100
C14	99.6	100	99.6	99.2
C15	100	100	100	100
C16	99.6	99.6	99.8	95.6
C17	100	99.4	99.6	98.2
C18	100	100	100	100
C19	100	100	100	100
C20	100	100	100	100
Average	96.63	96.52	97.09	97.63

从图 5 可以看出,随着迭代次数的增加, DBN 调整其权重和偏差,直到损失函数达到相对较小的值。从表 2—表 4 可以看出,不同噪声条件下的平均准确率基本都在 95% 以上。因此,该方法具有较高的分类能力,即使在高噪声水平下也不受影响。

为了详细评估分类性能,图 6 示出测试得到的混淆矩阵,其中横轴表示预测分类的标签,纵轴表示实际分类的标签。混淆矩阵的对角线和非对角线元素分别指对特定类型的 PQD 的成功分类和成功分类。从混淆矩阵中可以观察到,大多数类别被正确分类。

为了进一步评价该方法的有效性和可行性,将本文的分类精度与文献[28-31]中的分类精度进行了比较,并在表 5 中给出。由于扰动信号组合较多,因此本文与其他方法采用的扰动信号不完全相同。



(c) 20 dB

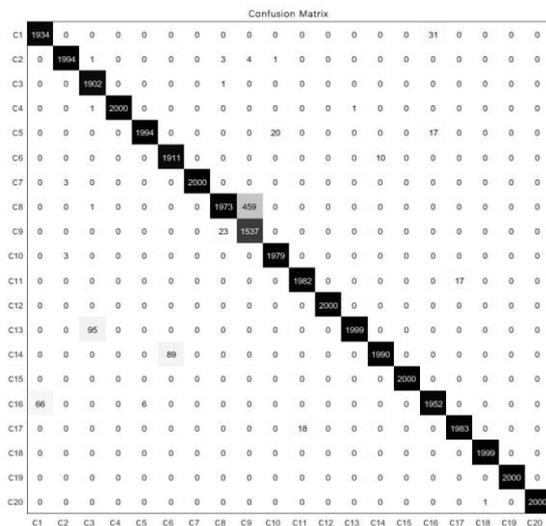
图 6 不同噪声水平下测试的混淆矩阵

Fig. 6 Confusion matrix tested under different noise levels

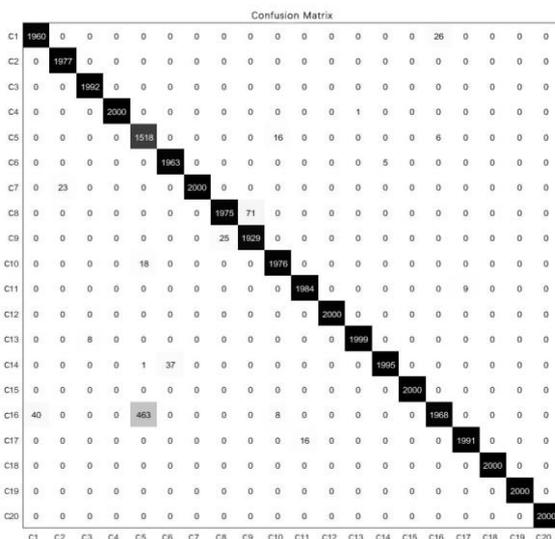
表 5 分类准确率性能比较

Table 5 Comparison of classification accuracy performance

方法	分类精度/%			
	无噪声	SNR=40 dB	SNR=30 dB	SNR=20 dB
文献[28](2012)	100	99	93.25	—
文献[29](2015)	99.8	98.2	96.1	93.5
文献[30](2016)	98.7	97.5	96.2	93.2
文献[31](2019)	—	—	96.55	94.1
40 dB	99.73	99.85	99.59	94.14
本文 30 dB	98.23	98.63	98.69	96.8
20 dB	96.63	96.52	97.09	97.63



(a) 40 dB



(b) 30 dB

从表 5 可以看出,在低强度噪声(40 dB 噪声或无噪声)的情况下,所提方法的性能几乎与其他方法一样高。但是,在较高的噪声水平(如 30 dB 和 20 dB)下,所提方法优于其他三种方法。比较结果表明,所提分类方法对噪声具有很高的鲁棒性,适用于高噪声环境。即使结合更多干扰,该方法的精确度也非常高,C18~C20 在所有情况下的分类准确率都达到 100%,即使在最差的情况下,C17 的多重干扰分类的准确率也达到 95%,可见所提方法组合更多的干扰对精度的影响较小,当组合更多的干扰时,误差会大大降低。这可能是因为 KF-ML 能够从原始失真的 PQ 信号中去噪声, DBN 结构对于各种干扰具有很高的检测多方面非线性特性的能力。

4 结论

本文提出了一种基于最大似然卡尔曼滤波

(KF-ML)和深度置信网络(DBN)相结合的电能质量扰动识别方法。该方法利用 KF-ML 对原始干扰信号去噪, 训练 DBN 能够准确识别复合电能质量扰动的类型。扰动识别的结果表明, 该方法不仅具有较好的识别效果, 而且具有较好的鲁棒性。对本文使用的 20 类电能质量扰动识别的平均准确率基本在 95% 以上, 对多重扰动的分类准确度基本达到 100%。

参考文献

- [1] 刘志刚, 张巧革, 张杨. 电能质量复合扰动分类的研究进展[J]. 电力系统保护与控制, 2013, 41(13): 146-153.
LIU Zhigang, ZHANG Qiaoge, ZHANG Yang. Research progress on the classification of compound disturbances in power quality[J]. Power System Protection and Control, 2013, 41(13): 146-153.
- [2] 占勇, 程浩忠. 电能质量复合扰动分类识别[J]. 电力自动化设备, 2009, 29(3): 93-96.
ZHAN Yong, CHENG Haozhong. Classification and identification of power quality composite disturbances[J]. Electric Power Automation Equipment, 2009, 29(3): 93-96.
- [3] 陈华丰, 杨志刚, 曾涛. 基于 S 变换和规则基的复合电能质量扰动识别[J]. 电测与仪表, 2015, 52(12): 122-128.
CHEN Huafeng, YANG Zhigang, ZENG Tao. Composite power quality disturbance identification based on S-transform and rule basis[J]. Electrical Measurement & Instrumentation, 2015, 52(12): 122-128.
- [4] 王仁明, 汪宏阳, 张贇宁, 等. 基于分段改进 S 变换和随机森林的复合电能质量扰动识别方法[J]. 电力系统保护与控制, 2020, 48(7): 19-28.
WANG Renming, WANG Hongyang, ZHANG Yunning, et al. Composite power quality disturbance recognition based on segmented modified S-transform and random forest[J]. Power System Protection and Control, 2020, 48(7): 19-28.
- [5] 徐达, 洪文慧, 季天瑶, 等. 基于 S 变换和长短期记忆网络的电能质量复合扰动识别[J]. 广东电力, 2021, 34(7): 33-39.
XU Da, HONG Wenhui, JI Tianyao, et al. Composite Disturbance identification of power quality based on S transform and long short term memory network[J]. Guangdong Electric Power, 2021, 34(7): 33-39.
- [6] SEBASTIAN P, DŪSA P A. Implementation of a power quality signal classification system using wavelet based energy distribution and neural network[C] // 2015 International Conference on Power and Advanced Control Engineering, August 12-14, 2015, Bengaluru, India: 157-161.
- [7] 郑炜, 林瑞全, 王俊, 等. 基于 GAF 与卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2021, 49(11): 97-104.
ZHENG Wei, LIN Ruiquan, WANG Jun, et al. Power quality disturbance classification based on GAF and a convolutional neural network[J]. Power System Protection and Control, 2021, 49(11): 97-104.
- [8] 祁才君, 王小海. 基于插值 FFT 算法的间谐波参数估计[J]. 电工技术学报, 2003, 18(1): 92-95.
QI Caijun, WANG Xiaohai. Parameter estimation of interharmonics based on interpolation FFT algorithm[J]. Transactions of China Electrotechnical Society, 2003, 18(1): 92-95.
- [9] JAIN B, JAIN S, NEMA R K. Investigations on power quality disturbances using discrete wavelet transform[J]. International Journal of Electrical, Electronics and Computer Engineering, 2013, 2(2): 47-53.
- [10] 兰金晨, 朱革兰, 李松奕. 基于广义 S 变换突变识别的暂稳态谐波检测方法[J]. 电力系统保护与控制, 2020, 48(23): 40-46.
LAN Jinchen, ZHU Gelan, LI Songyi. Detection method of transient and steady state harmonics based on generalized S-transform mutation recognition[J]. Power System Protection and Control, 2020, 48(23): 40-46.
- [11] 田振果, 傅成华, 吴浩, 等. 基于 HHT 的电能质量扰动定位与分类[J]. 电力系统保护与控制, 2015, 43(16): 36-42.
TIAN Zhenguo, FU Chenghua, WU Hao, et al. Location and classification of power quality disturbances based on HHT[J]. Power System Protection and Control, 2015, 43(16): 36-42.
- [12] 陈晓静, 李开成, 肖剑, 等. 一种实时电能质量扰动分类方法[J]. 电工技术学报, 2017, 32(3): 45-55.
CHEN Xiaojing, LI Kaicheng, XIAO Jian, et al. A classification method of real-time power quality disturbances[J]. Transactions of China Electrotechnical Society, 2017, 32(3): 45-55.
- [13] KUMAR R, SINGH B, SHAHANI D T, et al. Recognition of power-quality disturbances using S-transform based ANN classifier and rule-based decision tree[J]. IEEE Transactions on Industry Applications, 2015, 51(2): 1249-1258.
- [14] LEE C Y, SHEN Y X. Optimal feature selection for power-quality disturbances classification[J]. IEEE Transaction on Power Delivery, 2011, 26(4): 2342-2351.
- [15] ZHAO Wenjing, SHANG Liqun, SUN Jinfan. Power quality disturbance classification based on time-frequency domain multifeatured and decision tree[J]. Protection and Control of Modern Power Systems, 2019, 4(4): 337-342.

[16] 徐艳春, 阚锐涵, 高永康, 等. 混合动力系统电能质量扰动分析及治理[J]. 电力建设, 2021, 42(4): 17-26.
XU Yanchun, KAN Ruihan, GAO Yongkang, et al. Research on power quality improvement of hybrid power system[J]. Electric Power Construction, 2021, 42(4): 17-26.

[17] 聂小华. 一种基于卡尔曼滤波的电能质量扰动检测新方法[J]. 中国电机工程学报, 2017, 37(22): 6649-6659.
NIE Xiaohua. A new method of power quality disturbance detection based on Kalman filter[J]. Proceedings of the CSEE, 2017, 37(22): 6649-6659.

[18] 崔永林, 席燕辉, 张小东. 基于自适应卡尔曼滤波残差分析的谐波检测[J]. 电力系统保护与控制, 2019, 47(24): 92-100.
CUI Yonglin, XI Yanhui, ZHANG Xiaodong. Detection of harmonic based on residual analysis using adaptive Kalman filter[J]. Power System Protection and Control, 2019, 47(24): 92-100.

[19] 程华, 张雪婷, 房一泉. 基于扩散卡尔曼滤波算法的目标跟踪估计[J]. 计算机应用与软件, 2021, 38(2): 191-197.
CHENG Hua, ZHANG Xueting, FANG Yiquan. Target tracking estimation based on diffusion Kalman filtering algorithm[J]. Computer Applications and Software, 2021, 38(2):191-197.

[20] 王维博, 张斌, 曾文入, 等. 基于特征融合一维卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2020, 48(6): 53-60.
WANG Weibo, ZHANG Bin, ZENG Wenru, et al. Power quality disturbance classification based on feature fusion one-dimensional convolution neural network[J]. Power System Protection and Control, 2020, 48(6): 53-60.

[21] ENSHAEI A, ENSHAEI P. A new S-transform-based method for identification of power quality disturbances. Arabian Journal for Science and Engineering, 2018, 43(6): 2817-2832.

[22] SINGH N, PRADHAN P M. Efficient discrete S-transform based on optimally concentrated window[J]. IEEE Signal Processing Letters, 2019, 26(1): 14-18.

[23] 许立武, 李开成, 罗奕, 等. 基于不完全 S 变换与梯度提升树的电能质量复合扰动识别[J]. 电力系统保护与控制, 2019, 47(6): 24-31.
XU Liwu, LI Kaicheng, LUO Yi, et al. Power quality composite disturbance identification based on incomplete S-transform and gradient lifting tree[J]. Power System Protection and Control, 2019, 47(6): 24-31.

[24] FU Yang, ZHANG Yun, QIAO Haiyu, et al. Analysis of feature extracting ability for cutting state monitoring using deep belief networks[J]. Procedia CIRP, 2015, 31: 29-34.

[25] 张然, 郭俊宏, 蓝新斌, 等. 基于深度置信网络的电能质量扰动检测与分类[J]. 广东电力, 2020, 33(6): 92-98.
ZHANG Ran, GUO Junhong, LAN Xinbin, et al. Power quality disturbance detection and classification based on deep belief network[J]. Guangdong Electric Power, 2020, 33(6): 92-98.

[26] 杨雯, 尹康涌, 鲍奕宇, 等. 基于深度置信网络的电网故障类型辨识[J]. 电力工程技术, 2021, 40(2): 169-177.
YANG Wen, YIN Kangyong, BAO Yiyu, et al. Fault type identification of power network based on deep confidence network[J]. Electric Power Engineering Technology 2021, 40(2): 169-177.

[27] HINTON G E. Training products of experts by minimizing contrastive divergence[J]. Neural Computation, 2002, 14(8): 1771-1800.

[28] HUANG N T, XU D G, LIU X S, et al. Power quality disturbances classification based on S-transform and probabilistic neural network[J]. Neurocomputing, 2012, 98: 12-23.

[29] ALSHAHRANI S, ABBOD M, ALAMRI B, et al. Evaluation and classification of power quality disturbances based on discrete wavelet transform and artificial neural networks[C] // 50th International Universities Power Engineering Conference (UPEC), September 1-4, 2015, Stoke on Trent, UK: 1-5.

[30] ABDOOS A A, MIANA EI P K, GHADIKOLAEI M R. Combined VMD-SVM based feature selection method for classification of power quality events[J]. Applied Soft Computing, 2016, 38: 637-646.

[31] MOHAMMADI M, AFRASIABI M, AFRASIABI S, et al. Detection and classification of multiple power quality disturbances based on temporal deep learning[C] // 2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), June 11-14, 2019, Genova, Italy.

收稿日期: 2021-07-22; 修回日期: 2021-11-24

作者简介:

徐子璇(1997—), 男, 通信作者, 硕士研究生, 研究方向为电能质量扰动分类; E-mail: 448686623@qq.com

席燕辉(1979—), 女, 博士, 副教授, 研究方向为复杂系统建模; E-mail: xiyanhui@126.com

沈银(1997—), 男, 硕士研究生, 研究方向为电力故障检测。E-mail: 1214235356@qq.com

(编辑 魏小丽)