

DOI: 10.19783/j.cnki.pspc.200997

基于 GAF 与卷积神经网络的电能质量扰动分类

郑炜, 林瑞金, 王俊, 李振嘉

(福州大学电气工程与自动化学院, 福建 福州 350108)

摘要: 针对在设计电能质量扰动(Power Quality Disturbance, PQD)分类器时人工选取特征过程繁琐并且不够精确的问题, 提出一种基于格拉姆角场(Gramian Angular Field, GAF)和卷积神经网络(Convolutional Neural Network, CNN)的 PQD 分类方法。首先将一维 PQD 信号映射为二维图像, 接着在已有的神经网络基础上构造适用于 PQD 分类的网络框架。最后将二维图像作为输入, CNN 将自动从海量的扰动样本中提取特征并加以分类。仿真结果表明该方法在噪声数据中具有良好的分类性能, 是一种行之有效的 PQD 分类方法。

关键词: 电能质量; 格拉姆角场; 卷积神经网络; 特征提取; 扰动分类

Power quality disturbance classification based on GAF and a convolutional neural network

ZHENG Wei, LIN Ruiquan, WANG Jun, LI Zhenjia

(College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China)

Abstract: Given that the manual feature selection process is cumbersome and not sufficiently accurate, a classification method of Power Quality Disturbance (PQD) based on a Gramian Angular Field (GAF) and a Convolutional Neural Network (CNN) is proposed when designing the power quality disturbance classifier. First, one-dimensional power quality disturbance signals are mapped to two-dimensional images. Then a network framework suitable for power quality disturbance classification is constructed based on the existing neural network. Finally, two-dimensional images are taken as input, and the CNN will automatically extract features from the massive disturbance samples and classify them. Simulation results show that this method has good classification performance in noisy data, and it is an effective power quality disturbance classification method.

This work is supported by the National Natural Science Foundation of China (No. 61871133).

Key words: power quality; Gramian angular field; convolutional neural network; feature extraction; disturbances classification

0 引言

随着多能源一体化系统的发展, 越来越多的可再生能源系统和联合优化能源系统接入电网^[1], 与传统电力系统相比, 在能源生产、转换和消费的不同阶段, 扰动产生的风险越来越高, 这样会对电力系统安全稳定运行造成严重影响^[2-3]。为了减小 PQD 造成的经济损失, 对其进行准确的识别是治理电能质量问题的基础。

在理想状态下, 电力系统中电压、电流的波形应该是标准的正弦或余弦函数, 但在实际的电网中, 由于受到外界扰动和电力系统内部噪声的影响, 电压和电流波形的光滑程度下降, 出现波形畸变^[4]。

对 PQD 进行检测和分类, 有助于系统分析 PQD 产生的原因并采取有效的措施进行治理^[5]。PQD 信号的检测和分类方法较多, 但大体分为两个步骤, 即扰动信号特征的提取以及依据特征向量对扰动信号进行分类。

扰动信号特征的提取是指对原始扰动信号进行加工处理, 以便获得能体现该扰动特性的低维度的特征向量, 而不过分丢失原始信号的扰动信息。现有的特征提取方法有傅里叶变换^[6]、小波变换、S 变换^[7]、希尔伯特黄变换^[8](Hilbert-Huang Transform, HHT)等。上述的这些分析方法都展现了各自的分析特点。如文献[9]提出了一种不需要倒叙的快速傅里叶变换算法, 在一定程度上提高了时间效率, 降低了算法的复杂性, 但所需的空间大了一倍。文献[10]利用小波的多分辨率分析的能力, 将扰动信号投影

基金项目: 国家自然科学基金项目资助(61871133)

到不同尺度上来提取信号特征。文献[11]提出了一种基于分段改进 S 变换和神经网络相结合的方法, 不仅兼顾时频特性而且提高了分类准确率, 但是多扰动特征提取的问题没有得到解决。文献[12]提出了一种基于 HHT 的 PQD 定位与分类的新方法, 利用 HHT 算法获得的 Hilbert 谱来对扰动进行定位, 但需要较复杂的运算。

而扰动分类的基本思路是将特征向量的提取作为基础, 与不同的分类方法相结合实现扰动信号的分类。目前比较常见的方法为: k 近邻^[13]、决策树^[14]、支持向量机^[15]、神经网络^[16]等。如文献[17]用了决策树和支持向量机相结合的分类器, 决策树分类过程中采用支持向量机来区分特定扰动, 简化了特征提取过程。文献[18]提出了一种基于特征融合的一维卷积方法, 但是对于电压暂降和中断的分类准确率较低, 并且存在网络层次复杂的问题。综上所述, 我们要根据扰动特征的不同, 选取合适的分类器, 在实时处理数据的基础上通过参数优化等手段来实现更高的分类准确率。

本文利用现有方法的特点, 提出了一种结合 GAF 和 CNN 的 PQD 分类新方法。首先充分利用机器视觉的优势, 发掘一维信号里的绝对时间关系, 采用 GAF 方法将扰动信号映射为二维图像, 然后建立了一种基于 CNN 的图像分类模型, 用于 PQD 识别。将深度学习应用于 PQD 分类的问题上, 不但可以提高分类的准确率, 而且可以节省人力, 简化分类过程。最后通过 16 种合成 PQD 信号以及 IEEE 电能质量数据分析工作组的实测数据, 对该方法的性能进行了测试。

1 基本原理描述

1.1 时间序列成像

首先介绍一下将一维信号序列编码为图像的方法^[19]。本文使用的方法为 GAF, 其特别之处是在极坐标系中表示扰动信号序列, 而不是在典型的笛卡尔坐标系中。具体过程如下:

给定一个一维扰动信号 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$, 其中时间序列由 n 个时间戳 t 和对应的实际观测值 x 组成, 使用最小-最大定标器将时间序列缩放到 $[-1, 1]$ 中, 公式如式(1)所示。

$$\tilde{x}_i = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (1)$$

之后将缩放后的序列 \tilde{x}_i 的值映射为角度 ϕ , 将时间映射为半径 r , 这样就可以在极坐标系中重新将缩放的时间序列表示出来, 公式式(2)所示。

$$\begin{cases} \phi = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, t_i \in N \end{cases} \quad (2)$$

式中, t_i 为时间戳, 将区间 $[0, 1]$ 分成 N 等份, 这样使得极坐标系的跨度正则化。式(2)的编码映射具有两个重要性质。首先, 它是双射的, 因为 $\cos(\phi)$ 在 $\phi \in [0, \pi]$ 时是单调递减的, 在给定一个时间序列的情况下, 在极坐标系中有唯一一个对应的值, 且其逆映射也具有唯一性。其次, 与笛卡尔坐标不同的是极坐标保持绝对的时间关系。

将一维信号映射到极坐标系后, 我们可以很容易地利用角度视角, 通过考虑每个点之间的三角函数和来识别不同时间间隔内的时间相关性。GAF 定义为

$$\mathbf{G} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cdots & \cos(\phi_2 + \phi_n) \\ \vdots & \vdots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} = \tilde{\mathbf{X}}' \cdot \tilde{\mathbf{X}} - \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2} \cdot \sqrt{\mathbf{I} - \tilde{\mathbf{X}}^2} \quad (3)$$

式中: \mathbf{I} 是单位行向量 $[1, 1, \dots, 1]$; $\phi_i (i = 1, L, n)$ 是两个向量的夹角。将一维时间序列映射到极坐标系后, 将每个步长的时间序列作为一维度量空间。因为 GAF 更加稀疏, 所以在笛卡尔坐标系中重新定义内积 $\langle x, y \rangle = x \cdot y - \sqrt{1 - x^2} \cdot \sqrt{1 - y^2}$, 相对于传统内积, 新定义的内积增加了一个惩罚项, 这样使得我们所需要的输出很容易与高斯噪声区分开来。G 是一个 Gram 矩阵, 定义如式(4)所示。

$$\mathbf{G} = \begin{bmatrix} \langle \tilde{x}_1, \tilde{x}_1 \rangle & \cdots & \langle \tilde{x}_1, \tilde{x}_n \rangle \\ \langle \tilde{x}_2, \tilde{x}_1 \rangle & \cdots & \langle \tilde{x}_2, \tilde{x}_n \rangle \\ \vdots & \ddots & \vdots \\ \langle \tilde{x}_n, \tilde{x}_1 \rangle & \cdots & \langle \tilde{x}_n, \tilde{x}_n \rangle \end{bmatrix} \quad (4)$$

GAF 包含时间相关性, 因为 $G_{(i, j) | i-j=k}$ 表示时间相关性是通过时间间隔 k 的方向所叠加, 并且用相对相关性来解释。当 $k=0$ 时, 主对角线 $G_{i,i}$ 由缩放后的时间序列的原始值构成。利用主对角线, 可以根据深度学习学习的高层特征来近似地重构时间序列。

1.2 卷积神经网络

通常, CNN 模型由卷积层、池化层、完全连接层等组成^[20]。

卷积运算可以提取出图像的隐藏特征, 加强原始信号的某些特征。卷积层通过滑动卷积核, 使之

与图片上的不同区域进行卷积, 然后通过激活单元产生输出特征, 由于用相同的核来提取特征, 因此具有权值共享的特性。计算过程如式(5)所示。

$$x_j^l = \sum_{i \in m} x_i^{l-1} \times k_{ij}^l + b_j^l \quad (5)$$

式中: l 表示层数; x_j^l 表示第 l 层的第 j 个神经元; m 表示上一层与当前层有连接的神经元个数; k 为权重值; b 为偏置。

池化层是一种降采样操作, 通常在卷积层之后要增加池化层。在卷积层提取特征之后, 使得特征维数增加, 使用池化层对数据进行缩放, 以降低数据的维数, 提取重要信息。池化层分为最大池化层和平均池化层, 基于 PQD 信号易受噪声的干扰, 本文首先采用最大池化:

$$x^l = \max(\sum_{i \in m} x_i^{l-1}) + b^l \quad (6)$$

全连接层通常在 CNN 的尾部, 与上层所有的节点相连接, 以集成从前层提取的特征, 并将输出值送给分类器, 完成输入图像到标签集的映射。由于其完全连接的性质, 全连接层的参数也是最多的, 全连接层表示如式(7)所示。

$$x_o^l = f(x_i^{l-1} \times D_{io}^l + b^l) \quad (7)$$

式中, D_{io}^l 为第 l 层的可学习参数。

2 PQD 分类算法

2.1 基于 GAF 和 CNN 的 PQD 识别框架

如图 1 所示, 在上述的 GAF 和 CNN 算法的基础上, 本文提出了一种基于 GAF 和 CNN 的 PQD 识别框架, 该方法具有以下优点:

1) 利用 GAF 图像替代了单变量时间序列, 能更好地对扰动数据的共性和潜在关系进行解释和呈现。

2) CNN 可以自动提取扰动的特征, 无需人工的干预, 不仅极大地增加了特征提取速度, 还提高了分类准确率。

3) 采用梯度下降法来训练网络, 每层的权重会通过损失函数的变换不断地调整参数, 实现完全的自动化, 无需任何手动操作。

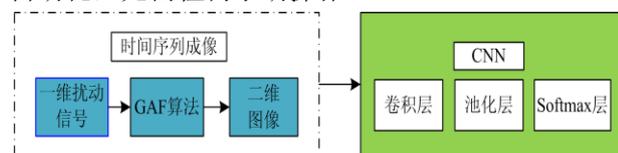


图 1 算法流程

Fig. 1 Algorithm process

2.2 扰动信号成像

由于一维扰动信号在水平和垂直方向上只存在

单向相关性, 在某种程度上无法解释数据的潜在关系, 并且一维序列的点积运算无法区分信号中有效信息和高斯噪声, 所以我们将一维扰动信号数据映射到极坐标, 序列随着时间的增加, 相应的值会在圆上的不同角点之间扭曲, 就像水的涟漪一样。这样生成的序列是双射的, 不会丢失任何信息, 并且保持了时间依赖性。这种基于极坐标的表示是一种理解一维信号的新方法。之后利用角度透视生成 GAF, 通过改变空间维度, 可以充分利用角关系来挖掘出扰动信号中的隐藏特征, 并且处理后的稀疏输出很容易将有效信息与高斯噪声区分开来。而 CNN 容易受到噪声的影响且其在处理稀疏数据方面的能力已经得到充分的证实^[21]。因此将一维扰动信号数据映射到极坐标并生成 GAF, 之后用 CNN 对其进行训练学习, 可以有效提高分类的准确率。然而, 当扰动信号序列的长度为 n 时, 由于 Gram 矩阵的大小为 $n \times n$, 所以 GAF 较大, 为了减小 GAF, 我们采用分段聚集近似对时间序列进行平滑。生成 GAF 的过程如图 2 所示。

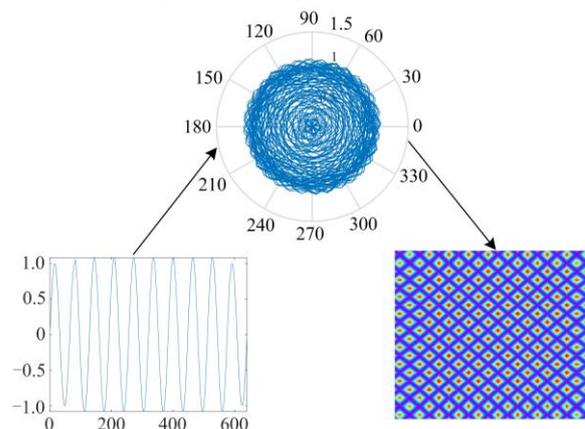


图 2 一维信号映射成二维图像

Fig. 2 A one-dimensional signal maps to a two-dimensional image

2.3 深度学习框架

深度学习在图像分类、语音识别和机器翻译等方面有着良好的表现^[22-23]。它通过多个层次的抽象特征提取对样本进行监督训练然后完成分类。想要采用 CNN 完成分类任务, 首先需要充足的样本, 其指的不仅是数量多, 还要具有多样性, 不可残缺。其次要求样本信息应具有完全性, 是按确定性的规律进行演化的, 也就是说应该是可预测的问题^[24]。基于这些条件, 将 CNN 应用在 PQD 领域是十分合适的, 其不仅样本类别多、区分度大, 而且是可预测的。因此本文通过大量的尝试, 在原有神经网络的框架上, 最终设计了适合 PQD 问题的网络结构。该 CNN 具有一个输入层、五个卷积层、四个池化层、一个完全连接层和一个输出层, 具体如图 3 所示。

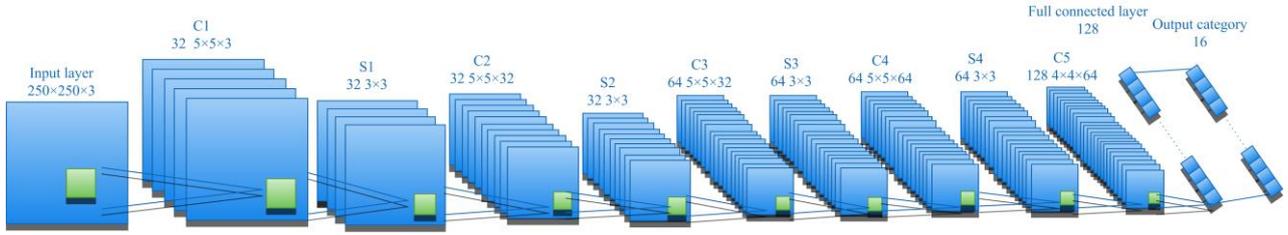


图 3 卷积神经网络框架

Fig. 3 Convolutional neural network framework

首先利用卷积算子来提取 PQD 信号图像的特征，并且为了提取边缘特征，采用了零填充方法。在卷积层之后执行激活操作，这样可以增加网络对非线性特征的学习能力，解决线性模型不能解决的问题。本文采用一种非饱和激活函数 RELU，该函数在深度学习中比 TANH 函数收敛更快，效果更好，并且没有梯度耗散的问题。

$$f_{\text{ReLU}}(x) = \max(0, x) \quad (8)$$

然后加入一个池化层以减少网络的维数，它缩短了训练计算时间，有效地消除了过拟合现象，接着，全连接层使用一个 Softmax 函数来进行分类，最后分类结果由输出层输出。在该方法中采用误差反向传播来调整模型参数。

具体步骤如下：

- 1) 随机初始化所有的神经元参数，其目的是为了将网络中的所有连接权重赋予一个初始值，一般情况下将网络的连接权重和阈值初始化为一个均值为 0 的相对较小的均匀分布区间内。
- 2) 将二维扰动图像作为 CNN 的输入，该网络经过前向传播(卷积、正则、池化和全连接)来自适应地训练网络，最后通过输出层来判别该输入类别。例如标签结果为 {1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0}，则表示 CNN 将该输入判别为第一类样本。使用类别交叉熵作为损失函数来指导训练^[25]：

$$E = -\frac{1}{n} \sum_{i=1}^n [y'_i \ln y_i + (1 - y'_i) \ln(1 - y_i)] \quad (9)$$

3) 在 CNN 的反向传播中计算实际输出与相应的理想输出的差，通过梯度下降法^[26]不断调整各层神经元的参数来降低损失值，随着损失值不断缩小，预测也就越来越准确。

4) 对训练集中的所有图像重复步骤 2)、3)，直到损失函数达到预期的范围。

5) CNN 训练完之后，用测试集对其准确性进行验证，并用 IEEE 电能质量数据分析工作组的实测数据，验证其实用性。

最后，表 1 列出了经过训练的网络结构，清楚

地说明了每一层的网络参数。

表 1 深度学习网络结构设计

Table 1 Structural design of deep learning network

序号	层类型	内核大小	内核个数	步长	填补
1	卷积层 1	5×5×3	32	1	2
2	最大池化层 1	3×3	32	2	1
3	卷积层 2	5×5×32	32	1	2
4	平均池化层 2	3×3	32	2	1
5	卷积层 3	5×5×32	64	1	2
6	平均池化层 3	3×3	64	2	1
7	卷积层 4	5×5×64	64	1	2
8	平均池化层 4	3×3	64	2	1
9	卷积层 5	4×4×64	128	1	2
10	全连接层	16	1	*	*

3 仿真与分析

3.1 数学建模和网络参数

考虑到 CNN 在训练过程中需要大量的数据，且在现实中采集大量的 PQD 数据较困难，因此通过建立 PQD 的数学模型来得到数据集。本文在 Matlab 中建立了 16 种 PQD 信号模型。其中包括标准信号、电压暂降、电压中断、谐波、电压闪变等 10 种单一类型，以及谐波+暂降、谐波+中断、暂降+闪烁等 6 种复合扰动类型。参数变化符合 IEEE-1159 标准^[27]，具体如表 2 所示。其中，基波频率 f_0 为 50 Hz， T 为采样周期，采样频率 f_s 为 3 200 Hz， $u(t)$ 为单位阶跃信号，信号采样长度为 10 个周期(0.2 s)，640 个采样点。按照上述的数学模型随机更改约束参数可以生成海量数据，这样才能够满足深度学习对于训练数据量的要求。在现实中，传感器采集到的信号数据总是伴随着噪声的，因此为了验证该方法的抗造性，在合成 PQD 信号数据的时候分别叠加信噪比为 30、40、50 dB 的高斯白噪声，这样生成的信号更加接近实际扰动信号。因此，本次实验一生成 480 000 个样本，其中每种扰动各有 30 000 个，即三个不同程度的噪声各有 10 000 个样本。然后将总样本分为训练集和测试集两个部分，其中训练集和测试集的比例为 7:3。

表 2 PQD 信号的数学模型

Table 2 Mathematical model of power quality disturbance signal

扰动类型	信号模型	参数
标准信号	$y(t) = A[1 \pm \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t)$	$\alpha \leq 0.1 \quad T \leq t_2 - t_1 \leq 9T$
电压暂升	$y(t) = A[1 + \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t)$	$0.1 \leq \alpha \leq 0.8 \quad T \leq t_2 - t_1 \leq 9T$
电压暂降	$y(t) = A[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t)$	$0.1 \leq \alpha \leq 0.9 \quad T \leq t_2 - t_1 \leq 9T$
电压中断	$y(t) = A[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t)$	$0.9 \leq \alpha \leq T \leq t_2 - t_1 \leq 9T$
谐波	$y(t) = A[\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t)]$	$0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15 \quad \sum \alpha_i^2 = 1$
电压闪变	$y(t) = A[1 + \alpha_f \sin(\beta \omega t)]\sin(\omega t)$	$0.1 \leq \alpha_f \leq 0.2 \quad 5 \text{ Hz} \leq \beta \leq 20 \text{ Hz}$
暂态振荡	$y(t) = A[\sin(\omega t) + \alpha^{-c(t-t_1)/\tau} \sin \omega_n(t-t_1)(u(t_2) - u(t_1))]$	$0.1 \leq \alpha \leq 0.8 \quad 0.5T \leq t_2 - t_1 \leq 3T$ $8 \text{ ms} \leq \tau \leq 40 \text{ ms} \quad 300 \text{ Hz} \leq f_n \leq 900 \text{ Hz}$
暂态脉冲	$y(t) = A[1 - \alpha\{u(t-t_1) - u(t-t_2)\}]\sin(\omega t)$	$0 \leq \alpha_i \leq 0.414 \quad T/20 \leq t_2 - t_1 \leq T/10$
电压缺口	$y(t) = \sin(\omega t) - \text{sign}(\sin(\omega t)) \times \left\{ \sum_{n=0}^9 K[u(t-t_1-0.02n) - u(t-t_2-0.02n)] \right\}$	$0 \leq t_1 t_2 \leq 0.5T \quad 0.01T \leq t_2 - t_1 \leq 0.05T$
电压尖峰	$y(t) = \sin(\omega t) + \text{sign}(\sin(\omega t)) \times \left\{ \sum_{n=0}^9 K[u(t-t_1-0.02n) - u(t-t_2-0.02n)] \right\}$	$0 \leq t_1 t_2 \leq 0.5T \quad 0.01T \leq t_2 - t_1 \leq 0.05T$ $0.1 \leq K \leq 0.4$
谐波+暂降	$y(t) = A[1 - \alpha(u(t-t_1) - u(t-t_2))][\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t)]$	$0.1 \leq \alpha \leq 0.9 \quad T \leq t_2 - t_1 \leq 9T$ $0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15 \quad \sum \alpha_i^2 = 1$
谐波+暂升	$y(t) = A[1 + \alpha(u(t-t_1) - u(t-t_2))][\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t)]$	$0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15 \quad \sum \alpha_i^2 = 1$ $T \leq t_2 - t_1 \leq 9T \quad 0.1 \leq \alpha \leq 0.8$
谐波+中断	$y(t) = A[1 - \alpha(u(t-t_1) - u(t-t_2))][\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t)]$	$0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15 \quad \sum \alpha_i^2 = 1$ $T \leq t_2 - t_1 \leq 9T \quad 0.9 \leq \alpha \leq 1$
谐波+闪变	$y(t) = A[1 + \alpha_f \sin(\beta \omega t)]\sin(\omega t)[\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t)]$	$0.1 \leq \alpha_f \leq 0.2 \quad 5 \text{ Hz} \leq \beta \leq 20 \text{ Hz}$ $0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15 \quad \sum \alpha_i^2 = 1$
闪变+暂降	$y(t) = A[1 + \alpha_f \sin(\beta \omega t)]\sin(\omega t)(1 - \alpha(u(t-t_1) - u(t-t_2)))$	$0.1 \leq \alpha_f \leq 0.2 \quad 0.1 \leq \alpha \leq 0.9$ $T \leq t_2 - t_1 \leq 9T \quad 5 \text{ Hz} \leq \beta \leq 20 \text{ Hz}$
闪变+暂升	$y(t) = A[1 + \alpha_f \sin(\beta \omega t)]\sin(\omega t)(1 + \alpha(u(t-t_1) - u(t-t_2)))$	$0.1 \leq \alpha_f \leq 0.2 \quad 0.1 \leq \alpha \leq 0.9$ $T \leq t_2 - t_1 \leq 9T \quad 5 \text{ Hz} \leq \beta \leq 20 \text{ Hz}$

3.2 训练结果分析

在这项工作中, 个人计算机的处理器、RAM 分别为 4 核的 AMD Ryzen 5 1500X CPU 和 16 GB、

GPU 为 ASUS RTX 2070S。使用 3.1 节中的数据对网络进行训练, 模型训练期间的损耗和性能曲线如图 4 所示。

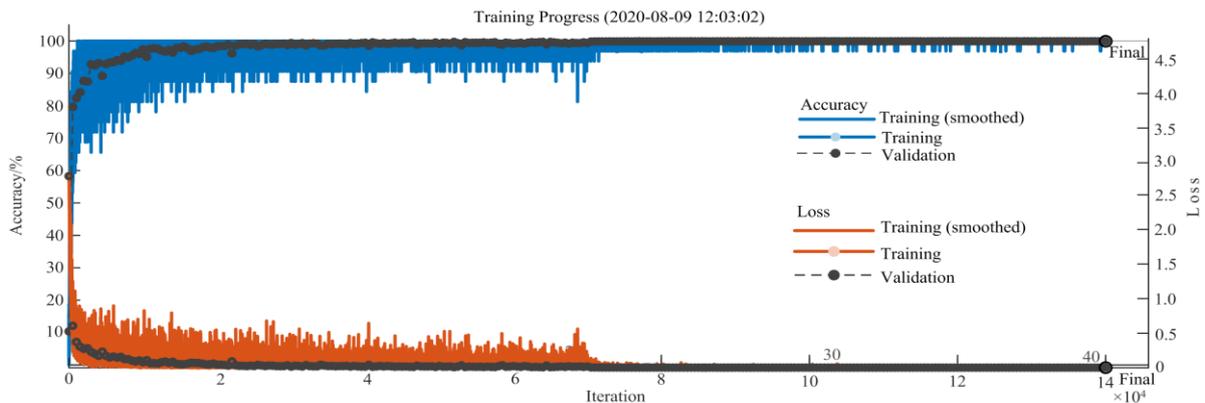


图 4 CNN 的训练结果(信噪比为 50 dB)

Fig. 4 Training results of CNN (SNR is 50 dB)

从图 4 中可以看出在训练初始阶段准确率还比较低,但是经过约 11 代的训练学习之后,损失值就快速减小至 0.1 以下,分类准确率不断提高至 99% 左右,并趋于稳定,说明网络已经收敛。在约 23 次迭代后训练精度和测试精度几乎相等,在迭代完 40 代之后,测试集的总分类准确率为 99.91%,由训练集和测试集的损失曲线可以看出,两者的变化趋势基本一致,说明网络运行良好,没有出现欠拟合和过拟合的问题。为了获得更好的网络性能,有必要确定超参数对网络训练准确率的影响,其中学习率的设定至关重要。通过大量实验验证,本网络采用动态学习率方法,初始学习率设置为 0.001,经过 20 次迭代后,下降为 0.000 1。这样设置可以进一步提高 CNN 的分类准确率。

3.3 与现有方法的对比

虽然本文提出的算法训练时间相对较长,需要的算力较大,但是分类预测的精确度较高。为了证明所提算法的有效性,我们将其与文献[28]的方法进行了比较。具体如表 3 所示。

由表 3 可以看出,本文提出的方法在不同的噪声强度下对扰动分类的总体准确率较理想,与文献[28]相比,在电压暂降、中断方面分类的准确率有了很大的提升,并且该方法在复合扰动方面也有着较好的效果,是一种适合于 PQD 分类的方法。

表 3 在不同噪声环境下的扰动分类结果

Table 3 Disturbance classification results under different noise environments

扰动类型	分类准确率/%					
	文献[28]			本文分类模型		
	30 dB	40 dB	50 dB	30 dB	40 dB	50 dB
标准信号	1.000	1.000	1.000	0.990 0	0.996 0	0.998 7
电压暂升	0.995	1.000	1.000	0.997 0	0.999 3	0.999 3
电压暂降	0.915	0.925	0.940	0.995 0	0.997 0	0.999 3
电压中断	0.940	0.950	0.975	0.999 0	0.999 0	0.999 7
谐波	1.000	1.000	1.000	1.000 0	1.000 0	1.000 0
电压闪变	1.000	1.000	1.000	0.998 7	1.000 0	1.000 0
暂态振荡	0.985	0.995	0.985	0.999 7	1.000 0	1.000 0
暂态脉冲	1.000	1.000	1.000	0.978 0	0.986 7	0.995 0
电压缺口	*	*	*	0.987 0	0.997 3	0.996 7
电压尖峰	*	*	*	0.981 3	0.995 3	0.999 0
谐波+暂降	*	*	*	0.994 0	0.997 7	0.999 0
谐波+暂升	*	*	*	0.998 0	0.999 3	0.999 0
谐波+中断	*	*	*	0.998 0	0.999 0	0.999 7
谐波+闪变	*	*	*	1.000 0	1.000 0	1.000 0
闪变+暂降	*	*	*	0.996 0	0.999 3	0.999 0
闪变+暂升	*	*	*	0.995 7	0.998 0	1.000 0
平均准确率	0.978 8	0.983 8	0.987 5	0.994 2	0.997 8	0.999 1

3.4 真实数据验证

为了进一步验证该方法在实际应用中的可行性,本部分使用一组实际信号作为输入对该方法进行验证。数据集由 IEEE PES 数据库^[29]提供,提供的信号采样率为每个周期 256 个采样点,信号长度为 1 536 个点,分类结果如表 4 所示。

表 4 真实数据的分类结果

Table 4 Classification results of real data

扰动类型	样本数	准确率/%
正常电压	20	0.90
电压暂降	100	0.73
闪变+暂降	10	0.80
谐波+暂降	10	0.80
振荡+暂降	8	0.75
谐波	30	1.00

由于电力系统中出现的干扰不是平衡的,往往电压暂降、暂升以及谐波出现的概率占有扰动类型的 70% 以上^[30-31],因此得到的各类扰动样本数不是平均的。在给出的 100 组电压暂降的数据中,有 73 组被识别为电压暂降,8 组被识别为振荡+暂降,2 组被识别为闪变+暂降,18 组被识别为谐波+暂降。对这 18 组复合信号进行了进一步分析,发现确实存在较小的谐波分量,并且谐波参数满足 IEEE 标准的要求,说明了原始数据的标签不够准确,也证明了该方法可以更准确地识别出容易让人忽略的复合扰动。这 100 组电压暂降扰动的总分类时间为 15 s,平均一个样本的分类预测时间为 0.15 s,说明本文的方法分类预测的速度较快,具有一定的实用性。真实数据分类准确率与仿真数据的结果还有一定的差距,分析其原因,主要是真实数据的类型更复杂,并且训练神经网络需要大量的样本,现有的真实数据量还不足以训练出实用性很好的网络,并且给样本打标签需要耗费很大的人力物力,这些都是导致 CNN 在实际应用中分类准确率还不够理想的原因。

4 结语

本文提出了一种基于 GAF 与 CNN 的 PQD 分类新方法,通过 GAF 方法将 PQD 信号转化为二维图像,并将其作为 CNN 的输入,经过监督学习,CNN 实现了特征的自动提取和分类,避免了人工选取特征的困难。该方法采用了易于实现的技术,使得训练后的 CNN 具有良好的泛化能力和分类效果。仿真和实测数据均验证了该方法的有效性,与现有方法相比,该方法在分类准确率、抗噪性方面具有更好的性能。在未来的工作中,将对 PQD 定位展开

相关研究, 因为除了对扰动进行准确的分类以外, 精确地定位到扰动发生的起止时刻也是有效治理电能质量问题的关键。

参考文献

- [1] 李静, 李幸芝, 韩蓓, 等. 考虑分布式电源不确定性与相关性的配电网状态估计[J]. 全球能源互联网, 2020, 3(3): 231-237.
LI Jing, LI Xingzhi, HAN Bei, et al. State estimation in distribution systems considering distributed generation uncertainties with correlations[J]. Journal of Global Energy Interconnection, 2020, 3(3): 231-237.
- [2] SINGH G K. Power system harmonics research: a survey[J]. European Transactions on Electrical Power, 2009, 19(2): 151-172.
- [3] 何国庆, 王伟胜, 刘纯, 等. 分布式电源并网技术标准研究[J]. 中国电力, 2020, 53(4): 1-12.
HE Guoqing, WANG Weisheng, LIU Chun, et al. Study on technical standard of distributed resources grid integration[J]. Electric Power, 2020, 53(4): 1-12.
- [4] SEME S, LUKAČ N, ŠTUMBERGER B, et al. Power quality experimental analysis of grid-connected photovoltaic systems in urban distribution networks[J]. Energy, 2017, 139: 1261-1266.
- [5] 张然, 郭俊宏, 蓝新斌, 等. 基于深度置信网络的 PQD 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.
- [6] SATPATHI K, YEAP Y M, UKIL A, et al. Short-time Fourier transform based transient analysis of VSC interfaced point-to-point DC system[J]. IEEE Transactions on Industrial Electronics, 2018, 65(5): 4080-4091.
- [7] GUO F, WANG P, WANG Y, et al. Research on improved S transform for the feature extraction of power quality disturbance signal[J]. IEEE Access, 2020, 8: 137910-137917.
- [8] 刘丹丹. 基于经验模态分解的时间序列预测方法[J]. 上海电力大学学报, 2021, 37(3): 231-234, 252.
LIU Dandan. The method for time series prediction based on empirical mode decomposition[J]. Journal of Shanghai University of Electric Power, 2021, 37(3): 231-234, 252.
- [9] 李齐礼, 季振山, 舒双宝. 电能质量分析中 FFT 算法的改进与实现[J]. 数据采集与处理, 2013, 28(1): 105-109.
LI Qili, JI Zhenshan, SHU Shuangbao. Improvement and implementation of FFT algorithm for power quality analysis[J]. Journal of Acquisition and Processing, 2013, 28(1): 105-109.
- [10] 潘从茂, 李凤婷. 基于小波变换的暂态电能质量的检测与识别[J]. 电测与仪表, 2013, 50(11): 69-72.
PAN Congmao, LI Fengting. The detection and identification of transient power quality based on wavelet transform[J]. Electrical Measurement and Instrumentation, 2013, 50(11): 69-72.
- [11] 杨剑锋, 姜爽, 石戈戈. 基于分段改进 S 变换的复合 PQD 识别[J]. 电力系统保护与控制, 2019, 47(9): 64-71.
YANG Jianfeng, JIANG Shuang, SHI Gege. Classification of composite power quality disturbances based on piecewise-modified S transform[J]. Power System Protection and Control, 2019, 47(9): 64-71.
- [12] 田振果, 傅成华, 吴浩, 等. 基于 HHT 的 PQD 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. Power quality disturbance for location and classification based on HHT[J]. Power System Protection and Control, 2015, 43(16): 36-42.
- [13] 檀何凤, 刘政怡. 基于标签相关性的 K 近邻多标签分类方法[J]. 计算机应用, 2015, 35(10): 2761-2765.
TAN Hefeng, LIU Zhengyi. Multi-label K nearest neighbor algorithm by exploiting label correlation[J]. Journal of Computer Applications, 2015, 35(10): 2761-2765.
- [14] ZHAO Wenjing, SHANG Liqun, SUN Jinfan. Power quality disturbance classification based on time-frequency domain multi-feature and decision tree[J]. Protection and Control of Modern Power Systems, 2019, 4(4): 337-342. DOI: 10.1186/s41601-019-0139-z.
- [15] 马嘉秀, 徐玮浓, 何复兴, 等. 基于 WT 和 SVM 的电能质量分类识别方法[J]. 智慧电力, 2019, 47(3): 16-22.
MA Jiaxiu, XU Weinong, HE Fuxing, et al. A novel power quality classification and identification method based on WT and SVM[J]. Smart Power, 2019, 47(3): 16-22.
- [16] 刘佳翰, 陈克绪, 马建, 等. 基于卷积神经网络和随机森林的三相电压暂降分类[J]. 电力系统保护与控制, 2019, 47(20): 112-118.
LIU Jiahao, CHEN Kexu, MA Jian, et al. Classification of three-phase voltage dips based on CNN and random forest[J]. Power System Protection and Control, 2019, 47(20): 112-118.
- [17] 陈华丰, 张葛祥. 基于决策树和支持向量机的 PQD 识别[J]. 电网技术, 2013, 37(5): 1272-1278.
CHEN Huafeng, ZHANG Gexiang. Power quality disturbance identification using decision tree and support

- vector machine[J]. Power System Technology, 2013, 37(5): 1272-1278.
- [18] 王维博, 张斌, 曾文入, 等. 基于特征融合一维卷积神经网络的 PQD 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 of one-dimensional convolutional neural network based on feature fusion[J]. Power System Protection and Control, 2020, 48(6): 53-60.
- [19] WANG Z, OATES T. Imaging time-series to improve classification and imputation[C] // Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence, July 28-August 1, 2015, Buenos Aires, Argentina: 3939-3945.
- [20] WANG S, CHEN H. A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network[J]. Applied Energy, 2019, 235: 1126-1140.
- [21] CHEN H, MIAO F, SHEN X. Hyperspectral remote sensing image classification with CNN based on quantum genetic-optimized sparse representation[J]. IEEE Access, 2020, 8: 99900-99909.
- [22] 赵振兵, 齐鸿雨, 聂礼强. 基于深度学习的输电线路视觉检测研究综述[J]. 广东电力, 2019, 32(9): 11-23.
ZHAO Zhenbing, QI Hongyu, NIE Liqiang. Research overview on visual detection of transmission lines based on deep learning[J]. Guangdong Electric Power, 2019, 32(9): 11-23.
- [23] 薛阳, 吴海东, 俞志程, 等. 基于深度学习的变压器图像识别系统[J]. 上海电力大学学报, 2021, 37(1): 51-56.
XUE Yang, WU Haidong, YU Zhicheng, et al. Transformer image recognition system based on deep learning[J]. Journal of Shanghai University of Electric Power, 2021, 37(1): 51-56.
- [24] 魏文兵, 毛钧毅, 荣娜, 等. 采用随机矩阵与 CNN 的暂态电压稳定快速评估[J]. 电网与清洁能源, 2020, 36(11): 68-76.
WEI Wenbing, MAO Junyi, RONG Na, et al. Fast evaluation of transient voltage stability using random matrix and convolutional neural network[J]. Power System and Clean Energy, 2020, 36(11): 68-76.
- [25] 黄宇鹏, 李立新, 王磊, 等. 基于神经网络的电网运行趋势估计算法及应用[J]. 智慧电力, 2019, 47(6): 113-120.
HUANG Yupeng, LI Lixin, WANG Lei, et al. Power network operation trend estimation algorithm based on neural network and its application[J]. Smart Power, 2019, 47(6): 113-120.
- [26] LECUN Y, BENGIO Y, HINTON G E, et al. Deep learning[J]. Nature, 2015, 521: 436-444.
- [27] SCHMIDHUBER J. Deep learning in neural networks: an overview[J]. Neural Networks, 2015, 61: 85-117.
- [28] 瞿合祚, 李晓明, 陈陈, 等. 基于卷积神经网络的 PQD 分类[J]. 武汉大学学报: 工学版, 2018, 51(6): 534-539.
QU Hezuo, LI Xiaoming, CHEN Chen, et al. Classification of power quality disturbances using convolutional neural network[J]. Engineering Journal of Wuhan University, 2018, 51(6): 534-539.
- [29] IEEE Power Engineering Society. IEEE PES working group P1433 power quality definitions[Z]. Accessed, 2001.
- [30] SHARMA A, RAJPUROHIT B S, AGNIHOTRI S, et al. Evaluation of new power quality indices proposed for estimation of economic loss due to poor power quality[C] // 2016 IEEE Region 10 Conference, November 22-25, 2016, Singapore, Singapore: 3631-3634.
- [31] 潘晓杰, 徐友平, 朱成亮, 等. 基于深度学习的多输入特征融合的暂态电压稳定性评估方法[J]. 电网与清洁能源, 2021, 37(2): 79-84.
PAN Xiaojie, XU Youping, ZHU Chengliang, et al. Transient voltage stability evaluation method based on multi-input feature fusion of deep learning[J]. Power System and Clean Energy, 2021, 37(2): 79-84.

收稿日期: 2020-08-15; 修回日期: 2021-05-08

作者简介:

郑炜(1994—), 男, 硕士研究生, 研究方向为电能质量、人工智能。E-mail: zw0901vip@163.com

林瑞全(1971—), 男, 通信作者, 教授, 主要研究方向为神经网络控制。E-mail: rqlin@fzu.edu.cn

(编辑 魏小丽)