

DOI: 10.19783/j.cnki.pspc.240802

# 一种电能质量混合扰动检测与识别新方法

王燕<sup>1</sup>, 曹浩敏<sup>2</sup>, 刘世龙<sup>1</sup>, 骆玉深<sup>1</sup>, 卞安吉<sup>1</sup>

(1. 西南民族大学电气工程学院, 四川 成都 610041; 2. 广州市奔流电力科技有限公司, 广东 广州 510700)

**摘要:** 随着高碳电力系统向新型电力系统的快速转型和发展, 风电、光伏等新能源及电力电子设备大规模接入电网, 导致电力系统产生更为复杂、多变的电能质量扰动问题。为快速、准确地检测与捕捉扰动数据, 并针对传统扰动识别方法对复杂混合扰动适用性降低、人工选取特征困难等不足, 提出一种电能质量混合扰动检测与识别新方法。该方法首先采用所提出的峰差引导局部差和累加扰动检测方法, 以快速、准确地检测与捕捉扰动数据。其次, 采用改进迭代自适应核回归滤波方法对捕捉到的含噪扰动数据进行预处理, 达到有效抑制噪声干扰、保留扰动突变等细节特征的目的。最后采用所提出的改进可视化轨迹圆方法把一维扰动数据变换为形状特征更明显、更利于辨识的二维轨迹圆图像, 并输入卷积神经网络进行自动特征提取与分类。实验结果表明, 新方法不仅具有较强的抗噪性和较高的扰动检测准确率, 且对单一及复杂混合扰动具有较高的识别准确率。

**关键词:** 电能质量扰动检测与识别; 可视化轨迹圆; 迭代自适应核回归; 卷积神经网络

## A novel method for combined power quality disturbances detection and identification

WANG Yan<sup>1</sup>, CAO Haomin<sup>2</sup>, LIU Shilong<sup>1</sup>, LUO Yushen<sup>1</sup>, BIAN Anji<sup>1</sup>

(1. College of Electrical Engineering, Southwest Minzu University, Chengdu 610041, China;

2. Guangzhou Power Electrical Technology Co., Ltd., Guangzhou 510700, China)

**Abstract:** With the rapid transformation of high-carbon power systems to new power systems, the large scale integration of renewable energy sources such as wind and solar, along with the widespread use of power electronic devices, has led to increasing complex and variable power quality disturbances (PQDs). To quickly and accurately detect and capture PQDs and to overcome limitations of traditional disturbance identification methods, such as reduced applicability to complex hybrid PQDs and difficulty in manually selecting features, this paper propose a novel approach for PQDs detection and identification. The proposed approach first employs peak difference guided local difference accumulation to rapidly and accurately detect and capture the PQDs. Then, the improved iterative adaptive kernel regression (IIAKR) method is used for preprocess the captured noisy PQDs, effectively suppressing noise while preserving detailed disturbance features. Finally, the improved visual trajectory circle (IVTC) method transforms the 1-D PQDs into 2-D trajectory circle images with more prominent shape and easier identification features, which are then input to convolutional neural networks (CNN) for autonomous feature extraction and classification. Experimental results show that the proposed approach offers strong noise immunity, high detection rate and classification accuracy for both single and complex PQDs.

This work is supported by the National Natural Science Foundation of China (No. 52477198).

**Key words:** PQD detection and identification; visual trajectory circle; iterative adaptive kernel regression; CNN

## 0 引言

在过去的20年间, 我国实现了风电、光伏等新能源技术的跨越式发展。随着2020年双碳战略目标

的提出, 促进高比例风电、光伏等新能源并网消纳, 将成为我国构建新型电力系统的当务之急。但伴随着具有随机性、波动性与间歇性的新能源大规模并网, 以及高比例电力电子设备的接入<sup>[1]</sup>, 电网电能质量问题也越来越严重, 导致电网电压、电流畸变, 产生谐波、振荡、电磁脉冲以及更为复杂的混合电能质量扰动问题。这些电能质量扰动问题, 会影响

**基金项目:** 国家自然科学基金项目资助(52477198); 西南民族大学中央高校基本科研业务费专项资金项目资助(ZYN2025047)

电网供电可靠性,危害电网安全与稳定性,甚至造成用电设备故障及重大经济损失<sup>[2]</sup>。目前高比例风电、光伏等新能源并网的电力系统发展处于起步阶段,对其可能出现的复杂混合扰动开展检测与分类研究具有重要意义<sup>[3-4]</sup>,也提出了更高的要求。

电能质量扰动(power quality disturbance, PQD)检测方法的研究目前大多集中在时域、时频域分析技术两大类。目前时频域的扰动检测方法主要有小波变换、小波包变换、经验模态分解、变分模态分解、局部均值分解以及S变换等。其中,小波变换虽具有良好的时频分辨率,但其抗噪性较差,不同的小波基检测性能差异较大<sup>[5]</sup>。文献[6]针对经验小波变换在频谱泄露和抗噪性方面存在的不足,提出改进经验小波变换的扰动检测方法,一定程度上提升了扰动检测性能,但其存在端点效应问题,且检测效果在扰动分量频率接近时不佳。小波包能更加精细地划分频带,但在扰动检测过程中存在严重的频谱混叠现象,也易受噪声干扰。经验模态分解<sup>[7]</sup>、变分模态分解<sup>[8-9]</sup>和局部均值分解<sup>[10]</sup>的端点效应及模态混叠现象均难以完全抑制。S变换一般用于特征提取,具有良好的时频特性及抗噪性,但运算量大<sup>[11-12]</sup>,且对扰动起止时刻定位的功能较弱。因此,时频域的扰动检测方法可以从时域和频域两个方面检测扰动的持续时间、幅值及频率特征等,一般多用于分类特征量的提取与特征刻画图像的获取,但其运算量往往较大,不如时域扰动检测方法更适合扰动的快速检测与捕捉。目前,时域扰动检测方法中,奇异值分解具有一定抗噪性,但无法有效检测过零点扰动<sup>[13]</sup>;为解决过零点扰动检测问题,文献[14]提出自适应辛几何模态分解结合短时能量差分因子的扰动检测方法,具有较好的扰动起止时刻检测效果,但对暂态振荡的检测效果有待提升。文献[15]提出弧长差分序列扰动检测方法,该方法较简单,但在扰动检测的过程中必须前置滤波器来提高抗噪性,对过零点扰动检测效果不佳。

电能质量扰动分类与识别方法的研究目前主要集中在两大方向,即传统特征提取+模式分类器、深度学习算法<sup>[16]</sup>。传统特征提取+模式分类器的方法中,特征提取主要采用短时傅立叶变换、希尔伯特黄变换、小波变换、经验模态分解及S变换等对扰动信号进行时频分析,概括并提炼出较为显著的分类特征,而模式分类器主要采用聚类算法、决策树、支持向量机、随机森林等对提取的特征量进行分类与识别<sup>[17-18]</sup>。传统特征提取+模式分类器的方法一般具有结构简单、分类效率高等优点,但特征的提取和筛选没有统一的方法指导,需要具有

相关先验知识的人工参与,筛选特征的有效性及准确性也会直接影响最终扰动的分类效果<sup>[19]</sup>。近几年深度学习算法因具有自动提取大数据抽象特征的能力而在图像、语音识别等领域成为了研究热点,并取得了不错的研究成果<sup>[20-21]</sup>。当前深度学习算法中卷积神经网络(convolutional neural networks, CNN)可对图像进行直接学习,自主筛选提取特征,具有高度的自适应性和较好的分类效果,已被广泛应用于人脸识别、目标跟踪和文字识别等方面,近几年才逐渐在电能质量扰动分类方面展开相应的研究和应用<sup>[22-23]</sup>。有些扰动信号特别是混合扰动的特征在时域往往区别不明显,因此运用CNN进行扰动识别的关键是如何将电能质量扰动信号从一维转换为特征形状更明显的二维图像。文献[24]提出一种新颖的神秘曲线方法,可将电能质量扰动信号映射为三维空间的立体曲线,虽然图像中扰动特征明显,但三维图像数据复杂,数据量较大,应用于深度学习中会增加计算复杂度。文献[3]提出一种可视化轨迹圆方法,可将不同类型的电能质量扰动信号从一维变换成二维轨迹圆图像,该方法提取的轨迹圆图像简单、数据量小且扰动特征明显,但对部分扰动特征的刻画不够准确,例如当扰动突变幅值较大时,提取的轨迹圆存在形状如脉冲扰动的异常突变特征,会影响深度学习算法对扰动识别的准确度。

为了快速、准确地检测和捕捉电能质量扰动,并且有效地对混合电能质量扰动进行分类与识别,本文在深入研究现有时域扰动检测方法和PQD识别技术的基础上,创新性地提出一种电能质量扰动检测与识别新方法。为了验证该方法的有效性,首先进行了大量的仿真扰动检测与分类实验,并与多种方法进行了对比分析;其次,为验证该方法的实用性,对电网实测扰动数据进行了测试与分析。

## 1 本文所提混合扰动检测与识别新方法概述

PQD检测与识别系统架构一般包括PQD数据采集、通信和上位系统PQD分析<sup>[25]</sup>。本文主要以该系统架构为分析背景,针对PQD数据采集侧和上位系统PQD分析侧,研究高效的电能质量扰动检测方法、上位系统PQD识别技术。本文基于该系统架构,提出一种混合扰动检测与识别新方法,如图1所示,该方法主要包含电能质量扰动检测、滤波及识别这几部分内容。

1) PQD检测:本文提出基于峰差引导局部差和累加的电能质量扰动检测新方法,对电能质量信号 $x(n)$ 进行快速的扰动检测与捕获。考虑到一般在PQD数据采集侧(如风电场、光伏电站、变电站、电

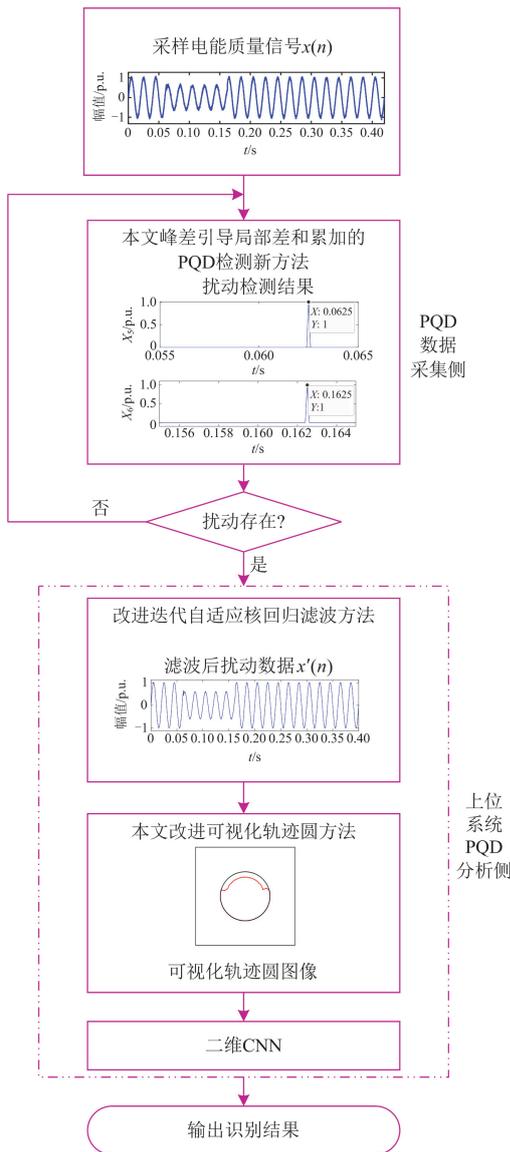


图 1 本文电能质量混合扰动检测与识别新方法

Fig. 1 Flow chart of the proposed new method for combined disturbances detection and recognition

动汽车充电站、工业负荷、居民负荷侧及海量分布式电源并网点等位置)可安装低成本电能质量采集设备<sup>[25]</sup>,若将本文扰动检测方法嵌入电能质量采集设备可实现扰动波形的快速检测与捕获,即当检测到未发生扰动,则继续监测,当检测到扰动存在,则可快速捕获扰动波形并上传上位系统分析。

2) PQD 滤波: 考虑到低信噪比环境下 PQD 数据可能会受较强噪声污染,而深度学习算法往往抗噪性又较低,为提高低信噪比环境下扰动识别的准确率,上位系统分析侧可通过设置启动滤波处理程序对扰动数据进行滤波。文中采用改进迭代自适应核回

归方法(improved iterative adaptive kernel regression, IIAKR)对 PQD 信号  $x(n)$  进行滤波处理,可获得滤波后的扰动数据  $x'(n)$ 。需要说明的是,若应用于非低信噪比环境时也可设置关闭此滤波处理程序。

3) PQD 识别: 本文提出基于二维 CNN 的改进可视化轨迹圆电能质量扰动识别方法,该方法针对文献[3]中可视化轨迹圆方法(visual trajectory circle, VTC)的不足,提出改进可视化轨迹圆方法(improved visual trajectory circle, IVTC),并利用其将不同类型的一维扰动数据  $x'(n)$  转换成二维轨迹圆图像,使不同类型扰动的形状特征更加明显和易于辨识;其次将轨迹圆图像输入 CNN 神经网络,自动提取图像数据的内在特征,有效识别其扰动类型。

## 2 基于峰差引导局部差和累加的电能质量扰动检测新方法

为了快速、准确地检测和捕获 PQD,本文提出了一种基于峰差引导局部差和累加的 PQD 检测新方法,其流程如图 2 所示。

设采样的电能质量信号为  $x(n)$ , 算法进行扰动检测的详细步骤如下所述。

Step1: 对归一化电能质量信号  $x(n)$ , 利用式(1)求归一化频谱  $X(l\Delta f)$ , 并在  $[100, f_s/2]$  Hz 范围内利用式(2)提取幅值较大的高频主频率点  $l_i\Delta f$  的频谱  $X_{\text{main}}(l_i\Delta f)$ 。当高频主频率点数大于等于 1, 则表明存在幅值较大的高频扰动,直接进入 Step9 捕获扰动信号;反之,则进入 Step2 继续判定。

$$X(l\Delta f) = 2|X_{\text{FFT}}(l\Delta f)|/N \quad (1)$$

式中:  $X_{\text{FFT}}$  为离散快速傅里叶频谱;  $\Delta f$  表示频率采样间隔,  $\Delta f = f_s/N$ ,  $f_s$  为信号采样频率;  $l=1, 2, \dots, \text{floor}(N/2)$ ,  $N$  为信号采样点数。

$$\begin{cases} X((l_i - 1)\Delta f) < X(l_i\Delta f) > X((l_i + 1)\Delta f) \\ X(l_i\Delta f) \geq \varepsilon \\ X_{\text{main}}(l_i\Delta f) = X(l_i\Delta f) \end{cases} \quad (2)$$

式中:  $l_i$  表示第  $i$  个主频率点的序列号;  $\varepsilon$  在此处取较大的阈值 0.07 p.u., 目的是直接、快速、准确地检测出明显的谐波、振荡等高频加性扰动。

Step2: 以归一化电能质量信号  $x(n)$  初始过零点为起始, 根据波峰差异检测定位原理计算其每  $M/T$  周期绝对值的最大值构成序列  $X_1$ , 再进行差分计算得到差分序列  $X_2$ 。

$$X_1(k) = \max \left\{ \begin{aligned} &|x(1 + (k-1)M)|, \\ &|x(2 + (k-1)M)|, \dots, |x(kM)| \end{aligned} \right\} \quad (3)$$

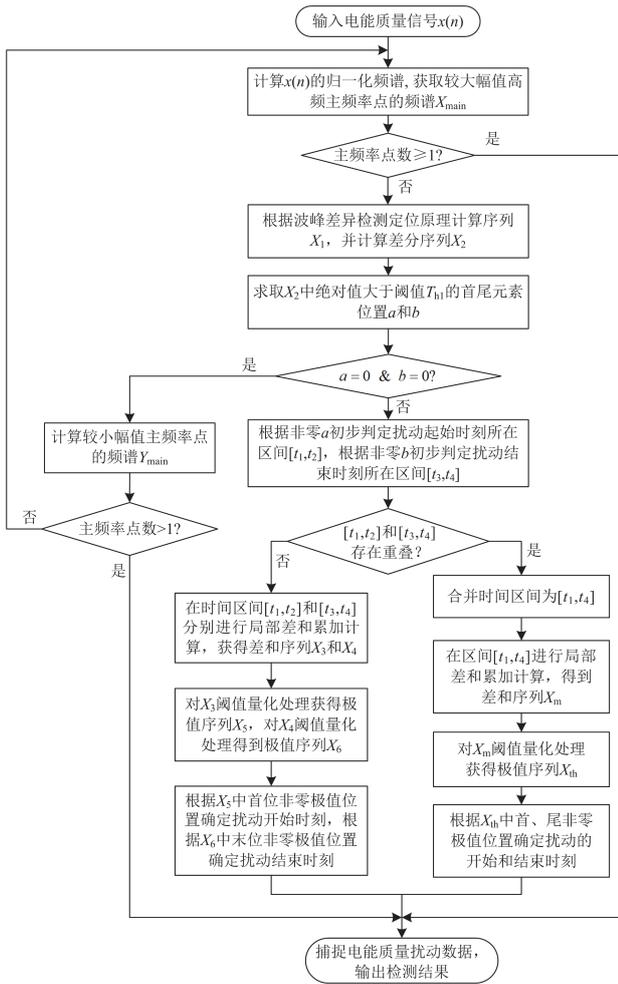


图2 基于峰差引导局部差和累加的PQD检测新方法流程

Fig. 2 Flow chart of the new PQD detection method based on peak difference guided local difference accumulation

式中:  $k=1,2,\dots,\text{floor}(N/M)$ ,  $M$  可取  $T/4$  或  $T/2$ ,  $T$  为每周周期采样点数。当电能质量信号采样频率较低时, 每周周期数据点较少,  $M$  可取  $T/2$  使结果更具准确性。

$$X_2(k) = X_1(k+1) - X_1(k) \quad (4)$$

**Step3:** 求取  $X_2$  序列中绝对值大于阈值  $T_{h1}$  的元素, 并用  $a$  和  $b$  分别记录这些元素中首、尾元素的位置。若  $X_2$  序列中不存在绝对值大于  $T_{h1}$  的元素, 则令  $a=0$  和  $b=0$ , 进入 **Step4**; 反之进入 **Step5**。

通过大量实验确定具有自适应性的阈值  $T_{h1}$  如式(5)所示。

$$T_{h1} = \text{mean}(|X_2|) / \chi \quad (5)$$

式中:  $\text{mean}$  表示取平均值; 参数  $\chi$  一般取值范围为  $[0.18, 0.25]$ , 通常取值 0.21 均能满足要求。

需要说明的是非零  $a$  和  $b$  能反映暂态扰动发生和结束时刻所在的大致区间, 但对于正常电压、电

压闪变及幅值较小的谐波等稳态电能质量扰动, 提取的  $a$  和  $b$  均为 0。因此在  $a=0$  &  $b=0$  的情况下还需进入 **Step4** 继续检测是否存在较小幅值谐波、电压闪变等稳态扰动。

**Step4:** 设定  $\varepsilon$  为 0.01 p.u. 可有效滤除背景噪声频谱干扰的影响, 在  $(0, f_s/2)$  Hz 范围内利用式(2)提取较小幅值主频率点  $l_i \Delta f$  的频谱  $Y_{\text{main}}(l_i \Delta f)$ 。当主频率点数大于 1 时, 进入 **Step8** 捕获电能质量扰动信号, 反之则为正常电压, 返回 **Step1** 继续进行监测。

**Step5:** 根据非零  $a$ 、 $b$  初步判定扰动起始时刻所在区间  $[t_1, t_2]$ 、扰动结束时刻所在区间  $[t_3, t_4]$ , 如式(6)所示。然后同时进入 **Step6** 和 **Step9**。

$$\begin{cases} t_1 = (aM - M) \cdot \Delta t \\ t_2 = (aM + M) \cdot \Delta t \end{cases} \begin{cases} t_3 = (bM - M) \cdot \Delta t \\ t_4 = (bM + M) \cdot \Delta t \end{cases} \quad (6)$$

式中:  $\Delta t$  表示采样时间间隔。

**Step6:** 判定  $t_3 < t_2$ ? 若条件不成立, 表明区间  $[t_1, t_2]$  和  $[t_3, t_4]$  不存在重叠, 则进入 **Step7** 在这两个区间分别进行扰动开始和结束时刻的精确定位; 反之若条件成立, 表明这两个区间存在重叠, 则将二者合并为一个区间  $[t_1, t_4]$ , 并进入 **Step8** 在该区间同时对扰动的开始和结束时刻进行精确定位。

需要说明的是, 对于脉冲暂态和持续时间非常短的其他暂态扰动, 其扰动的发生和结束时刻可能同时存在于  $[t_1, t_2]$  和  $[t_3, t_4]$  两个区间, 通过区间的合并, 能更加准确和高效地定位扰动起止时刻。

**Step7:** 在小区间  $[t_1, t_2]$  内进行局部差和累加计算, 得到归一化差和序列  $X_3$  如式(7)所示; 同理在小区间  $[t_3, t_4]$  内进行局部差和累加计算, 可获得归一化差和序列  $X_4$ 。

$$\begin{cases} X'_3(j) = \left| \sum_{i=1}^w [x(j) - x(j \pm i \Delta t)] \right| \\ X''_3(j) = \left[ \frac{1}{\sigma} (X'_3(j) - \bar{X}'_3) \right]^2 \\ X_3(j) = \frac{X''_3(j)}{\max(X''_3)} \end{cases} \quad (7)$$

式中:  $j = t_1, t_1 + \Delta t, \dots, t_2$ ;  $w$  取值范围为  $[2, 7]$ , 低信噪比下可以取较大值, 反之取较小值;  $X'_3$  为局部差和累加绝对值序列, 有助于放大扰动的突变奇异性;  $\bar{X}'_3$  表示  $X'_3$  的平均值;  $\sigma$  表示  $X'_3$  的方差;  $X''_3$  主要作用是突出偏离均值的扰动突变特性, 抑制背景噪声干扰;  $\max$  表示取最大值。

文中在两个小区间内对采样数据进行如式(7)所示的处理, 不仅可以显著降低运算量, 而且更有

利于准确定位扰动起止时刻。

再利用式(8)对  $X_3$  进行量化处理, 获得极值序列  $X_5$ ; 同理对  $X_4$  进行量化处理, 可获得极值序列  $X_6$ 。

$$X_5(j) = \begin{cases} X_3(j), & \text{if } X_3(j) \geq A_{\text{ptsx}} \ \& \\ & X_3(j - \Delta t) < X_3(j) > X_3(j + \Delta t) \\ 0, & \text{otherwise} \end{cases} \quad (8)$$

式中: 阈值  $A_{\text{ptsx}}$  的取值范围为 [0.1, 1), 通过大量实验发现一般取值约 0.6 均能满足要求。

统计  $X_5$  和  $X_6$  序列中的非零极值, 取  $X_5$  中第一个非零极值对应的时刻为扰动起始时刻, 并取  $X_6$  中最后一个非零极值对应的时刻为扰动结束时刻。跳转到 Step9。

**Step8:** 根据式(7)所示的局部差和累加以及式(8)所示的量化处理方法, 同理可在合并区间  $[t_1, t_4]$  内计算归一化的差和序列  $X_m$ , 获得极值序列  $X_{th}$ 。统计序列  $X_{th}$  中的非零极值, 可取首、尾非零极值对应的时刻分别作为扰动起始和结束时刻。

**Step9:** 捕捉 PQD 数据, 输出检测结果。根据检测结果用户可以根据实际需求灵活捕捉所检测的电能质量扰动数据长度。

为了更加形象和清晰地展示本文扰动检测新方法, 以 3 例采样频率为 10 kHz、信噪比为 25 dB 的含噪扰动信号为例进行检测分析。

利用本文扰动检测新方法对一例含有 3、5 和 7 次谐波成分的含噪谐波扰动信号  $x$  进行检测, 得到如附录 A 图 A1 所示的检测结果。 $x$  中谐波幅值分别设定为 0.2 p.u.、0.1 p.u. 和 0.3 p.u.。从图 A1 中可以看出: 通过 Step1 获得被检测信号的主频率点频谱  $X_{\text{main}}$  中包含了 150 Hz、250 Hz 和 350 Hz 的谐波频率点, 表明存在高频扰动, 则可直接进入 Step9 捕捉该电能质量扰动信号。

利用本文扰动检测新方法对一例含噪的暂降扰动信号  $x$  进行检测, 得到的检测结果如附录 A 图 A2 所示。 $x$  中暂降幅值设定为 0.4 p.u., 持续时间为 5 个周期, 起始时间设定为 0.0625 s, 结束时间为 0.1625 s。从图 A2 中可以看出: 通过 Step2 和 Step3 获得的  $X_2$  中存在超出阈值的系数, 其首尾两个系数分别位于第 12 和第 32 个 1/4 周期, 表示存在扰动, 令  $a=12$ 、 $b=32$ 。Step5 根据  $a$  和  $b$  确定扰动起始和结束时刻所在的时间区间分别为 [0.055, 0.065] s 和 [0.155, 0.165] s, Step6 判定这两个时间区间不存在重叠, 随后 Step7 对扰动进行精确定位。通过 Step7 分别在这两个时间区间计算获得了差和序列  $X_3$  和

$X_4$ , 而  $X_3$  和  $X_4$  中存在突出的尖脉冲分别指示扰动的开始和结束时刻, 也表明局部差和累加法能较好地突出扰动的突变奇异性 and 抑制背景噪声干扰。 $X_3$  和  $X_4$  经过量化处理, 滤除背景噪声干扰获得极值序列  $X_5$  和  $X_6$ , 精确定位出暂降的开始时刻为 0.0625 s、结束时刻为 0.1625 s, 与设定值的误差均为 0 s。

一例含噪的脉冲暂态扰动信号  $x$ , 其脉冲幅度为 0.6 p.u.、设定的脉冲开始时刻为 0.0821 s, 结束时刻为 0.0831 s, 利用本文扰动检测新方法得到的检测结果如图 3 所示。从图 3 中可以看出: 通过 Step2 和 Step3 获得  $X_2$  序列中存在两个超出阈值的系数, 分别位于第 16 和第 17 个 1/4 周期, 表示存在扰动, 于是令  $a=16$ 、 $b=17$ 。Step5 根据  $a$  和  $b$  确定扰动起始和结束时刻所在的时间区间分别为 [0.075, 0.0849] s 和 [0.08, 0.0899] s, Step6 将这两个存在重叠的时间区间合并为一个时间区间 [0.075, 0.0899] s, Step8 在该合并时间区间内对扰动进行精确定位。通过 Step8 获得差和序列  $X_m$ , 而  $X_m$  中存在突出的两个尖脉冲分别指示脉冲扰动的开始和结束时刻, 表明扰动的突变奇异性得到有效放大且背景噪声干扰得到有效抑制。 $X_m$  经量化处理得到极值序列  $X_{th}$ , 通过  $X_{th}$  首尾非零极值精确定位出脉冲暂态的开始时刻 0.0821 s、结束时刻 0.0831 s, 与设定值的误差均为 0 s。

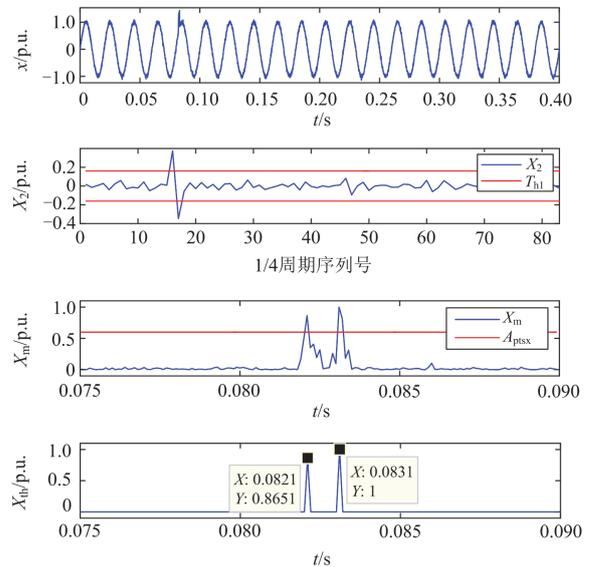


图 3 本文扰动检测方法的脉冲暂态检测结果

Fig. 3 Detection results of impulsive transient by using the proposed new disturbance detection method

### 3 改进迭代自适应核回归滤波方法

迭代自适应核回归方法是一种非常有效的图

像滤波方法,能有效抑制噪声干扰,并能有效保留图像边缘等细节特征信息,文献[26]在深入研究该方法的基础上提出了如图4所示的改进迭代自适应核回归PQD去噪方法。本文利用该方法对电能质量信号进行滤波,即使在强噪声干扰环境下,也能有效滤除噪声干扰、保护扰动细节特征。

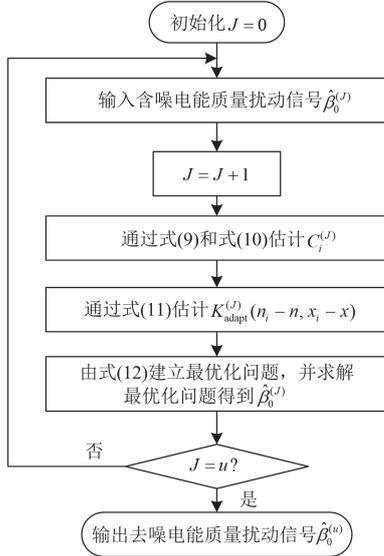


图4 改进迭代自适应核回归PQD去噪方法流程

Fig. 4 Flow chart of the IIKR for denoising of PQD

设捕捉的电能质量扰动信号为  $x(n)$ , 图4中第一次迭代时  $\hat{\beta}_0^{(0)} = x(n)$ , 下一次迭代的输入  $\hat{\beta}_0^{(J)}$  为上一次迭代重构的去噪PQD信号, 经过  $u$  次迭代输出最终的去噪电能质量扰动信号  $x'(n) = \hat{\beta}_0^{(u)}$ 。

第  $J$  次迭代过程中, 基于局部扰动信号采样点幅值之差的  $C_i^{(J)}$  为

$$C_i^{(J)} = \left[ \sum_{k=1}^R (x_i - x_{i-k}) + (x_i - x_{i+k}) \right]^2 \quad (9)$$

$$C_i^{(J)} = \frac{C_i^{(J)}}{\max\{C_i^{(J)}, i=1, 2, \dots, N\}} \quad (10)$$

式中:  $x_i$  表示  $n_i$  处的采样点幅值, 即  $x(n_i)$ ;  $R$  为局部分析窗宽度的一半;  $(x_{i-R}, \dots, x_{i+R})$  是以  $n_i$  为中心、 $2R$  为宽度的局部分析窗内采样点幅值。估计的  $C_i^{(J)}$  值在扰动突变点处较大, 而在其他非突变点处较小。

第  $J$  次迭代时, 自适应核函数  $K_{\text{adapt}}^{(J)}$  为

$$K_{\text{adapt}}^{(J)}(n_i - n, x_i - x) = \frac{1}{2\pi h^2 \mu_i^2} \exp\left\{-\frac{C_i^{(J)}(n_i - n)^2}{2h^2 \mu_i^2}\right\} \quad (11)$$

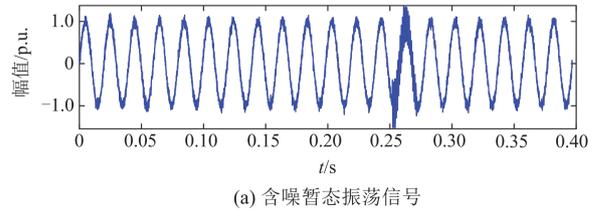
式中:  $x$  表示任意点  $n$  处的幅值;  $h$  为全局平滑参数;  $\mu_i$  为局部密度参数。为保护扰动细节特征,  $\mu_i$  在扰

动突变点或潜在突变点处取较小值以降低平滑度。 $\mu_i$  的详细计算过程可参考文献[26], 此处不再赘述。建立式(12)所示的最优化问题。

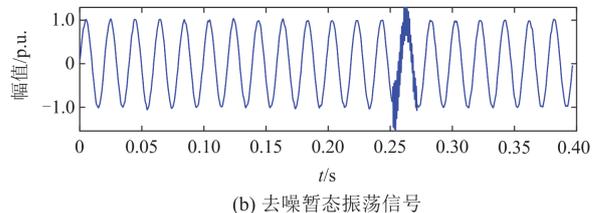
$$\min_{\{\beta_n^{(J)}\}} \sum_{i=1}^P \left[ x_i - \beta_0^{(J)} - \beta_1^{(J)}(n_i - n) - \beta_2^{(J)}(n_i - n)^2 \right]^2 \times K_{\text{adapt}}^{(J)}(n_i - n, x_i - x) \quad (12)$$

式中:  $P$  为回归核内采样点数目;  $\hat{\beta}_1^{(J)}$  和  $\hat{\beta}_2^{(J)}$  分别为一阶和二阶偏导数。通过最小二乘法求解式(12)所示的优化问题, 可得到去噪电能质量扰动信号  $\hat{\beta}_0^{(J)}$ , 详细的求解过程可参考文献[26]。

以一例含噪暂态振荡信号为例, 其信噪比为 20 dB, 得到的改进迭代自适应核回归去噪结果如图5所示, 算法具体参数设置参考文献[26]。从图5可以看出, 即使在强噪声干扰环境下, 去噪信号不仅具有较好的平滑效果, 而且较好地保护了振荡的特征。



(a) 含噪暂态振荡信号



(b) 去噪暂态振荡信号

图5 改进迭代自适应核回归的暂态振荡去噪结果

Fig. 5 Denoising result of transient oscillation using IIKR

## 4 基于二维CNN的改进轨迹圆混合电能质量扰动分类方法

无论是新型还是混合电能质量扰动, 直接通过其时域信号往往都难以准确辨识, 文献[3]提出一种可视化轨迹圆方法, 利用该方法提取的二维轨迹圆图像使不同扰动类型具有不同形状特征, 能与图像识别的深度学习相结合获得较好的分类效果, 但该方法也存在一定不足: 当暂降、中断等扰动突变幅值较大时, 提取的扰动幅值包络曲线在扰动起止时刻附近会存在异常突变, 类似假性脉冲扰动特征, 而受基频偏移影响时, 提取的扰动幅值包络曲线又存在边界问题, 导致形成的轨迹圆不能真实和准确地反映扰动形状特征, 进而影响扰动识别的准确率。

为了更加准确地表征扰动的形状特征, 有效地

识别混合扰动, 本文在弥补原可视化轨迹圆方法(VTC)不足的基础上提出了改进的可视化轨迹圆方法(IVTC), 并与基于 AlexNet 框架的二维 CNN 网络相结合。该方法通过将改进轨迹圆图像作为输入, 利用 CNN 自动提取其内在特征并进行分类, 具有较高的扰动识别准确性和稳定性。

#### 4.1 改进可视化轨迹圆方法

##### 1) VTC 方法的基本原理

对采样信号  $x(t)$  作 Hilbert 变换, 即

$$H(x(t)) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (13)$$

并构造采样信号  $x(t)$  的解析信号  $z(t)$ , 即

$$z(t) = x(t) + jH(x(t)) = l(t)e^{j\phi(t)} \quad (14)$$

式中:  $l(t)$  为瞬时幅值函数;  $\phi(t)$  为瞬时相位函数。其表达式如式(15)所示。

$$\begin{cases} l(t) = |x(t) + jH(x(t))| \\ \phi(t) = \arctan \frac{H(x(t))}{x(t)} \end{cases} \quad (15)$$

$l(t)$  可较好地表征扰动信号  $x(t)$  的局部特征, 即反映  $x(t)$  的幅值随时间和频率变化的规律。离散化  $l(t)$  得到  $x(t)$  的 Hilbert 变换包络幅值序列  $l(n)$ , 并以瞬时幅值  $l(n)$  为极径、瞬时相位对应极角, 如式(16)所示, 可方便地绘制出可视化轨迹圆图像<sup>[3]</sup>。

$$\begin{cases} R' = l(n) \\ \theta = \frac{n\pi}{32}, n = 0, 1, 2, \dots, N \end{cases} \quad (16)$$

式中:  $R'$  表示极径;  $\theta$  表示极坐标极角。

##### 2) IVTC 方法的原理

利用原算法式(13)一式(16)求得扰动数据  $x'(n)$  的 Hilbert 变换包络幅值序列  $l(n)$ , 在此基础上本文提出如下优化处理方案。

**Step1:** 为抑制包络幅值曲线  $l(n)$  两端受基频偏移影响产生的边界问题, 截掉其两端 1/4 周期的幅值包络曲线, 获得  $l(i), i = 1, 2, \dots, N_1$ , 其中  $N_1 = N - T/2$ 。

**Step2:** 判定扰动主频率点数 = 1 &  $\min(l) < 0.9 \text{ p.u.}$  &  $\max(l) > 1.05 \text{ p.u.}$ ? 若条件成立, 则进入 Step3; 若条件不成立, 则进入 Step6 直接以  $l(n)$  绘制可视化轨迹圆。

需要说明的是, 该条件成立表明可能存在暂降或中断等扰动, 而当暂降和中断的突变幅度较大时, 若直接以  $l(n)$  绘制可视化轨迹圆则不能真实和准确地反映暂降和中断扰动形状特征, 需通过 Step3 至 Step5 抑制虚假特征。

**Step3:** 构建滑动窗  $W_{\text{imp}}$ , 利用式(17)使  $W_{\text{imp}}$  在  $l(i)$  上滑动获取方差序列  $l_0$ 。

$$\begin{cases} l_0(i) = \delta(i) \\ l_0(i) = 0, l_0(i) < 0.1 \times \max(l_0) \end{cases} \quad (17)$$

式中:  $i = 1, 2, \dots, N_1$ ;  $\max$  表示取最大值;  $\delta(i)$  表示滑动到第  $i$  次时滑动窗  $W_{\text{imp}}(i)$  内元素的方差。滑动窗  $W_{\text{imp}}(i)$  内元素为

$$W_{\text{imp}}(i) = \begin{cases} \{l(1), l(2), \dots, l(p)\}, i \leq p \\ \{l(i-p/2), \dots, l(i), \dots, l(i+p/2)\}, p < i \leq N_1 - p \\ \{l(N_1 - p), \dots, l(N_1)\}, N_1 - p < i \leq N_1 \end{cases} \quad (18)$$

式中: 窗宽  $p$  一般取值范围为[8, 12]。

**Step4:** 求取  $l_0$  中所有满足式(19)所示的方差极大值对应的位置, 组成假性脉冲扰动特征的位置序列  $a(k)$ 。

$$\begin{cases} l_0(i-1) < l_0(i) > l_0(i+1) \& \\ \left( \frac{1}{2p} \sum_{j=1}^{2p} l(i-j) < 0.9 \text{ or } \frac{1}{2p} \sum_{j=1}^{2p} l(i+j) < 0.9 \right) \\ a(k) = i \end{cases} \quad (19)$$

式(19)中, 通过加入方差极大值处两侧  $2p$  长度幅值包络均值小于 0.9 的判定条件, 可消除对真实脉冲扰动特征的抑制。

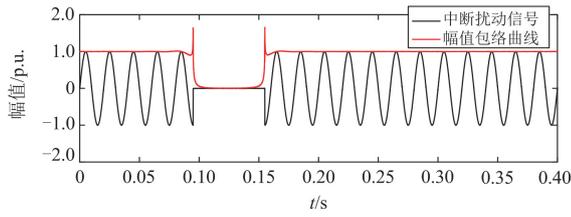
**Step5:** 利用式(20)消除幅值包络  $l(n)$  在  $a(k)$  处的假性扰动特征, 提高绘制轨迹圆的准确性。

$$\begin{cases} l(a(k)-j) = l(a(k)-2p-j) \\ l(a(k)+j) = l(a(k)+2p+j) \end{cases} \quad (20)$$

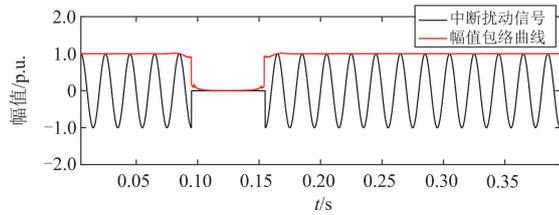
式中:  $j = 0, 1, \dots, p$ 。

**Step6:** 利用  $l(n)$  绘制可视化轨迹圆图像如图 6 所示。

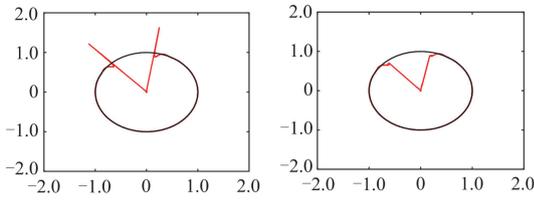
以一例电压中断为例, 利用 VTC 方法得到的幅值包络曲线和轨迹圆图像如图 6(a)和图 6(c)所示, 而利用本文 IVTC 方法得到的幅值包络曲线和轨迹圆图像如图 6(b)和图 6(d)所示。通过对比图 6(a)和图 6(b)、图 6(c)和图 6(d)可看出, 电压中断信号在扰动起止时刻处幅值突变较大, 利用 VTC 方法提取的幅值包络曲线在扰动起止时刻处有异常突变即假性脉冲扰动特征, 导致形成的轨迹圆也存在形状如脉冲扰动的异常突变特征, 不能真实体现中断扰动的特征, 而本文 IVTC 方法有效地消除了这种假性脉冲扰动特征, 提取的幅值包络曲线和轨迹圆更加真实和准确地体现了中断扰动的形状特征。



(a) 原算法电压中断幅值包络曲线



(b) 改进算法电压中断幅值包络曲线



(c) 原算法电压中断轨迹圆

(d) 改进算法电压中断轨迹圆

图6 算法改进前后的电压中断幅值包络及轨迹圆对比

Fig. 6 Comparison of amplitude envelope curve and trajectory circle of voltage interruption by using VTC and IVTC

## 4.2 CNN 基本原理

近几年深度学习算法在 PQD 识别领域的应用正在成为一个研究热点, 而深度学习方法中 CNN 具有处理各种维度数据的强大功能, 特别是在图像处理方面具有显著优势。因此本文采用 CNN 对输入的改进轨迹圆图像进行自主特征提取及扰动识别。

CNN 的结构由输入层、中间层(主要有卷积层、激活层、池化层及全连接层等)和输出层构成。在中间层中, 卷积层具有提取输入数据突出特征的关键作用; 池化层也是关键层, 可大幅减少网络参数量, 减少不明显的特征以进一步降低特征维度。在卷积层与池化层之间, 加入批量归一化层可以加快 CNN 的收敛速度并防止梯度消失或爆炸, 加入激活层可通过激活函数提高网络的非线性能力。全连接层在 CNN 中起到分类器的关键作用, 可对网络提取的特征进行整合与分类, 并将结果传递给输出层。若待分类的扰动类型有  $m$  种, 则可设置全连接层节点为  $m$ 。输出层通过 Softmax 函数对全连接层的输出进行归一化, 返回每个输入对应各类型的概率, 将输

入分配到其中一个互斥类并计算损失, 达到最终分类效果。

CNN 模型训练中, 采用收敛速度更快、学习效率更高的自适应时刻估计法 Adam 训练卷积层和全连接层中的权值, 通过误差反向传播对权值进行更新, 在误差反向传播的迭代过程中对核权值和偏差等可训练参数进行优化, 使损失函数最小化。另外, 设置合适的超参数也较为重要, 能起到提高 CNN 的收敛速度和识别精度的作用。

文中 CNN 的网络结构如附录 A 图 A3 所示, 各网络层参数及超参数的设置如表 1 所示。表 1 中,  $C$  表示通道数,  $W$  和  $H$  分别表示图像的长和宽。

表 1 CNN 模型结构参数及超参数

Table 1 Structural parameters and hyper-parameters of CNN

序号	层类型	函数	参数
1	输入层	—	$C \times W \times H$
2	一维卷积层 1	—	卷积核: $5 \times 5 \times 8$
3	批量归一化层	—	—
4	激活层 1	ReLU	—
5	最大池化层 1	—	池化核: $2 \times 2$ 步长: 2
6	一维卷积层 2	—	卷积核: $5 \times 5 \times 16$
7	批量归一化层	—	—
8	激活层 2	ReLU	—
9	最大池化层 2	—	池化核: $2 \times 2$ 步长: 2
10	一维卷积层 3	—	卷积核: $5 \times 5 \times 32$
11	批量归一化层	—	—
12	激活层 3	ReLU	—
13	全连接层	—	$1 \times k$ (扰动种类数)
14	输出层	Softmax	—
15	超参数	—	学习率: 0.001, Epoch: 150, 批大小: 300

## 5 验证与分析

为验证本文电能质量混合扰动检测与识别新方法的有效性, 通过 Matlab 从算法的 PQD 检测效果、IVTC 效果及分类效果几个方面进行了大量仿真及分析。仿真中, 基于文献[15]的扰动数学模型生成常见的单一及多种混合电能质量扰动信号, 信号采样频率为 10 kHz, 每周期采样点数为 200, 共 20 个周期。最后将本文方法用于电网实测扰动数据分析中, 进一步验证其有效性。

### 5.1 PQD 检测效果分析

考虑到实际 PQD 可能存在的噪声强度, 本文主要在 25~40 dB 噪声环境下验证所提扰动检测新方法的准确率及抗噪性。随机生成包含正常电压、单一及混合扰动在内的 20 种 PQD 信号, 其扰动类型的标签分别用 C0—C19 表示, 每一类扰动数据 500 组。利用本文扰动检测新方法分别对叠加 25 dB、

30 dB、35 dB、40 dB 噪声干扰的每一类 PQD 数据进行检测，结果如表 2 和表 3 所示。

表 2 不同信噪比条件下各类单一扰动检测率

Table 2 Detection rate of single PQDs under different SNRs

扰动类型	标签	不同信噪比条件下的检测率/%			
		25 dB	30 dB	40 dB	50 dB
正常信号	C0	100	100	100	100
电压暂降	C1	99.2	100	100	100
电压暂升	C2	99.4	99.8	100	100
电压中断	C3	100	100	100	100
暂态振荡	C4	99.6	100	100	100
电磁脉冲	C5	100	100	100	100
谐波	C6	100	100	100	100
闪变	C7	99.6	99.6	100	100

表 3 不同信噪比条件下各类混合扰动检测率

Table 3 Detection rate of combined PQDs under different SNRs

扰动类型	标签	不同信噪比条件下的检测率/%			
		25 dB	30 dB	40 dB	50 dB
中断 + 振荡	C8	100	100	100	100
暂降 + 振荡	C9	100	100	100	100
暂降 + 谐波	C10	100	100	100	100
暂降 + 脉冲	C11	100	100	100	100
暂升 + 振荡	C12	100	100	100	100
中断 + 谐波	C13	100	100	100	100
暂升 + 脉冲	C14	100	100	100	100
暂升 + 暂降	C15	100	100	100	100
暂升 + 谐波	C16	100	100	100	100
暂升 + 振荡 + 谐波	C17	100	100	100	100
暂降 + 振荡 + 谐波	C18	100	100	100	100
中断 + 振荡 + 谐波	C19	100	100	100	100

从表 2 和表 3 中可以看出，在信噪比为 25 dB 的低信噪比环境下，暂降、暂升、振荡暂态和闪变扰动的检测准确率分别为 99.2%、99.4%、99.6% 和 99.6%，而在信噪比为 30 dB 条件下暂升和闪变的检测准确率分别为 99.8% 和 99.6%，其余不同信噪比条件下各类单一及混合扰动的检测准确率均为 100%。因此表 2 和表 3 的结果表明本文所提的扰动检测新方法具有较强的抗噪性，对各类单一及混合扰动在不同噪声环境下具有较高的检测准确率；通过该方法能有效地检测扰动的存在，进而可实现电能质量扰动数据的快速和有效捕捉。

### 5.2 改进轨迹圆可视化效果分析

为了展示本文改进可视化轨迹圆方法提取扰动二维轨迹圆图像的效果，利用该方法对信噪比为 40 dB 的正常电压及 11 种扰动信号进行处理，得到

如图 7 所示的轨迹圆图像。

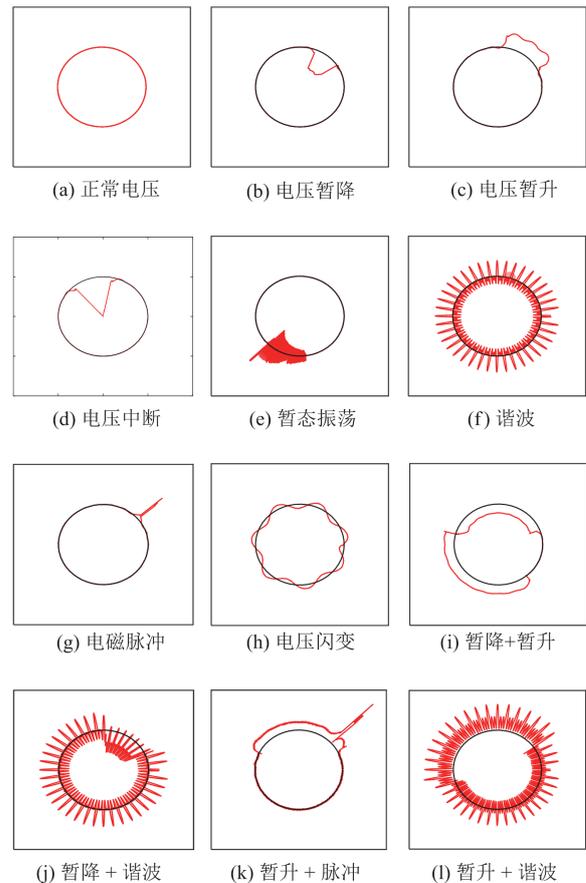


图 7 电能质量扰动改进可视化轨迹圆

Fig. 7 Improved visual trajectory circles of PQDs

从图 7 中可以看出，正常电压的轨迹圆是一个单位圆环；电压暂降的轨迹圆存在持续偏离单位圆的凹口，反映了电压幅值降低的特征；电压暂升的轨迹圆存在持续偏离单位圆的凸起，反映了电压幅值升高的特征；电压中断的轨迹圆存在持续指向圆心的深凹口，反映了中断扰动幅值过低的特征；暂态振荡的轨迹圆存在明显的局部振荡特征；电磁脉冲的轨迹圆存在明显的尖脉冲特征；电压闪变的轨迹圆围绕单位圆环呈现出幅值波动特征；谐波的轨迹圆呈现出独特的幅值畸变轨迹圆特征；混合扰动轨迹圆是各单一扰动轨迹圆特征的组合。因此，图 7 的结果表明，改进可视化轨迹圆方法将扰动信号从一维转换为二维轨迹圆，能更加清晰地显现不同类型扰动的独特特征信息，降低了扰动辨识难度。

在强噪声干扰环境下电能质量扰动信号受噪声污染较严重，部分扰动特征容易被噪声湮没。例如，一例信噪比为 20 dB 的暂降扰动的轨迹圆如图 8(a) 所示，由于强噪声干扰的影响，暂降轨迹圆的特征

不够明显, 可能会影响扰动识别的准确性。为了抑制强噪声干扰的影响, 本文引入改进迭代自适应核回归滤波方法对扰动信号进行滤波处理。图 8(b)~图 8(f)是信噪比为 20 dB、25 dB、30 dB、40 dB 和 50 dB 条件下暂降扰动去噪后提取的改进轨迹圆图像。对比图 8(a)和图 8(b)可以看出, 滤波后轨迹圆中强噪声干扰得到有效的抑制。图 8 的结果表明, 改进迭代自适应核回归滤波方法使不同噪声环境下提取的扰动轨迹圆更加平滑, 扰动特征更加清晰, 更有利于提高强噪声环境下扰动类型识别的准确度。

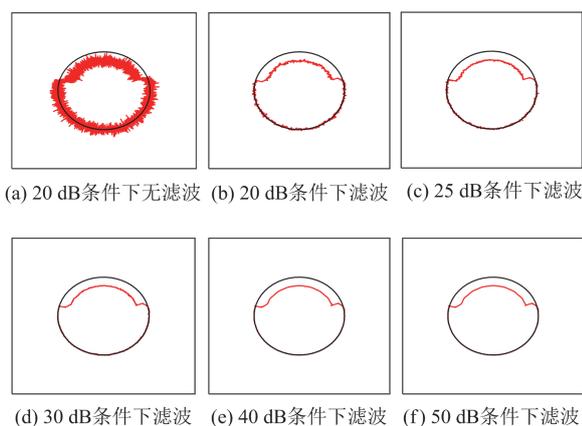


图 8 不同噪声环境下提取的暂降扰动可视化轨迹圆

Fig. 8 Improved visual trajectory circles of sag disturbance under different noisy conditions

### 5.3 电能质量扰动分类效果分析

为验证本文图 1 所示的 IIAKR+IVTC+CNN 识别方法的扰动分类效果, 在不同信噪比条件下对标签为 C0—C19 的 20 种电能质量扰动进行分类实验。

在信噪比为 20 dB、25 dB、30 dB、40 dB 和 50 dB 条件下, 20 种 PQD 信号随机产生总计 50 000 组数据。利用本文识别方法对所有生成的扰动数据进行处理, 提取 50 000 张轨迹圆图像, 组成深度学习数据库。为了降低神经网络输入数据量、训练复杂度并提高训练速度, 将 3 通道轨迹圆图像全部转化成单通道灰度图像。仿真中, 数据库样本按 70%:20%:10%的比例划分训练集、验证集和测试集; CNN 经过 2700 多次迭代训练后, 对测试集进行测试, 分类准确率如表 4 所示。

从表 4 可以看出, 本文方法对正常电压、单扰动、双重及三重混合扰动共计 20 种 PQD 信号, 在信噪比为 50 dB、40 dB 环境下识别的平均准确率能高达 100%, 而在 30 dB 环境下准确率虽有略微降低, 但仍在 99.96%以上, 即使在 25 dB 和 20 dB 等强噪声环境下, 其识别的平均准确率依然能稳定在 99.7%

以上。低信噪比环境下的扰动识别结果也表明 IIAKR 具有较好的滤波效果, 能有效滤除噪声干扰、保护扰动特征, 使本文识别方法在强噪声环境下也具有较高扰动识别准确率, 提升了识别算法的抗噪性。另外, 不同信噪比条件下 IIAKR+VTC+CNN 对各类扰动的平均识别率分别为 99.90%、99.87%、99.53%、98.87%和 98.58%, 均低于本文识别方法, 也表明本文 IVTC 方法提取轨迹圆图像更具有有效性。

表 4 不同噪声条件下各类扰动分类准确率

Table 4 Classification accuracy of various PQD signals under different noisy conditions

扰动类型	分类准确率/%				
	50 dB	40 dB	30 dB	25 dB	20 dB
C0	100	100	100	100	100
C1	100	100	100	100	99.36
C2	100	100	100	100	100
C3	100	100	100	100	100
C4	100	100	100	100	100
C5	100	100	100	100	100
C6	100	100	100	100	100
C7	100	100	100	100	100
C8	100	100	100	100	100
C9	100	100	100	100	100
C10	100	100	99.33	99.36	98.73
C11	100	100	100	98.73	100
C12	100	100	100	100	100
C13	100	100	100	100	100
C14	100	100	100	98.73	98.73
C15	100	100	100	100	100
C16	100	100	100	100	96.97
C17	100	100	98.99	98.99	100
C18	100	100	100	100	100
C19	100	100	100	100	100
本文识别方法的 平均准确率	100	100	99.96	99.78	99.71
IIAKR + VTC + CNN 方法的平均准确率	99.90	99.87	99.53	98.87	98.58

为进一步验证本文方法的扰动识别有效性, 将本文方法与文献[27]、文献[28]和文献[29]中方法的分类结果进行对比, 结果见表 5。

表 5 的结果表明, 相比于文献[27-29]中的这些方法, 本文方法具有较强的抗噪性, 不同信噪比下具有更高的扰动识别准确率。文献[27-29]中方法是基于传统特征提取和模式分类器的方法, 而本文方法是基于神经网络的深度学习算法, 具有高度的自适应性, 能自动提取和筛选多级特征, 弥补了传统模式分类方法中特征提取和筛选没有统一的方法指导、需要具有相关先验知识的人工参与等不足。

表 5 不同方法分类准确率比较

Table 5 Classification accuracy of different methods

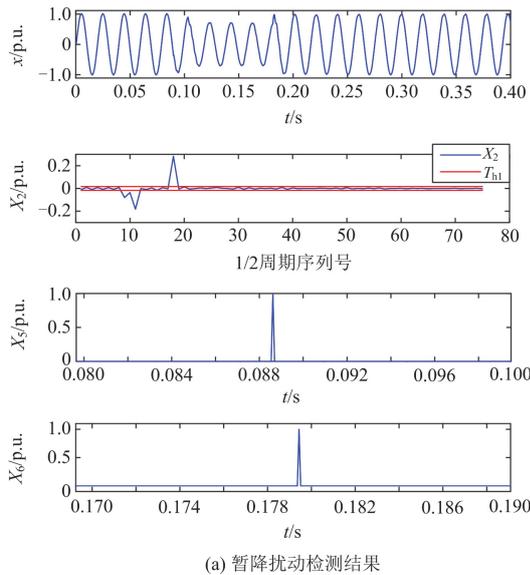
识别方法	总类别数	分类准确率/%	
		30 dB	20 dB
DWT + PNN <sup>[27]</sup>	16	98.6	95.2
FastICA + RF <sup>[28]</sup>	9	98.76	99.28
S-transform + Decision Tree <sup>[29]</sup>	16	99.69	99.08
本文方法	20	99.96	99.71

5.4 实测电能质量扰动案例分析

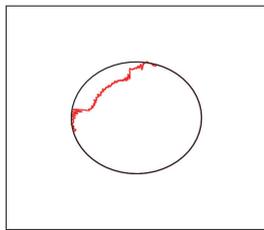
为验证本文方法的实用性，对电网实际采集的扰动数据进行分析。

1) 实测暂降的分析

图 9(a)中， $x$  为实测暂降扰动数据，利用本文扰动检测方法得到检测结果  $X_2$ 、 $X_5$  和  $X_6$ 。其中， $X_2$  存在 3 个超出阈值的系数，原因主要是电能质量信号在大约 0.08~0.1 s 期间幅值降低到 0.89 p.u.，约在 0.1~0.18 s 期间幅值又降低到 0.7 p.u.。由  $X_2$  中超出阈值的首尾系数的位置确定  $a=9$ 、 $b=18$ ，表明存在扰动。再根据  $a$  和  $b$  可确定扰动起始和结束时刻



(a) 暂降扰动检测结果



(b) 暂降的可视化轨迹圆

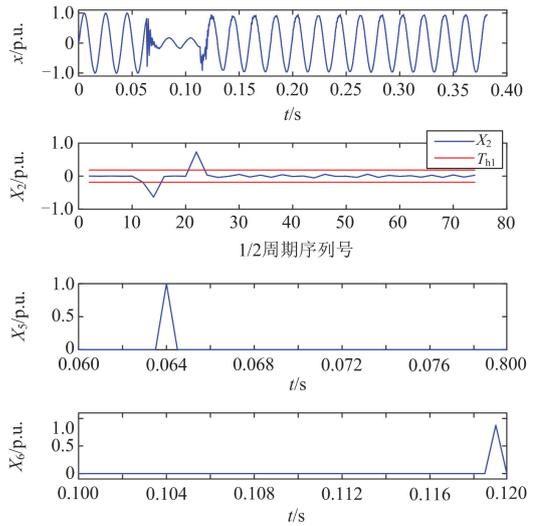
图 9 本文方法对实测暂降扰动数据的分析结果

Fig. 9 Analysis results of using the proposed method for actual sag disturbance

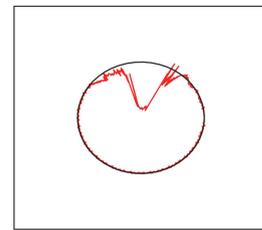
所在的两个时间区间，并在这两个时间区间内进行精确定位得到  $X_5$  和  $X_6$ 。 $X_5$  和  $X_6$  中的非零极值分别指示扰动起始时刻为 0.088 62 s，结束时刻为 0.1794 s，与实际暂降扰动的发生时刻吻合，达到了有效检测扰动的目的。该扰动数据经过 IIAKR 和 IVTC 方法处理，提取的可视化轨迹圆图像如图 9(b) 所示。该轨迹圆存在持续偏离单位圆的较大凹口，有效地表征了暂降扰动的特征，通过 CNN，其扰动类型被准确地识别为 C1。

2) 实测暂降 + 振荡的分析

图 10(a)中  $x$  为实测暂降 + 振荡数据，利用本文扰动检测方法得到检测结果  $X_2$ 、 $X_5$  和  $X_6$ 。根据  $X_5$  和  $X_6$  中非零极值，检测出扰动起始时刻为 0.064 s，结束时刻为 0.119 s，与该实测混合扰动的发生时刻吻合。该混合扰动数据经过 IIAKR 和 IVTC 处理，绘制出如图 10(b) 所示的可视化轨迹圆图像。该轨迹圆存在偏离单位圆的较大凹口，且在凹口两侧存在较为明显的振荡特征，其混合扰动的形状特征明显，通过 CNN，其扰动类型被准确地识别为 C9。



(a) 暂降+振荡检测结果



(b) 暂降 + 振荡的可视化轨迹圆

图 10 本文方法对实测暂降+振荡的分析结果

Fig. 10 Analysis results of using the proposed method for actual sag + oscillation

## 6 结论

本文提出了一种电能质量混合扰动检测与识别的新方法。通过仿真验证、算法对比分析及实测数据分析可以得出如下结论。

1) 本文提出的基于峰差引导局部差和累加的 PQD 检测新方法, 能快速、有效地检测各类单一及混合扰动, 具有较强的抗噪性和较高的检测准确率, 可用于 PQD 的快速捕捉。另外该方法还能较准确地定位暂态扰动的起止时刻。

2) 通过改进迭代自适应核回归方法, 扰动数据中的噪声干扰能被有效地滤除, 扰动细节特征也能被有效地保护, 进而可有效地提高强噪声干扰环境下扰动识别的准确率。

3) 原可视化轨迹圆方法提取的瞬时幅值包络在基频偏移条件下存在边界问题, 又在暂降、中断等扰动幅值突变较大处存在异常突变, 导致绘制的二维轨迹圆图像所表征扰动形状特征不够真实和准确, 会影响扰动识别的准确性。本文改进可视化轨迹圆方法较好地地弥补了原方法的不足, 使轨迹圆特征更加明显和准确。

4) 改进可视化轨迹圆结合 CNN 的方法, 有效地避免了传统模式分类方法对复杂混合扰动人工提取和筛选特征困难的问题, 可有效地自主提取扰动特征, 具有高度的自适应性和较好的分类效果。

下一步的研究工作是对本文方法做进一步的优化和调整, 以进一步提升其对复杂扰动检测和识别的种类以及准确率; 探讨本文扰动检测方法在实际低成本电能质量采集设备中的应用。

### 附录 A

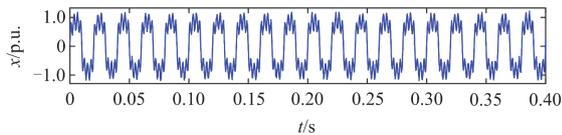


图 A1 本文扰动检测方法的谐波检测结果

Fig. A1 Detection results of harmonics by using the proposed new disturbance detection method

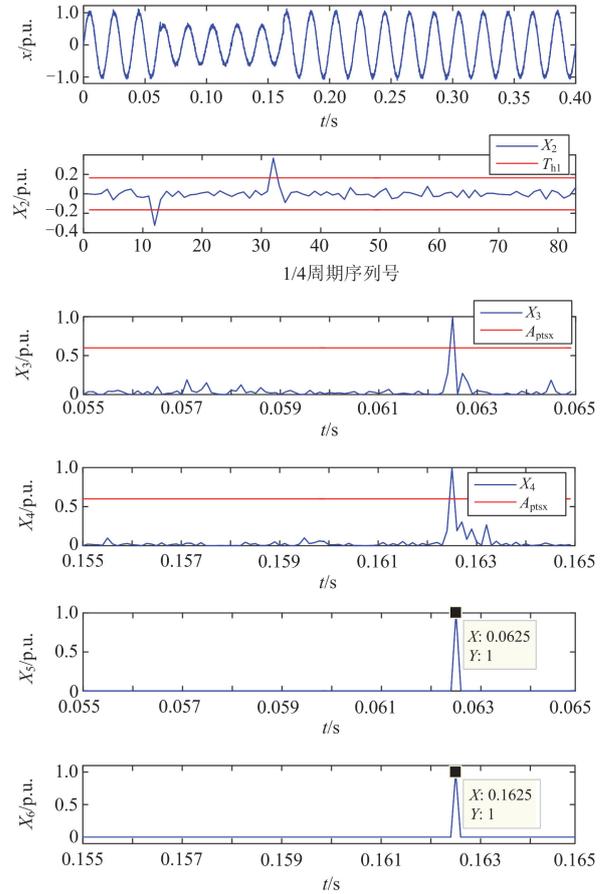


图 A2 本文扰动检测方法的暂降检测结果

Fig. A2 Detection results of voltage sag by using the proposed new disturbance detection method

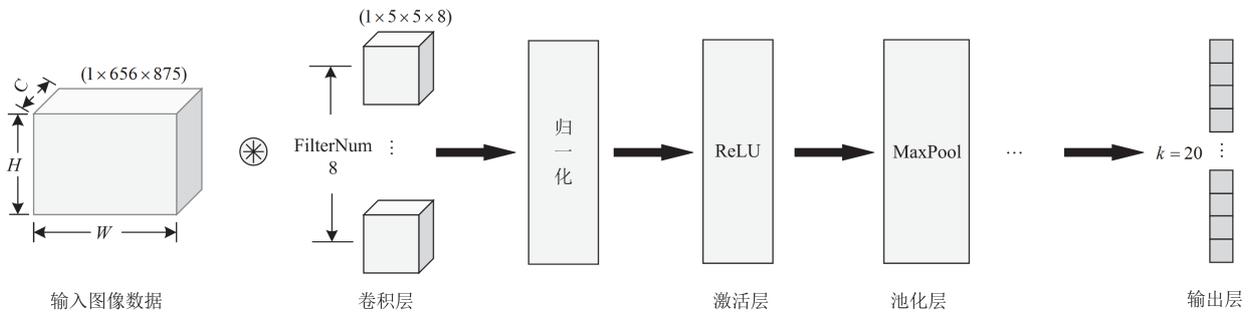


图 A3 CNN 结构

Fig. A3 CNN structure

## 参考文献

- [1] 黎博, 陈民铎, 钟海旺, 等. 高比例可再生能源新型电力系统长期规划综述[J]. 中国电机工程学报, 2023, 43(2): 555-581.  
LI Bo, CHEN Minyou, ZHONG Haiwang, et al. A review of long-term planning of new power systems with large share of renewable energy[J]. Proceedings of the CSEE, 2023, 43(2): 555-581.
- [2] LIU Y, JIN T, MOHAMED M A, et al. A novel three-step classification approach based on time-dependent spectral features for complex power quality disturbances[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-14.
- [3] 兰名扬, 刘宇龙, 金涛, 等. 基于可视化轨迹圆和 ResNet18 的复合电能质量扰动类型识别[J]. 中国电机工程学报, 2022, 42(17): 6274-6286.  
LAN Mingyang, LIU Yulong, JIN Tao, et al. An improved recognition method based on visual trajectory circle and ResNet18 for complex power quality disturbances[J]. Proceedings of the CSEE, 2022, 42(17): 6247-6286.
- [4] 李琦, 许素安, 施阁, 等. 基于 S 变换和 IWOA-SVM 的复合电能质量扰动识别[J]. 智慧电力, 2023, 51(5): 30-35, 50.  
LI Qi, XU Su'an, SHI Ge, et al. Identification of composite power quality disturbance based on S-transform and IWOA-SVM[J]. Smart Power, 2023, 51(5): 30-35, 50.
- [5] 王燕. 电能质量扰动检测的研究综述[J]. 电力系统保护与控制, 2021, 49(13): 174-186.  
WANG Yan. Review of research development in power quality disturbance detection[J]. Power System Protection and Control, 2021, 49(13): 174-186.
- [6] 吴建章, 梅飞, 潘益, 等. 基于改进经验小波变换的电能质量扰动检测新方法[J]. 电力自动化设备, 2020, 40(6): 142-151.  
WU Jianfei, MEI Fei, PAN Yi, et al. A new power quality disturbance detection method based on improved empirical wavelet transform[J]. Electric Power Automation Equipment, 2020, 40(6): 142-151.
- [7] BAYATI N, BAGHAEE H R, A HAJIZADEH A, et al. EMD/HT-based local fault detection in DC microgrid clusters[J]. IET Smart Grid, 2022, 5(3): 177-188.
- [8] XU Yanchun, GAO Yongkang, LI Zhenhua, et al. Detection and classification of power quality disturbances in distribution networks based on VMD and DFA[J]. CSEE Journal of Power and Energy Systems, 2020, 6(1): 122-130.
- [9] 张博智, 张茹, 焦东翔, 等. 基于 VMD-SAST 的电能质量扰动分类识别方法[J]. 中国电力, 2024, 57(2): 34-40.  
ZHANG Bozhi, ZHANG Ru, JIAO Dongxiang, et al. Power quality disturbance identification method based on VMD-SAST[J]. Electric Power, 2024, 57(2): 34-40.
- [10] 徐艳春, 高永康, 李振兴, 等. 改进 LMD 算法在微电网电能质量扰动信号检测中的应用[J]. 电网技术, 2019, 43(1): 332-341.  
XU Yanchun, GAO Yongkang, LI Zhenxing, et al. Application of improved LMD algorithm in signal detection of power quality disturbance in microgrid[J]. Power System Technology, 2019, 43(1): 332-341.
- [11] 王燕, 李雨婕, 卞安吉, 等. 一种数据库查询的多标签混合电能质量扰动分类与识别新方法[J]. 中国电机工程学报, 2024, 44(15): 5886-5898.  
WANG Yan, LI Yujie, BIAN Anji, et al. A new multi-label database query method for combined power quality disturbances classification and recognition[J]. Proceedings of the CSEE, 2024, 44(15): 5886-5898.
- [12] 商立群, 李朝彪, 邓力文, 等. 基于 ISSA-XGBoost 的电能质量扰动识别方法研究[J]. 电力系统保护与控制, 2024, 52(13): 115-124.  
SHANG Liqun, LI Chaobiao, DENG Liwen, et al. A power quality disturbance identification method based on ISSA-XGBoost[J]. Power System Protection and Control, 2024, 52(13): 115-124.
- [13] LI Shenghui, BAI Xue, DONG Henan. A power quality disturbance detection combined with adaptive threshold and multi-resolution SVD packets[C] // International Conference on Green Energy and Sustainable Development, May 30-31, 2019, Chongqing, China.
- [14] 李云峰, 高云鹏, 蔡星月, 等. 自适应辛几何模态分解和短时能量差分因子在电能质量扰动检测中的应用[J]. 电工技术学报, 2022, 37(17): 4390-4400.  
LI Yunfeng, GAO Yunpeng, CAI Xingyue, et al. Application of adaptive symplectic geometry modal decomposition and short-time energy difference factor in power quality disturbance detection[J]. Transactions of China Electrotechnical Society, 2022, 37(17): 4390-4400.
- [15] 卓金宝, 施伟锋, 兰莹, 等. 基于改进形态滤波器和弧长差分序列的微电网电能质量扰动定位与识别[J]. 电工技术学报, 2017, 32(17): 21-34.  
ZHUO Jinbao, SHI Weifeng, LAN Ying, et al. Location and recognition of micro-grid power quality disturbances based on modified morphological filter and arc length differential sequence[J]. Transactions of China Electrotechnical Society, 2017, 32(17): 21-34.
- [16] 王义国, 林峰, 李琦, 等. 基于 TCN-LSTM 模型的电网电能质量扰动分类研究[J]. 电力系统保护与控制, 2024, 52(17): 161-167.

- WANG Yiguo, LIN Feng, LI Qi, et al. Classification of power quality disturbances in a power grid based on the TCN-LSTM model[J]. *Power System Protection and Control*, 2024, 52(17): 161-167.
- [17] 贺才郡, 李开成, 董宇飞, 等. 基于知识蒸馏与 RP-MobileNetV3 的电能质量复合扰动识别[J]. *电力系统保护与控制*, 2023, 51(14): 75-84.
- HE Caijun, LI Kaicheng, DONG Yufei, et al. Power quality compound disturbance identification based on knowledge distillation and RP-MobileNetV3[J]. *Power System Protection and Control*, 2023, 51(14): 75-84.
- [18] NADERIAN S, SALEMNIA A. An implementation of S-transform and type-2 fuzzy kernel based support vector machine algorithm for power quality events classification[J]. *Journal of Intelligent & Fuzzy Systems*, 2019, 36(6): 5115-5124.
- [19] 盖勤. 基于深度学习的电能质量检测方法研究[D]. 北京: 北京交通大学, 2021.
- [20] YONG Gang, RU An, XIAO Fei, et al. Research on power quality disturbance recognition and classification technology in high noise background[J]. *IET Generation, Transmission & Distribution*, 2019, 13(9): 1661-1671.
- [21] 屈相帅, 段斌, 尹桥宣, 等. 基于稀疏自动编码器深度神经网络的电能质量扰动分类方法[J]. *电力自动化设备*, 2019, 39(5): 157-162.
- QU Xiangshuai, DUAN Bin, YIN Qiaoxuan, et al. Classification method of power quality disturbances based on deep neural network of sparse auto-encoder[J]. *Electric Power Automation Equipment*, 2019, 39(5): 157-162.
- [22] GARCIA C I, GRASSO F, LUCHETTA A, et al. A comparison of power quality disturbance detection and classification methods using CNN, LSTM and CNN-LSTM[J]. *Applied Sciences*, 2020, 10(19).
- [23] 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 a convolutional neural network[J]. *Power System Protection and Control*, 2021, 49(11): 97-104.
- [24] NARAYANASWAMI R, SUNDARESAN D, PREMA V R. The mystery curve: a signal processing based power quality disturbance detection[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(10): 10078-10086.
- [25] 黄南天, 赵文广, 蔡国伟, 等. 计及物联网数据传输速率约束的 LightGBM 电能质量扰动高效识别[J]. *中国电机工程学报*, 2021, 41(15): 5189-5201.
- HUANG Nantian, ZHAO Wenguang, CAI Guowei, et al. Efficient recognition of power quality disturbance of LightGBM considering data transmission rate constraints of IoT[J]. *Proceedings of the CSEE*, 2021, 41(15): 5189-5201.
- [26] WANG Yan, LI Qunzhan, ZHOU Fulin. Transient power quality disturbance denoising and detection based on improved iterative adaptive kernel regression[J]. *Journal of Modern Power Systems and Clean Energy*, 2019, 7: 644-657.
- [27] KHOKHAR S, ZIN A A M, MEMON A P, et al. A new optimal feature selection algorithm for classification of power quality disturbances using discrete wavelet transform and probabilistic neural network[J]. *Measurement*, 2017, 95: 246-259.
- [28] LIU Jun, SONG Hang, SUN Huiwen et al. High-precision identification of power quality disturbances under strong noise environment based on fastICA and random forest[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(1): 377-387.
- [29] ZHONG Tie, ZHANG Shuo, CAI Guowei, et al. Power quality disturbance recognition based on multiresolution S-transform and decision tree[J]. *IEEE Access*, 2019, 7: 88380-88392.

收稿日期: 2024-06-24

作者简介:

王 燕(1985—), 女, 工学博士, 讲师, 硕士生导师, 主要从事电能质量分析与控制、光伏发电系统及并网、无线电能传输技术、电力图像处理等方面的研究工作; E-mail: yanyanjtdx@126.com

曹浩敏(1997—), 男, 通信作者, 工学硕士, 研究方向为电能质量分析。E-mail: 761224641@qq.com

(编辑 魏小丽)