

DOI: 10.7667/PSPC171080

基于相空间重构和卷积神经网络的电能质量扰动分类

陈伟, 何家欢, 裴喜平

(兰州理工大学电气工程与信息工程学院, 甘肃 兰州 730050)

摘要: 为了提高电能质量扰动信号分类的准确率, 首先利用相空间重构将一维时间序列电能质量扰动信号重构到多维相空间, 获得扰动信号轨迹并投影到二维相平面, 形成二维轨迹图像。然后对该图像进行二值化处理, 减少信号的数据量, 凸显轨迹轮廓。最后通过卷积神经网络对处理后的轨迹图像进行特征提取, 并对相应的扰动信号进行分类识别。在卷积神经网络框架 Caffe 下进行仿真实验, 仿真结果表明该方法具有很高的识别准确率和良好的抗噪能力。

关键词: 电能质量; 扰动分类; 相空间重构; 深度学习; 卷积神经网络

Classification for power quality disturbance based on phase-space reconstruction and convolution neural network

CHEN Wei, HE Jiahuan, PEI Xiping

(School of Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: In order to improve the accuracy of the power quality disturbance signals classification, firstly, the one-dimensional time series power quality disturbance signals are reconstructed into the multidimensional phase space by phase-space reconstruction theory, thereby obtaining the disturbance signals trajectory and projecting to the two-dimensional plane, and forming a two-dimensional images. Then these images are binarized to reduce the amount of data of the signal and highlight the trajectory profile. Finally, the convolution neural network is used to extract the features of trajectory images and achieve the classification and identification of the corresponding disturbance signals. Simulation experiments are carried out under the Caffe framework of convolution neural network, showing that the method has high recognition accuracy and good ability to resist noise.

This work is supported by National Natural Science Foundation of China (No. 51767017 and No. 51267012).

Key words: power quality; disturbance classification; phase-space reconstruction; deep learning; convolution neural network

0 引言

随着电力电子设备的大量使用, 系统中电能质量问题日益突出, 引起了电力部门和广大电力用户的广泛关注。为了改善电能质量, 需要首先对电能质量扰动信号进行准确快速的识别与分类。

目前国内外学者对电能质量扰动的研究大多采用不同特征提取方法与分类器相结合的手段解决扰动识别和分类问题。特征提取方法主要有: 快速傅里叶变换(FFT)^[1]、小波变换^[2]、S变换^[3]、希尔伯

特黄变换(HHT)^[4]、数学形态学^[5]、瞬时无功理论^[6]、原子分解法^[7]等。目前所用的分类器主要有: 人工神经网络^[2]、支持向量机^[8]、模糊分类^[9-10]、决策树^[11]等。文献[12]采用粒子群优化算法结合概率神经网络实现了6种单一电能质量扰动信号的分类。但在实际电力系统中, 扰动信号大多以复合形式存在, 各种扰动之间特征量的交叉重叠导致特征提取困难。文献[13]采用快速傅里叶变换和S变换提取扰动特征, 采用决策树和支持向量机设计组合分类器进行扰动分类, 并通过仿真验证了该方法识别率高、抗噪能力强, 但是该方法分类器的分块化设计复杂, 并且考虑的复合扰动种类较少。文献[14]提出一种基于改进遗传算法的特征组合优化算法, 对

基金项目: 国家自然科学基金项目资助(51767017, 51267012), 甘肃省科技支撑工业计划项目资助(1504GKCA033)

原始特征进行筛选和优化组合,并验证了不同噪声情况下的分类效果,但该方法泛化能力和分类准确率有待进一步提高。文献[15]结合小波分析与 Prony 方法实现常见电能质量扰动信号的区分和辨识。首先分别对稳态扰动和暂态扰动进行分析,然后对混合扰动信号进行分析。该方法达到了较高的分类准确率,但所选扰动类型相对单一,且抗噪能力一般。总体上,现有的研究方法对扰动信号分类特征的选择没有统一标准,易产生冗余特征,导致分类准确率下降,并且泛化能力差,受噪声影响较大。

本文通过相空间重构获得扰动信号的轨迹图像,然后利用卷积神经网络对轨迹图像进行分类识别,并通过仿真实验验证了所提方法的有效性。

1 电能质量扰动信号的相空间重构

电能质量扰动信号的频率成分、电压幅值会在扰动产生的瞬间发生变化,多种类型的扰动信号相互混合导致时频域特征改变,扰动信号的信息量变大。将这种复杂的电能质量扰动信号看作混沌时间序列,利用相空间重构技术把该时间序列重构到高维相空间,得到的轨迹保留了原始时间序列的主要特征,并且可以充分显现扰动信号的隐藏信息^[16]。

1.1 基于坐标延迟法的相空间重构

对于时间序列 x_1, x_2, \dots, x_N 通过坐标延迟重构法引入一个时间延迟参数 τ 和一个嵌入维数 m , 构造一个 m 维的相空间。

$$\mathbf{X}_i = [x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}] \quad (1)$$

式中, $i=1, 2, \dots, L$, $L=N-(m-1)\tau$ 重构后得到的相空间轨迹矩阵为

$$\mathbf{X} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_L \end{bmatrix} = \begin{bmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(m-1)\tau} \\ x_2 & x_{2+\tau} & \cdots & x_{2+(m-1)\tau} \\ \vdots & \vdots & & \vdots \\ x_L & x_{L+\tau} & \cdots & x_{L+(m-1)\tau} \end{bmatrix} \quad (2)$$

式中:行向量 \mathbf{X}_i 组成多维相空间的相点; L 个相点共同构成重构相空间轨迹。

针对电能质量扰动信号采样序列分别计算 $x(n)$ 和 $x(n+\tau)$ 的信息熵,从而得到互信息函数 $I(x(n), x(n+\tau))$, 记为 $I(\tau)$, $I(\tau)$ 的极小值表示 $x(n)$ 和 $x(n+\tau)$ 最大可能不相关。根据 Fraser 和 Swinney 的建议,取 $I(\tau)$ 的第一个极小值点对应的的时间延迟点为最佳时间延迟 τ 。在采样频率为 5 000 Hz 的情况下, τ 取值为 60 进行重构。

根据塔肯斯(Takens)定理,为了保证相空间容纳状态空间原来吸引子的拓扑特征,该吸引子嵌入的

相空间维数必须达到原来吸引子所处空间维数的两倍再加上一维。原奇异吸引子的维数就是关联维数,采用 Grassberger-Procassis(G-P)关联维数法求得关联维数为 1,则电能质量扰动信号的最佳嵌入维数 $m=3$ 。嵌入维数的增加会增大计算复杂度,但嵌入维数的不足将导致不能完全显现信号的隐藏信息。

以电压中断信号(图1(a))为例,根据已经确定的参数,得到三维相空间轨迹如图 1(b)所示,由于本文进行扰动识别的对象是二维图像,因此需要将三维相空间轨迹在二维平面上进行投影,投影的结果如图 1(c)所示。投影到二维平面之后保留了原来三维相空间轨迹的基本形状和分类特征。

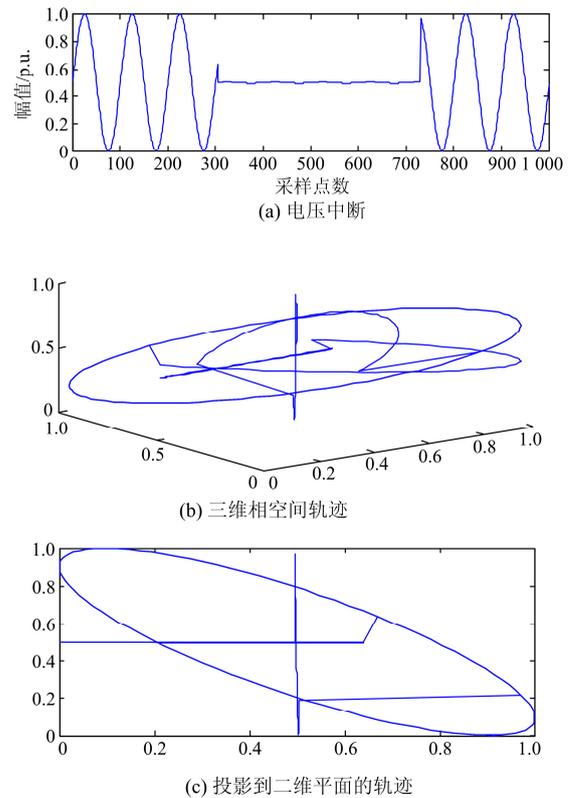


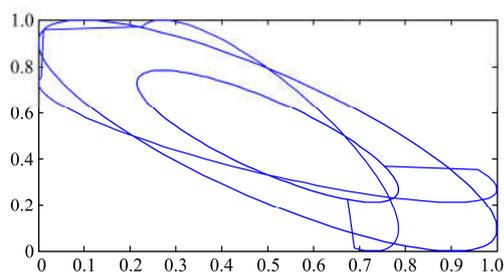
图 1 电压中断信号的相空间重构

Fig. 1 Phase space reconstruction of interruption signal

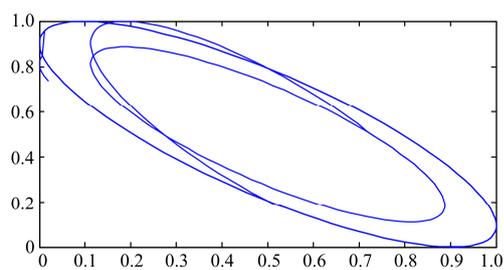
1.2 电能质量扰动信号的相空间重构轨迹图像

根据 IEEE Std 建立 7 种单一-电能质量扰动数学模型,分别为电压暂升(C0)、暂降(C1)、中断(C2)、谐波(C3)、暂态振荡(C4)、暂态脉冲(C5)和电压波动(C6)。基波频率 f_0 为 50 Hz,采样频率 f_s 为 5 000 Hz, T 为工频周期, $u(t)$ 为单位阶跃函数。根据电网实际情况,考虑 13 次以下的谐波,暂态振荡的频率取值为 800~1 800 Hz。在此基础上进一步生成复合电能质量扰动信号,复合扰动的组合形式有:谐波与

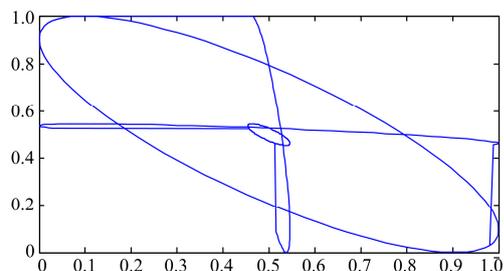
各种暂态扰动的复合、两种暂态扰动的复合、各种稳态扰动的复合等。根据扰动组合的规律, 本文所选取的复合扰动如下: 谐波+脉冲(C7)、谐波+振荡(C8)、谐波+波动(C9)、暂降+脉冲(C10)、暂降+振荡(C11)、谐波+暂降+脉冲(C12)、谐波+暂降+振荡(C13)。时间延迟点数 τ 取值 60, 嵌入维数 m 取值 3, 对 14 种电能质量扰动信号进行相空间重构, 投影得到部分二维轨迹图像如图 2 所示, 对每一幅轨迹图像进行二值化处理, 并除去坐标轴, 只保留轨迹轮廓, 图像的分辨率设为 256×256 , 批量生成各种扰动信号的样本轨迹图如图 3 所示, 将此类图像作为卷积神经网络的输入, 通过有监督的训练实现扰动信号的分类。



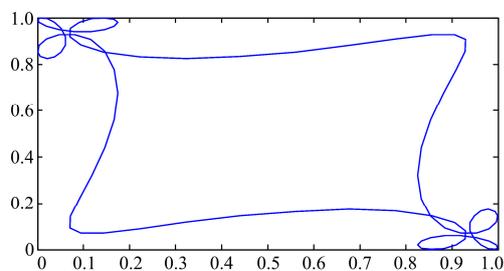
(a) 暂降



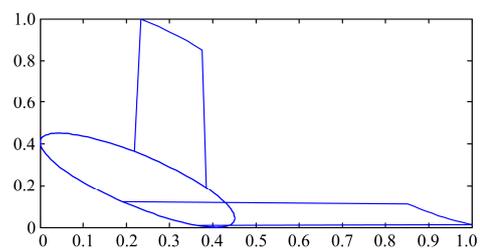
(b) 暂升



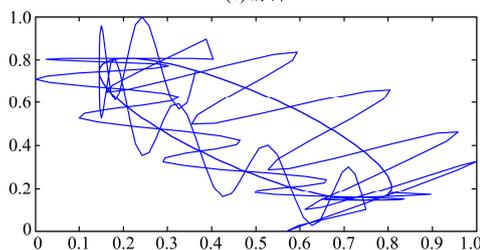
(c) 中断



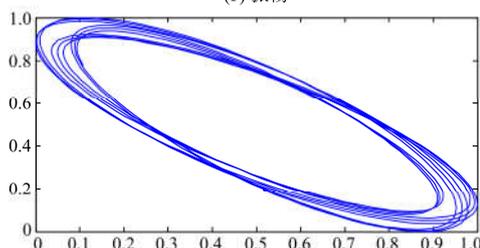
(d) 谐波



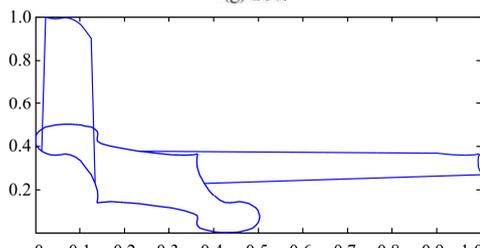
(e) 脉冲



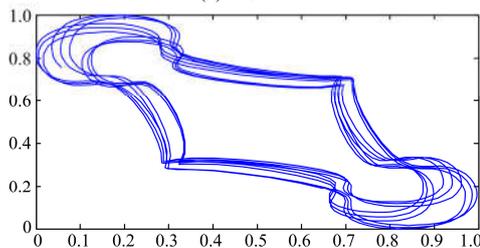
(f) 振荡



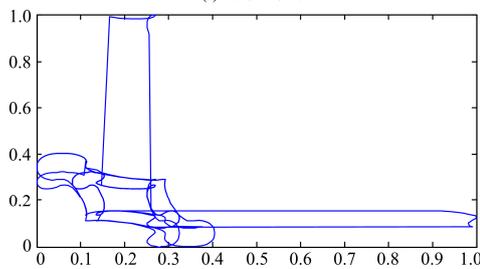
(g) 波动



(h) 谐波+脉冲



(i) 谐波+波动



(j) 谐波+暂降+脉冲

图 2 部分扰动信号重构轨迹图

Fig. 2 Partial reconstructed trajectory map of disturbance signals

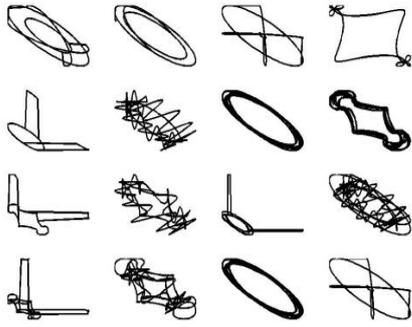


图3 电能质量扰动轨迹图样本

Fig. 3 Trajectory map samples of power quality disturbance

2 卷积神经网络(Convolutional Neural Network, CNN)

卷积神经网络作为一种深度学习的方法，已经成为模式分类领域的研究热点。CNN的权值共享机制更类似于生物神经网络，降低了网络模型复杂度，减少了权值数量^[17]。该网络避免了对图像的复杂前期预处理，可以直接输入原始图像，因而得到了更为广泛的应用。CNN的网络结构包含卷积层、下采样层和全连接层，网络的训练算法是反向传播算法。

2.1 CNN 网络结构

CNN网络结构如图4所示，前几个阶段需要通过多层卷积来提取图像特征，卷积层—激励层—池化层组成一个基本处理栈，堆叠多个基本处理栈就可以实现多层卷积，然后连接到全连接层，最后连接到Softmax层实现分类任务。

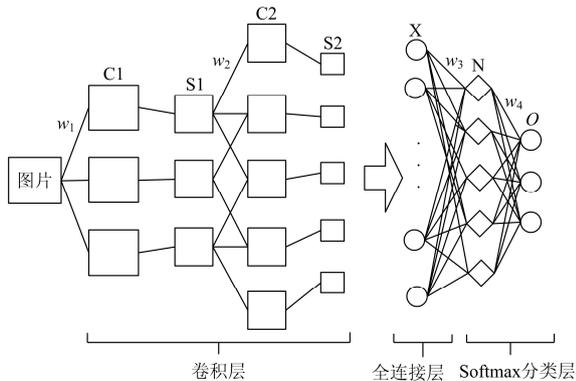


图4 CNN 分类网络结构图

Fig. 4 Structure chart of CNN classification network

图像不同窗口的数据和滤波器 filter 做内积实现卷积操作，滤波器 filter 可以看作是一个带着一组固定权重的神经元，多个滤波器叠加便形成了卷积层。激励层通过一种非饱和激活函数 ReLU (Rectified Linear Unite)实现将来自前一层的输入线性组合结果动态范围压缩到特定值域 $[0, +\infty]$ 。根据

图像的“静态性”属性，通过池化层将卷积计算得到的特征图进行聚合统计(如计算特定图像区域的最大值)，这些概要统计特征不仅具有低得多的维度(相比使用所有提取到的特征)，同时还会改善结果(不容易过拟合)。全连接层将二维网络特征图变换为一维向量作为网络输入，其输出通过对输入加权求和并通过激活函数的响应得到，输出数据送入Softmax 分类层，并结合图片样本的标签实现整个网络的训练。

2.2 CNN 学习算法

训练 CNN 包括两个阶段：前向传播计算(Forward)和反向传播计算(Backward)。前向传播阶段输入信号经过若干层的信号传递，在输出层得到输出。从输入数据集取样本 (X, Y) ，其中 X 为数据， Y 为标签。将 X 送入网络，逐层计算得到网络输出 O ，网络计算可表示为

$$O = F_n(\dots(F_2(F_1(XW_1)W_2)\dots)W_n) \quad (3)$$

式中： $F_i(i=1,2,\dots,n)$ 表示非线性变换；而 $W_i(i=1,2,\dots,n)$ 表示各个权值层权值。得到网络输出 O 后，用 (Y, O) 评估网络质量，理想网络满足 $Y = O$ 。

前向传播得到逐层的输出，将最后一层与目标函数比较得到损失函数，计算网络误差更新值，通过反向传播路径逐层到达第一层，并更新所有网络的权值。损失层是 CNN 的终点，接受两组数据，一是 CNN 的预测值，二是真实标签。通过对损失层的一系列计算得到网络损失函数(Loss Function)记为 $L(\theta)$ ，其中 θ 表示网络权值构成的向量空间。卷积神经网络学习的目的就是在权值空间中找到让损失函数 $L(\theta)$ 最小的权值 θ_{opt} 。本文通过Softmax层实现Softmax+交叉熵损失函数计算。设有 K 个类别，Softmax 计算过程为

$$\text{Soft max}(a_i) = \frac{\exp(a_i)}{\sum \exp(a_j)}, \quad i = 1, 2, \dots, K - 1 \quad (4)$$

Softmax 的输出结果可以看作是输入图像被分到每个标签的概率。

对 Softmax 的结果计算交叉熵分类损失函数为

$$L(\theta) = -\frac{1}{N} \sum_i \log[\text{Soft max}(a_k)] \quad (5)$$

式中： $i = 0, 1, 2, \dots, N - 1$ ； k 为真实标签值； N 为一个批量的大小。

3 基于Caffe深度学习框架的电能质量扰动分类模型

3.1 分类模型构建

根据自建数据样本集的特点构建一个卷积网络

模型 Net_256, 如图 5 所示。本文所选的电能质量扰动轨迹图像结构简单、轮廓清晰, 但扰动类型较多, 且单一扰动和混合扰动较为相似, 容易混淆。综合考虑, Net_256 设置 3 个卷积层和 3 个下采样层, 3 个全连接层和 1 个分类层。各个卷积层的卷积核以及下采样层的采样区域的大小如图 5 所示, 全连接层 N1 的输入是将 S3 层的二维输出特征映射图逐个展开为一维向量, 则 N1 的输入神经元个数为 $4 \times 4 \times 128 = 2048$, 输出神经元个数设为 1024, 激活函数选择 Relu 函数, 全连接层 N2 的输出神经元个数设置为 512, 全连接层 C3 的输出神经元个数设为 64。最后一层为 Softmax 分类层, 节点数根据实际任务选择, 本文一共有 14 种类型的电能质量扰动信号, 故将分类层的神经元节点设置为 14。

3.2 网络的最优化求解

Net_256 网络首先经过数据前向传播和误差反向传播, 初步得到一个卷积神经网络模型, 然后经过 Caffe 的求解器(Solver)进行网络模型的优化, Solver 要解决的关键问题是最小化损失函数的全局

优化, 对于数据集 N , 优化目标的损失函数平均值为

$$L(W) = \frac{1}{N} \sum_i f_w(X^{(i)}) + \lambda r(W) \quad (6)$$

式中: $f_w(X^{(i)})$ 为样本数据 $X^{(i)}$ 的损失函数; $r(W)$ 为正则项; λ 为正则项的权重。通过前向传播计算损失函数 f_w , 反向传播计算梯度 ∇f_w , 由误差梯度 ∇f_w 和正则项梯度 $\nabla r(W)$ 求得权值增量 ΔW , 再通过随机梯度算法(Stochastic Gradient Descent, SGD)更新权值 W 。权值更新的规则如下:

已知第 t 次迭代的权重更新历史 V_t 和权值 W_t , 其中, V_t 是权值更新历史。则第 $t+1$ 次迭代的 V_{t+1} 和 W_{t+1} 分别为

$$\begin{cases} V_{t+1} = \mu V_t - \alpha \nabla L(W_t) \\ W_{t+1} = W_t + V_{t+1} \end{cases} \quad (7)$$

式中: $\nabla L(W_t)$ 是损失函数平均值 $L(W_t)$ 的负梯度; α 是负梯度的权重, 即学习速率(Learning Rate, LR); μ 是 V_t 的权重, 即遗忘因子(Momentum); 超参数 α 和 μ 的调节是整个网络学习最优化的关键。

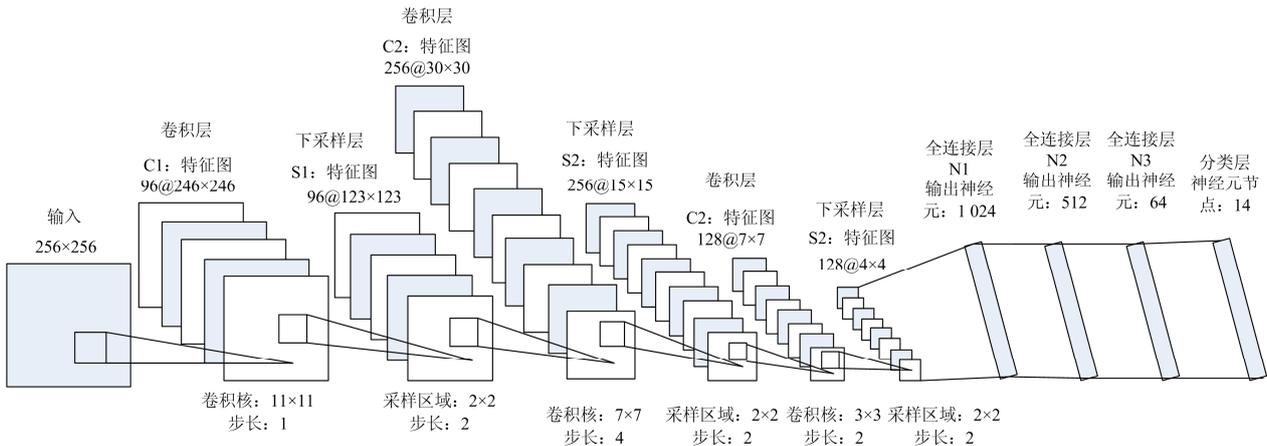


图 5 卷积神经网络 Net_256 结构

Fig. 5 Structure of CNN Net_256

4 仿真分析

以 Caffe 现有的模型 Alex_net 为基础进行网络层数和参数的修改, 搭建出图 5 所示的电能质量扰动分类模型 Net_256。通过 Matlab2014 分别生成信噪比为 40 dB 和 20 dB 的 14 类电能质量扰动信号, 每类 1000 个, 再通过相空间重构将扰动信号转化为图 3 所示的轨迹图像。对每个扰动类型的轨迹图像随机选取其中 600 个作为训练样本, 完成卷积神经网络模型的训练, 剩下的 400 个作为测试样本, 用来验证和评估网络性能。运行搭建好的 Net_256 卷积神经网络, 开始网络训练和同步测试。

为了评估网络的训练状态和训练效果, 绘制出损失函数以及分类正确率随着训练过程(迭代次数 iters)不断变化的曲线, 即训练损失曲线(Train loss)、测试损失曲线(Test loss)和分类精度曲线(Test Accuracy)。提取 Net_256 网络训练日志的损失函数和分类准确率信息, 损失函数曲线如图 6 和图 7 所示, 分类准确率曲线如图 8 所示。从图 6 和图 7 可以看出, 训练损失和测试损失都在不断下降, 训练过程中网络在不断地学习, 损失函数曲线在下降过程中波动较大, 但随着迭代次数的增加逐渐趋于稳定。测试损失曲线非常平稳, 不断下降并收敛于较小的数值, 说明整个网络模型训练在不断优化完善,

网络稳定性在不断增加。图 8 显示分类精度由一个很低的随机初始值通过训练不断升高为接近 1 的较高分类精度。通过对比信噪比为 20 dB 和 40 dB 的扰动信号分类效果可知, 随机噪声的增强使得在网络全局最优化过程中损失函数的极小值有所增大, 但网络仍保持了较高的分类精度, 分类准确率仅下降了两个百分点, 表明该方法具有一定的抗噪能力, 适用于不同噪声环境的扰动分类需求。

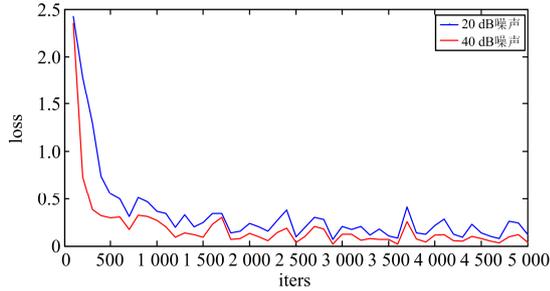


图 6 训练损失函数曲线

Fig. 6 Curve of training loss function

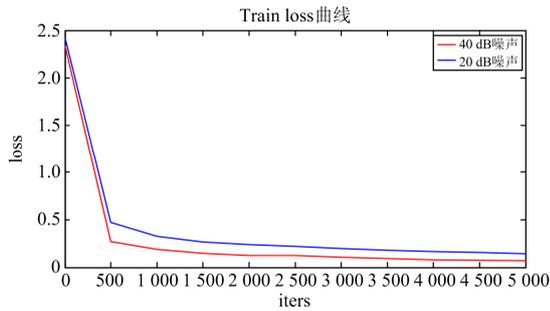


图 7 测试损失函数曲线

Fig. 7 Curve of test loss function

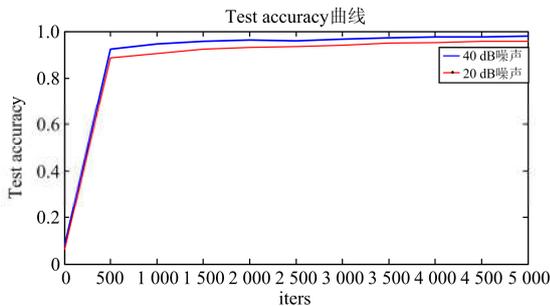


图 8 分类正确率曲线

Fig. 8 Curve of classification accuracy

信噪比为 40 dB 和 20 dB 的各类扰动信号的分类准确率如表 1 所示。从表 1 可以看出, 本文方法对单一扰动、二重扰动和三重扰动都具有较高的分类准确率, 适合复合扰动分类。综上所述, 本文所构建的 Net_256 网络分类性能良好, 抗噪能力强,

有效实现了电能质量复合扰动信号的准确分类。

表 1 各类扰动信号的分类准确率

Table 1 Classification accuracy of disturbance signals

扰动类型	分类准确率/%		
	40 dB	20 dB	
单一扰动	C0	98.2	96.2
	C1	98.8	95.8
	C2	100.0	100.0
	C3	100.0	100.0
	C4	96.5	95.7
	C5	97.2	96.3
二重扰动	C6	100.0	100.0
	C7	96.3	94.4
	C8	96.7	94.6
	C9	100.0	97.6
	C10	97.8	93.4
三重扰动	C11	97.4	94.7
	C12	96.5	92.1
C13	97.0	92.0	
平均值	98.03	95.91	

5 结论

本文通过相空间重构将电能质量扰动数据由一维信号转化为二维轨迹图像, 避免了对原始扰动信号的复杂特征提取。从图像处理的角度出发, 利用深度学习中的卷积神经网络学习扰动轨迹图像的特征, 实现了电能质量扰动数据的分类。仿真结果表明, 本文算法可以达到很高的分类准确率和较高的鲁棒性, 对于电力系统中随机性较强的扰动信号的识别具有一定的普遍适用性。未来课题组将通过 GPU 加速运算, 利用 GPU 的向量处理、矩阵运算和图形处理功能, 减少卷积神经网络训练时间, 从而提高扰动数据的识别效率。

参考文献

- [1] 黄建明, 瞿合祚, 李晓明. 基于短时傅里叶变换及其谱峭度的电能质量混合扰动分类[J]. 电网技术, 2016, 40(10): 3184-3191.
HUANG Jianming, QU Hezuo, LI Xiaoming. Classification for hybrid power quality disturbance based on STFT and its spectral kurtosis[J]. Power System Technology, 2016, 40(10): 3184-3191.
- [2] CHANDRASEKARP, KAMARAJV. Detection and classification of power quality disturbance waveform using MRA based modified wavelet transform and neural networks[J]. Journal of ElectricalEngineering, 2010, 61(4): 235-240.
- [3] GARG R, SINGH B, SHAHANI D, 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.
- [4] 李天云, 赵妍, 李楠, 等. 基于 HHT 的电能质量检测新方法[J]. 中国电机工程学报, 2005, 25(17): 52-56.
LI Tianyun, ZHAO Yan, LI Nan, et al. A new method for power quality detection based on HHT[J]. Proceedings of the CSEE, 2005, 25(17): 52-56.
- [5] 王丽霞, 何正友, 赵静. 基于数学形态学的电能质量扰动检测和定位[J]. 电网技术, 2008, 32(10): 63-68, 88.
WANG Lixia, HE Zhengyou, ZHAO Jing. Detection and location of power quality disturbance based on mathematical morphology[J]. Power System Technology, 2008, 32(10): 63-68, 88.
- [6] 魏磊, 张伏生, 耿中行, 等. 基于瞬时无功功率理论的电能质量扰动检测、定位与分类方法[J]. 电网技术, 2004, 28(6): 53-58.
WEI Lei, ZHANG Fusheng, GENG Zhongxing, et al. Detection and location and identification of power quality disturbance based on instantaneous reactive power theory[J]. Power System Technology, 2004, 28(6): 53-58.
- [7] 张磊, 黄纯, 江亚群, 等. 应用 HS 改进原子分解的电能质量扰动辨识分析[J]. 电网技术, 2015, 39(1): 194-200.
ZHANG Lei, HUANG Chun, JIANG Yaqun, et al. Identification analysis of power quality disturbances based on harmony search and atom decomposition[J]. Power System Technology, 2015, 39(1): 194-200.
- [8] YONGD D, BHOWMIKS, MAGNAGOF. An effective power quality classifier using wavelet transform and support vector machines[J]. Expert Systems with Applications, 2015, 15(1): 6075-6081.
- [9] DEGHANI, VAHIDIB, NAGHIZA DEHRA, et al. Power quality disturbance classification using a statistical and wavelet-based hidden Markov model with Dempster-Shafer algorithm[J]. International Journal of Electrical Power and Energy Systems, 2013, 47(5): 368-377.
- [10] RAHUL, KAPOOR R, TRIPATHI M M. Detection and classification of multiple power signal patterns with Volterra series and interval type-2 fuzzy logic system[J]. Protection and Control of Modern Power Systems, 2017, 2(2): 92-101. DOI: 10.1186/s41601-017-0039-z.
- [11] 瞿合祚, 刘恒, 李晓明, 等. 基于多标签随机森林的电能质量复合扰动分类方法[J]. 电力系统保护与控制, 2017, 45(11): 1-7.
QU Hezuo, LIU Heng, LI Xiaoming, et al. Recognition of multiple power quality disturbances using multi-label random forest[J]. Power System Protection and Control, 2017, 45(11): 1-7.
- [12] 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 disturbances classification based on generalized S-transform and PSO-PNN[J]. Power System Protection and Control, 2016, 44(15): 10-17.
- [13] 陈华丰, 张葛祥. 基于决策树和支持向量机的电能质量扰动识别[J]. 电网技术, 2013, 37(5): 1272-1277.
CHEN Huafeng, ZHANG Gexiang. Power quality disturbance identification using decision tree and support vector machine[J]. Power System Technology, 2013, 37(5): 1272-1277.
- [14] 瞿合祚, 刘恒, 李晓明, 等. 一种电能质量多扰动分类中特征组合优化方法[J]. 电力自动化设备, 2017, 37(3): 146-152.
QU Hezuo, LIU Heng, LI Xiaoming, et al. Feature combination optimization for multi-disturbance classification of power quality[J]. Electric Power Automation Equipment, 2017, 37(3): 146-152.
- [15] 任子晖, 刘昊岳, 徐进霞. 基于小波变换和改进 Prony 方法的电能质量扰动分析[J]. 电力系统保护与控制, 2016, 44(9): 122-128.
REN Zihui, LIU Haoyue, XU Jinxia. Power quality disturbance analysis based on wavelet transform and improved Prony method[J]. Power System Protection and Control, 2016, 44(9): 122-128.
- [16] 李智勇, 吴为麟, 林震宇. 基于相空间重构和支持向量机的电能扰动分类方法[J]. 电力系统自动化, 2007, 31(5): 70-75.
LI Zhiyong, WU Weilin, LIN Zhenyu. A power disturbance classification method based on phase space reconstruction and support vector machines[J]. Automation of Electric Power Systems, 2007, 31(5): 70-75.
- [17] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1300-1312.
CHANG Liang, DENG Xiaoming, ZHOU Mingquan, et al. Convolutional neural networks in image understanding[J]. Acta Automatica Sinica, 2016, 42(9): 1300-1312.

收稿日期: 2017-07-19; 修回日期: 2017-11-30

作者简介:

陈伟(1976—), 男, 博士, 教授, 博导, 主要研究方向为电能质量分析与控制; E-mail: chenlin@lut.cn

何家欢(1992—), 男, 通信作者, 硕士研究生, 研究方向为电能质量扰动信号检测分析; E-mail: yyjh2012@163.com

裴喜平(1980—), 男, 博士, 副研究员, 主要研究方向为电能质量分析与控制。

(编辑 许威)