

引用格式:时帅,陈子文,黄冬梅,等.基于MTF可视化和改进DenseNet神经网络的电能质量扰动识别算法[J].电力科学与技术学报,2024,39(4):102-111.  
Citation:SHI Shuai,CHEN Ziwen,HUANG Dongmei, et al.An identification method based on MTF visualization and improved DenseNet for power quality disturbances[J].Journal of Electric Power Science and Technology,2024,39(4):102-111.

# 基于 MTF 可视化和改进 DenseNet 神经网络的 电能质量扰动识别算法

时 帅<sup>1</sup>,陈子文<sup>1</sup>,黄冬梅<sup>2</sup>,贺 琪<sup>3</sup>,孙 园<sup>4</sup>,胡 伟<sup>5</sup>

(1.上海电力大学电气工程学院,上海 200090;2.上海电力大学计算机与技术学院,上海 200090;3.上海海洋大学信息学院,上海 201306;  
4.上海电力大学数理学院,上海 200090;5.上海电力大学经济与管理学院,上海 200090)

**摘 要:**针对传统电能质量扰动(power quality disturbances, PQDs)分类器人工选取特征过程复杂、精细化程度不足的问题,提出一种基于马尔科夫迁移场(Markov translate filed, MTF)可视化和改进密集卷积网络(dense convolutional networks, DenseNet)的PQDs识别新方法。首先将一维PQD信号经MTF映射为二维图像,接着将图像输入到具有新型通道注意力机制的改进DenseNet中,最后训练网络自行从海量样本中提取特征,实现PQDs信号的正确识别。算例结果表明:在无噪声和信噪比为20、30 dB情况下,所提改进DenseNet能有效克服传统方法中主观性强、抗噪性能差等特征缺点,可以更好地提取复合PQD特征信息,对复合PQD识别率高。

**关 键 词:**电能质量扰动;马尔科夫迁移场;可视化;密集卷积网络;通道注意力机制;分类识别

**DOI:** 10.19781/j.issn.1673-9140.2024.04.012 **中图分类号:** TM721 **文章编号:** 1673-9140(2024)04-0102-10

## An identification method based on MTF visualization and improved DenseNet for power quality disturbances

SHI Shuai<sup>1</sup>, CHEN Ziwen<sup>1</sup>, HUANG Dongmei<sup>2</sup>, HE Qi<sup>3</sup>, SUN Yuan<sup>4</sup>, HU Wei<sup>5</sup>

((1.College of Electrical Power Engineering, Shanghai University of Electric Power, Shanghai 200090, China; 2.College of Computer Science and Technology, Shanghai University of Electric Power, Shanghai 200090, China; 3.College of Information Technology, Shanghai Ocean University, Shanghai 201306, China; 4.College of Mathematics and Physics, Shanghai University of Electric Power, Shanghai 200090, China; 5.College of Economics and Management, Shanghai University of Electric Power, Shanghai 200090, China))

**Abstract:** Aiming at the problems of complex process and insufficient refinement of artificial feature selection in traditional power quality disturbances (PQDs) classifier, a new PQD recognition method based on Markov transition field visualization and improved DenseNet is proposed. Firstly, the one-dimensional PQD signal is mapped into a two-dimensional image by MTF. Then, the image is input into an improved DenseNet with a new channel attention mechanism. Finally, the network is trained to extract features from a large number of samples by itself, so as to realize the correct recognition of PQD signals. The example results show that: in the case of no noise and signal-to-noise ratio of 20dB and 30dB, the proposed improved DenseNet can effectively overcome the shortcomings of traditional methods, such as strong subjectivity of feature selection and poor anti-noise performance. It can better extract the feature information of complex PQD, and has a high recognition rate for complex PQD.

**Key words:** power quality disturbance; Markov translate field; visualization; dense convolutional networks; channel attention mechanism; classification and recognition

随着现代电网的发展,可再生电源高渗透率和  
电力系统电力电子化趋势凸显<sup>[1-2]</sup>,电网中无功功

率过量、功率因数崩溃、负荷骤变、负荷非线性以  
及线路切换等造成的电能质量扰动(power quality

收稿日期:2023-03-06;修回日期:2023-04-27

基金项目:国家自然科学基金(61972240)

通信作者:时 帅(1987—),男,博士,讲师,主要从事电力系统运行等研究;E-mail:ssglasgow@163.com

disturbances, PQDs)问题越来越严重,电压波动闪变、电压骤变与三相不平衡等<sup>[3-4]</sup>PQDs 的发生将引发电网的安全隐患和经济损失。对 PQDs 精确有效地分类识别是解决电能质量问题的重要措施之一。

在过去几年中,研究人员对复杂的 PQDs 提出了各种检测和分类方法,主要包括特征值提取和信号分类 2 步。在信号特征值提取过程中,通过不同的处理方法从原始信号中提取不同的特征。传统方法主要包括快速傅里叶变换<sup>[5-6]</sup>、小波变换<sup>[7]</sup>、S 变换<sup>[8-9]</sup>、希尔伯特黄变换<sup>[10]</sup>,经验模态分解<sup>[11-12]</sup>、奇异值分解<sup>[13]</sup>以及卡尔曼滤波<sup>[14-15]</sup>等。在提取信号特征值后,将根据指定的规则对捕获干扰进行分类。研究主要集中在人工智能算法和机器学习上,如决策树<sup>[16-17]</sup>、支持向量机<sup>[18]</sup>、人工神经网络、模糊逻辑<sup>[19]</sup>以及混合集成学习器<sup>[20]</sup>。其中,决策树主要通过制定规则并模仿人类的逻辑思维完成分类,但各类别特征值的提取易受噪声影响<sup>[21]</sup>;支持向量机对多种类型扰动识别精度较高,但设计难度和计算复杂度都比较大。

学者们提出将典型特征的传统提取方法与先进的分类算法相结合,虽然研究取得了较好的结果,但其信号特征的阈值确定过于依赖专家经验和研究者的主观性,易忽略复合类型 PQDs 的深度特征。故本文基于深度学习中图像分类“端对端”的思想,通过监督学习和图像处理,将原始 PQDs 进行可视化,将效率低下的扰动数据特征提取识别转换为基于深度学习的图像分类。可视化技术可以在有限的展现空间中以直观的方式传达大量的电能质量抽象信息<sup>[22]</sup>。文献[23]提出将 PQDs 转化为形状特征明显的轨迹圆图像,进而输入到深度残差网络中进行分类的方法,但该方法在暂态振荡、电压暂降等多种扰动时表现不好;文献[24-25]利用递归算法将 PQDs 的一维时间序列投影到二维相平面,形成二维轨迹图像,最后将递归图输入到卷积神经

网络(convolutional neural networks, CNN)中进行分类,但在复杂 PQDs 下的递归图易遗漏重要特征信息,导致分类精度下降;文献[26]提出一种基于格拉姆角场将一维时间序列编码为图像和卷积神经网络的 PQDs 分类方法,但其未进行 2 种以上的复杂 PQDs 分类验证。

本文为应对高比例新能源接入电网引发的 PQDs 问题,提出一种基于马尔科夫迁移场(Markov translate filed, MTF)和改进密集卷积网络(dense convolutional network, DenseNet)<sup>[27]</sup>的 PQDs 识别新方法。利用马尔科夫转移概率可保留时域信息和多维相位空间轨迹的特性,将原始扰动信号转化为二维图像输入到 DenseNet 分类框架,结合 DenseNet 稠密连接的跳跃结构和改进通道注意力机制,训练网络进而实现 PQDs 信号的正确识别。最后,在无噪声和信噪比(signal-to-noise ratio, SNR)为 20、30 dB 情况下,通过与其他方法的识别精度和性能对比,表明本文所提方法可以高效、准确地进行扰动分类,并且具有较强的抗噪性、鲁棒性。

## 1 电能质量扰动信号

理想状态下正常电压信号为  $x = \sin(\omega t(n))$ , PQDs 发生时将以多项式表示为

$$x = \text{Mul}(t(n)) \cdot \sin(\omega(t(n))) + \text{Add}(t(n)) \quad (1)$$

式中,  $t(n)$  为以采样频率为基底的时间序列;  $\omega$  为工频下的角频率;  $\text{Mul}(t(n))$  为相乘形式发生的电能质量扰动信号,如电压暂降/暂升、电压中断和电压消失等;  $\text{Add}(t(n))$  为相加形式发生的电能质量扰动信号,如谐波、振荡和噪声等。

本文根据 IEEE Std 1159—2019 标准,设立常见的 7 类单一 PQDs、13 类复合扰动,具体单一扰动数学模型及其参数变化范围如表 1 所示,复合扰动数学模型及其参数变化范围参见文献[28]附录表 1。

表 1 单一电能质量扰动表达式

Table 1 Parameters of seven PQDs

扰动类型	模型	参数设置
电压暂降(C <sub>1</sub> )	$x(t) = A \{1 - \alpha [u(t - t_1) - u(t - t_2)]\} \sin(\omega t)$	$\alpha = 0.1 \sim 0.9, T < t_1 - t_2 < 8T$
电压暂升(C <sub>2</sub> )	$x(t) = A \{1 + \alpha [u(t - t_1) - u(t - t_2)]\} \sin(\omega t)$	$\alpha = 0.1 \sim 0.9, T < t_1 - t_2 < 8T$
电压中断(C <sub>3</sub> )	$x(t) = A \{1 - \alpha [u(t - t_1) - u(t - t_2)]\} \sin(\omega t)$	$\alpha = 0.9 \sim 1.0, T < t_1 - t_2 < 8T$
谐波(C <sub>4</sub> )	$x(t) = A \{a_1 \sin(\omega t) + a_3 \sin(3\omega t) + a_5 \sin(5\omega t) + a_7 \sin(7\omega t)\}$	$\alpha_1 = 0.1 \sim 0.9, 0.05 \leq \alpha_3, \alpha_5, \alpha_7 \leq 0.15$
暂态振荡(C <sub>5</sub> )	$x(t) = A \{ \sin(\omega t) + \lambda e^{-(t-t_1)} \sin(\mu \omega t) [u(t - t_1) - u(t - t_2)] \}$	$\lambda = 0.1 \sim 0.8, \mu = 10 \sim 40, 0.5T < t_1 - t_2 < 3T$
暂态脉冲(C <sub>6</sub> )	$x(t) = A \{ \sin(\omega t) + \alpha [u(t - t_1) - u(t - t_2)] \}$	$\alpha = 1 \sim 3, 1 \leq t_1 - t_2 \leq 3$
电压波动(C <sub>7</sub> )	$x(t) = A \{1 + \alpha \sin(\beta \omega t)\} \sin(\omega t)$	$\alpha = 0.1 \sim 0.3, \beta = 0.1 \sim 0.5$

## 2 马尔科夫迁移场可视化 PQDs

为了从庞大的扰动信号数据中自动提取特征,本文利用MTF通过表示马尔科夫转移概率保留时域信息的特点,将时间序列转换为MTF二维图像。

### 2.1 马尔科夫转移概率矩阵

马尔科夫链为一个状态转移到自身或其他状态的概率。给定一个时间序列 $X=(x_1, x_2, \dots, x_t, \dots, x_n)$ ,将其值域分为 $m$ 分位数, $x_t$ 定义为时刻 $t$ 的状态 $s_j$ ,分位数 $q_j$ 对应为 $x_t (j \in [1, m])$ ,状态数量为 $m$ 。  $m \times m$  维的马尔科夫转移概率矩阵 $P_{M \times M}$ 表示具有 $s_1, s_2, \dots, s_m$ 的 $m$ 个状态的马尔可夫链:

$$P_{M \times M} = \begin{bmatrix} p_{11} & p_{12} & \cdots & p_{1m} \\ p_{21} & p_{22} & \cdots & p_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ p_{m1} & p_{m2} & \cdots & p_{mm} \end{bmatrix} \quad (2)$$

其中, $p_{ij}$ 为各状态之间的转移概率, $\sum_i p_{ij} = 1$ ,且 $1 \leq i, j \leq m$ 。

### 2.2 MTF变换电能质量扰动信号

对马尔科夫转移概率矩阵按时间顺序排列,扩展得到马尔科夫转移矩阵。时间序列 $X$ 则可转化为 $n \times n$ 的马尔科夫转移矩阵 $F_{MTFnm}^{[29]}$ :

$$F_{MTFnm} = \begin{cases} p_{ij} = c_{ij} / \sum_i c_{ij}, 1 \leq i, j \leq m \\ \begin{bmatrix} f_{11} & \cdots & f_{1n} \\ f_{21} & \cdots & f_{2n} \\ \vdots & \ddots & \vdots \\ f_{n1} & \cdots & f_{nm} \end{bmatrix} \\ \begin{bmatrix} p_{ij|x_1 \in s_i, x_1 \in s_j} & \cdots & p_{ij|x_1 \in s_i, x_n \in s_j} \\ p_{ij|x_2 \in s_i, x_1 \in s_j} & \cdots & p_{ij|x_2 \in s_i, x_n \in s_j} \\ \vdots & \ddots & \vdots \\ p_{ij|x_n \in s_i, x_1 \in s_j} & \cdots & p_{ij|x_n \in s_i, x_n \in s_j} \end{bmatrix} \end{cases} \quad (3)$$

式中, $c_{ij}$ 为状态 $s_i$ 转移到 $s_j$ 的数据点个数; $f_{kl}$ 为状态 $s_i$ 以时间步长 $a$ 、点 $x_a$ 转移到状态 $s_j$ 以时间步长 $b$ 、点 $x_b$ 的概率。

若存在 $i, j$ 时间点,则 $F_{MTFi, j|l-l-j=k}$ 表示时间间隔为 $k$ 个点的转移概率, $F_{MTFi, j|j-i=1}$ 则为时间轴上相差一步的转移概率即一步转移概率,对角线 $F_{MTFi}$ 为 $k=0$ 在时间点 $i$ 上各个分位箱转移到自身的概率。本质上为 $X=(x_1, x_2, \dots, x_t, \dots, x_n)$ 任意2点的多跨度转移概率,在离散化信号并分置于各个分位箱后,记录各个分位箱单元的统计数 $c_{ij}$ 进行概率运算,将

马尔科夫转移概率矩阵每行各跨分位箱单元的统计数 $c_{ij}$ 分别除以该行跨分位箱单元的统计数总和 $\sum_i c_{ij}$ ,转变为各个跨分位数单元的过渡概率,最后得到马尔科夫转移概率矩阵。为使图像尺寸易于管理和计算效率更高,通过对每个非重叠 $m \times m$ 大小的窗口像素使用模糊核 $\{1/m^2\}_{m \times m}$ 进行平均,以减少MTF的尺寸。原始信号经MTF的编码映射过程如图1所示。

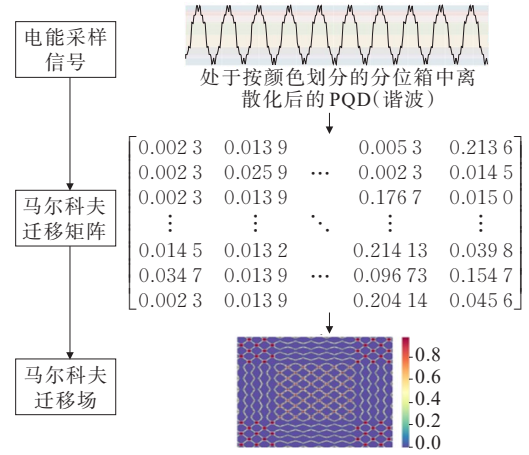


图1 MTF编码映射

Figure 1 Encoding mapping of MTF

与马尔科夫转移矩阵相比,MTF除了具有状态转移概率外,还具有额外的时间信息,因此,它更适合于表示和提取时间序列的特征。具有 $n$ 个数据采样点的时间序列映射到MTF中为 $n \times n$ 的矩阵,通过Python可视化二维MTF图像。本文中20种电能质量扰动经MTF变化后图像参见文献[28]附录表2。

## 3 DenseNet识别框架基本原理

残差网络(residual network, ResNet)的残差连接是每层与其前面的某层(一般是2~3层)短路连接在一起,连接方式为元素级相加,即

$$x_l = H_l(x_{l-1}) + x_{l-1} \quad (4)$$

而DenseNet相较于残差连接,设置了更激进的稠密连接机制,每层都会与其前面所有层的各通道维度进行连接,并作为下一层的输入,即

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (5)$$

式中, $x_l$ 为第 $l$ 层输出; $[x_0, x_1, \dots, x_{l-1}]$ 为 $0, 1, \dots, l-1$ 层的特征映射连接; $H_l(\cdot)$ 为非线性转化函数,其中,包含批归一化(batch normalization, BN)、线性整流单元(rectified linear unit, ReLU)、池化层

(pooling)及卷积层(convolution)操作。

DenseNet 的前向传播过程如图 2 所示,  $h_3$  的输入为  $h_2$  的  $x_2$  以及前两层的  $x_1, x_0$  在通道维度的连接, 即每一层都能接收到来自前面所有层的特征信息。




图 2 DenseNet 前向传播示意

Figure 2 Feedforward neural network of DenseNet

DenseNet 网络结构主体部分包括 4 个稠密连接块(dense block, DB)和 3 个传递层(transition layer, TL)。TL 为 Conv(1×1)+全局平均池化(global average pooling, GAP)(2×2)层。DB 中各层之间传递的特征映射大小一致,可以实现通道维度上的连接;DB 中的非线性转化函数  $H_l(\cdot)$  采用 BN+ReLU+Conv(3×3)的操作结构,如图 3 所示。




图 3 稠密连接块结构

Figure 3 Structure of dense block

此外,DB 中各层进行卷积操作后均得到  $k$  个特征映射的通道数,即 DenseNet 网络的增长率为  $k$ ,则第  $l$  层的输入通道数为  $k_0 + k(l - 1)$ ,其中  $k_0$  为输入层特征映射的通道数,由此可知,即使  $k$  较小(一般为 12),DB 的输入随着层数增加其数目会增大。如图 4 所示,DB 中采用瓶颈层(bottleneck)以减少计算量,即 BN+ReLU+Conv(1×1)+BN+ReLU+Conv(3×3),在 Conv(1×1)的卷积操作后得到  $4k$  个特征映射,可以降低特征数量、提升计算效率。




图 4 全连接层结构

Figure 4 Structure of dense layer

### 4 PQDs 识别框架搭建

区别于传统两步法,本文提出一种基于 MTF 图像和稠密连接网络的 PQDs 识别的新型两步法,该方法通过自主有监督地学习二维 MTF 图像特征信息,进而完成对复合电能质量扰动类型的识别,具体识别框架如图 5 所示。




图 5 MTF-DenseNet 电能质量扰动识别结构

Figure 5 Classification for power quality disturbance based on MTF-DenseNet

#### 4.1 识别框架整体思路

本文所提算法的整体思路:将复合扰动对应 MTF 作为图像识别神经网络的输入,并利用 DenseNet 网络自动提取图像像素数据的潜在特征,最终映射到样本标签,识别步骤如下:

- 1) 对采样得到的电能质量原始信号离散化为分位数,根据式(4)计算其马尔科夫转移矩阵,并将其经 MTF 矩阵编码映射得到聚合图像;
- 2) 构建 DenseNet 模型,对其进行调参并训练;
- 3) 利用训练所得的最优 DenseNet 模型,识别

测试样本集的电能质量扰动信号 MTF 编码图像,得到分类结果。

#### 4.2 改进 DenseNet 结构细节

本文所提改进 DenseNet 与 DB、TL 连接模式如图 6 所示,完整 DenseNet 架构以及有关层的信息参见文献[28]附录表 3。

- 1) 新型通道注意力模块。

本文基于有效通道注意力(efficient channel attention, ECA)模块和平均最大随机池化模块的特性构建一维卷积池化模块(1D-average max

stochastic, 1D-AMS)<sup>[30]</sup>的改进模块,如图7所示, ECA只使用GAP进行通道全局空间信息的特征提取。考虑PQDs信号发生扰动在全时间尺度上占比较小,而在经MTF编码得到的二维图像中,

扰动时刻对应的像素值在局部区域为最大的概率较低,故而ECA-Net中采用的GAP无法充分利用通道中有价值的特征,压缩空间信息过程中会出现特征损失。

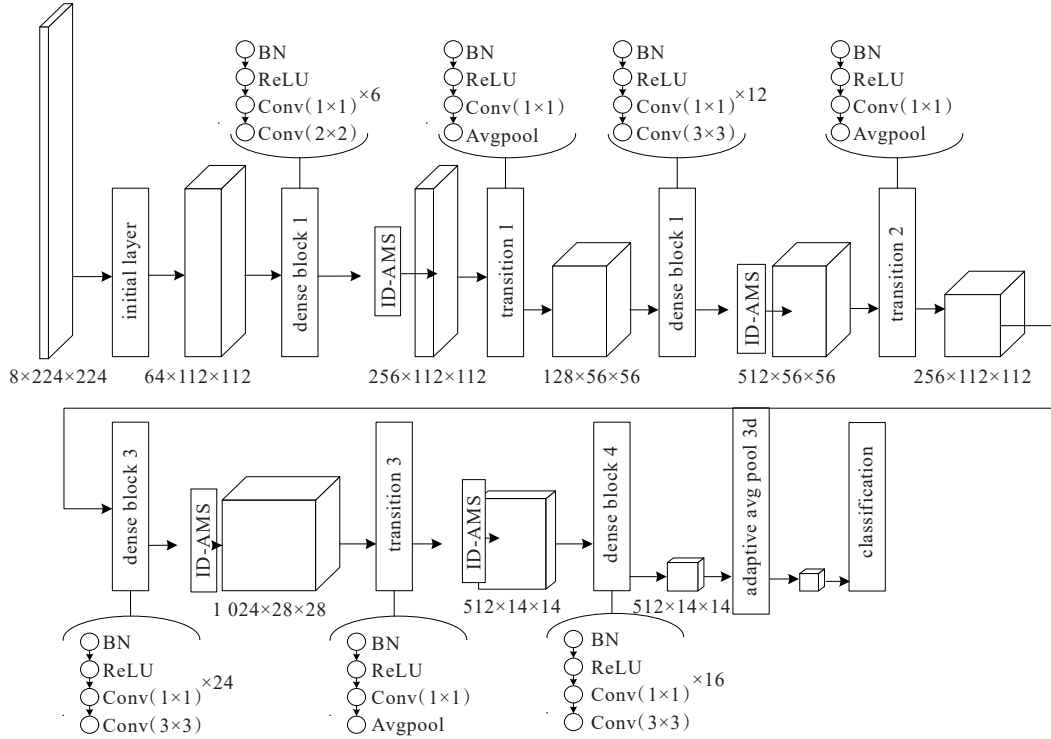


图6 改进DenseNet结构

Figure 6 Structure of improved DenseNet




图7 1D-AMS通道注意力模块结构

Figure 7 Structure of 1D-AMS module

本文将原始ECA模块中的GAP扩展为AMS(全局平均池化(GAP)、全局最大池化(global max-pooling, GMP)、全局随机池化(global stochastic pooling, GSP)以进行全局空间信息的压缩,各通道信息经扩展后再经一个具有自适应选择核大小的一维卷积神经网络(1D-CNN)和sigmoid激活函数进行通道之间的信息交互,对各通道的融合依赖关系进行特征信息的赋值。具体公式如下:

$$\omega = \sigma \left[ f_{w_1, w_2} (g_A(X)) \right] + \sigma \left[ f_{w_1, w_2} (g_M(X)) \right] + \sigma \left[ f_{w_1, w_2} (g_S(X)) \right] \quad (6)$$

式中,  $X$  为卷积块输出,  $X \in \mathbb{R}^{W \times H \times C}$ ,  $W$ 、 $H$ 和 $C$ 分

别为宽、高和通道维度(过滤器的数量);  $g_A(X)$ 、 $g_M(X)$ 、 $g_S(X)$ 分别为全局平均、全局最大、全局随机池化。

$$g_A(X) = \frac{1}{WH} \sum_{i=1, j=1}^{W, H} X_{ij} \quad (7)$$

$$g_M(X) = \max \{ X_{ij} \} \quad (8)$$

令  $y = g_A(X)$ , 则可得到:

$$f_{\{w_1, w_2\}}(y) = W_2 \text{ReLU}(W_1 y) \quad (9)$$

式中, ReLU为线性整流函数。

## 2) 多时间跨度扰动识别模块。

PQDs发生时间跨度一般处于不确定状况,在此前提下,本文采用多时间跨度自适应模块代替原有的全局池化操作。经过3个过渡层和4个密集连通的块后,得到的特征映射尺寸为原始图像的1/32,特征映射数目为1024。为了进一步减少计算量,即减少特征映射的数量和大小。在不增加网络参数的情况下,通过自适应3d平均池化操作(adaptive average pool 3d),将特征映射减少到512个,尺寸为1x1。此外,该操作保证了输出特征映

射的尺寸为  $1 \times 1$ , 数目为 512, 为后续卷积分类器提供了一个固定大小的特征映射, 使网络能够接受不同大小的图像。3 种时间跨度扰动输入的自适应模块如图 8 所示。




图 8 3 种时间跨度扰动输入的自适应模块

Figure 8 Adaptive module with three temporal PQDs input

3) 卷积分类器。

经自适应平均 3d 池化层削减特征数量后, 采用 2 个全连接层微调采样信号的高阶特征表示, 最后利用柔性最大 (softmax) 激活函数来执行概率映射。softmax 激活函数将最终的类别特征表示映射为每个类别的概率, 即

$$P(c|\nu) = \frac{\exp(X_c)}{\sum_{j=1}^n \exp(X_j)} \quad (10)$$

式中,  $X_c \in \nu$ ,  $X_c$  为卷积分类器产生的向量  $\nu$  的第  $c$  个数。

## 5 实验设置及结果分析

### 5.1 建立电能质量扰动数据集

设置基波频率为 50 Hz, 采样频率为 3 200 Hz, 信号采样长度为 10 个周期 (0.2 s)。在无噪声和信噪比为 20、30 dB 时, 分别测试文 1 中 20 类单一和复合扰动信号, 每类扰动由 1 000 个扰动点随机发生的样本组成, 训练集、验证集和测试集的比例为 8:1:1, 训练样本为分辨率在  $224 \times 224$  以上的 3 通道 RGB 图片格式。

在 Pytorch 环境中搭建改进 ASP-DenseNet 模型, 采用随机梯度下降优化算法, 其学习率设置为 0.001, 批输入尺寸为 16, 损失函数为 categorical\_crossentropy, 线性整流函数为 ReLU。

### 5.2 深度学习图像识别框架对比

为探究 DenseNet 在电能质量信号分类识别的性能, 选取同为轻量级网络的 GoogleNet、视觉变压器 (vision transformer, ViT)、ResNet 与本文所采用

的改进 ASP-DenseNet 进行对比, 对文 1 中构建的 PQDs 数据集进行分类, 迭代次数设为 30。

验证集分类准确率变化曲线如图 9 所示, 可知在迭代 5 次后, 本文所采用的可视化扰动识别方法的分类准确率就达到了 97% 以上, 且很快稳定保持在 99% 以上; 损失函数曲线如图 10 所示, ASP-DenseNet 网络的损失起始值为 0.386, 且在第 2 次迭代便下降到 0.126, 之后收敛渐趋于 0.001, 从验证集分类准确率和损失函数曲线可以证明, 本文提出的方法收敛快速、性能稳定。ResNet 迭代多次后在验证集分类的表现波动仍较大, 但其在采样信号可视化为轨迹圆时的准确率较高, 其轨迹圆形状特征较明显, 而本文前期对信号采取 MTF 可视化变换, 需要对图像的全局特征高效利用, DenseNet 中更密集的连接能实现这一点; ViT 则需要以足够的规模进行预训练后再迁移到任务中, 不适用于本文的数据集; 轻量级网络 GoogleNet 分类准确率和损失函数曲线在前期的表现逊色于基于迁移学习的 DenseNet。

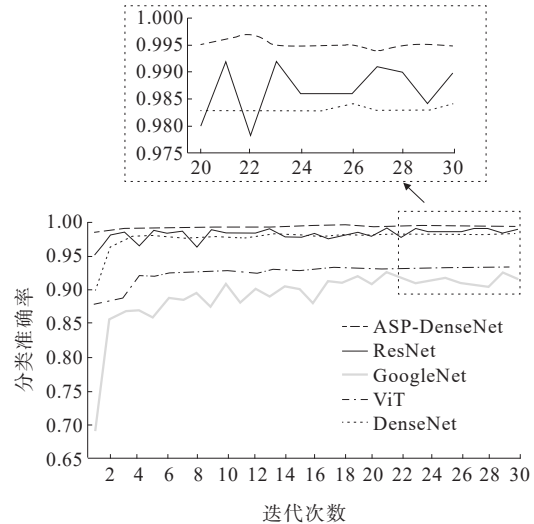


图 9 验证集分类准确率变化曲线

Figure 9 Accuracy curves of validation set classification




图 10 训练损失变化曲线

Figure 10 Curves of training loss

训练结束后依据验证集分类和损失函数曲线,选取表现较优的ResNet、DenseNet和本文所提方法进行测试集的扰动分类,MTF表示的电能质量扰动信号的分类准确率如表2所示,本文所提方法平均Top-1识别精度为99.52%,较ResNet、DenseNet分别高0.72%、0.67%。基于MTF可视化的3种识别框架在单一扰动分类表现均相当精确,本文所提ASP-DenseNet对测试集的100个扰动均正确分类,ResNet和DenseNet模型在电压暂降和电压波动识别中存在误判。

表2 无噪声环境下3种分类框架扰动识别准确率

Table 2 Recognition results of three classification frames in noiseless environment

扰动类型	Top-1 识别准确率/%		
	ResNet	DenseNet	ASP-DenseNet
C <sub>0</sub>	100.00	100.00	100.00
C <sub>1</sub>	98.00	100.00	100.00
C <sub>2</sub>	100.00	100.00	100.00
C <sub>3</sub>	100.00	100.00	100.00
C <sub>4</sub>	100.00	100.00	100.00
C <sub>5</sub>	100.00	100.00	100.00
C <sub>6</sub>	100.00	100.00	100.00
C <sub>7</sub>	99.00	98.00	100.00
C <sub>8</sub>	98.00	100.00	99.00
C <sub>9</sub>	97.00	98.00	100.00
C <sub>10</sub>	95.00	96.00	98.00
C <sub>11</sub>	100.00	96.00	100.00
C <sub>12</sub>	98.00	99.00	99.00
C <sub>13</sub>	98.00	97.00	98.00
C <sub>14</sub>	100.00	98.00	99.00
C <sub>15</sub>	98.00	96.00	100.00
C <sub>16</sub>	100.00	100.00	100.00
C <sub>17</sub>	100.00	100.00	99.00
C <sub>18</sub>	100.00	100.00	100.00
C <sub>19</sub>	98.00	100.00	100.00
C <sub>20</sub>	96.00	98.00	98.00
平均Top-1识别准确率/%	98.80	98.85	99.52

在进行复合扰动识别中,本文所提ASP-DenseNet识别率相较于其他2种识别框架有明显的提升,据此说明ASP-DenseNet中的稠密连接比残差连接可以更好地加深模型深度,提取更加深

层、全面的特征,提高分类精度;采用改进的1D-ASP模块可有效获得各通道之间的依赖关系,提高DenseNet模型的识别精度。此外,在电压暂降/暂升+暂态振荡等扰动复合的情况下,采用本文所提MTF可视化图像预处理,信号时序性特征的提取得到了进一步的提升,在复合扰动识别中具有优良表现,与其他方法<sup>[23]</sup>相比均有提高,由此说明,MTF可视化技术可以精确地提取信号特征并适用于深度学习识别框架中。

5.3 抗噪性测试

考虑大量电子元件等造成的环境噪声,为模拟实际情景,对8种PQDs信号叠加信噪比为20、30 dB的高斯噪声,每种扰动信号包含100个测试样本。8类测试数据的详细分类结果如图11所示,图中的混淆矩阵来自重复实验的典型测试数据。




图11 不同信噪比下单一扰动分类混淆矩阵  
Figure 11 Confusion matrix with single disturbance classification under different SNR

由图11可以看出,分类结果位于混淆矩阵的对角线上,这反映了预测类对应于实际值,由此可见,在高信噪比下单一扰动分类依旧准确稳定,具有较强的抗噪性。

20、30 dB下进行扰动分类重复实验的平均准确率如表3所示,结果表明:在20 dB下本文所提MTF-DenseNet扰动识别法中,除电压暂降( $C_1$ )、电压暂升+谐波( $C_9$ )、电压暂降+暂态振荡( $C_{10}$ )、电压暂升+暂态脉冲( $C_{13}$ )分类准确率小于97.00%外,大多数扰动分类的准确率高达99.00%及以上。在随机噪声的影响下,扰动分类准确率有轻微下

降,特别是在复合扰动中存在暂态振荡、谐波的情况下,本文设置的振荡、谐波转化为MTF,处于高信噪比下与其他扰动相比,在高维相空间中提取特征会出现局部损失,但其复合PQDs识别效果与文献[15]在噪声环境下具有高识别率的卡尔曼滤波法持平,且在单一扰动识别中具有明显优势;与采用可视化轨迹圆结合深度残差连接网络的文献[23]相比,本文在复合扰动识别中识别率略高。由此可见,本文所提方法的整体分类效果优秀、普适性较高,适合于单一和复合扰动信号的大规模识别。

表3 不同噪声环境下3种分类框架的扰动分类结果

Table 3 Recognition results of three classification frames in different noise environment %

类型	20 dB下扰动识别分类 Top-1 识别准确率			30 dB下扰动识别分类 Top-1 识别准确率		
	文献[14]	文献[20]	MTF-DenseNet	文献[14]	文献[20]	MTF-DenseNet
$C_1$	99.00	81.00	96.00	95.00	89.00	98.00
$C_2$	98.00	98.00	100.00	99.00	99.00	100.00
$C_3$	100.00	100.00	98.00	99.00	97.00	98.00
$C_4$	100.00	98.00	97.00	100.00	100.00	99.00
$C_5$	69.00	100.00	99.00	76.00	100.00	99.00
$C_6$	99.00	100.00	100.00	93.00	100.00	100.00
$C_7$	100.00	100.00	99.00	100.00	100.00	99.00
$C_8$	96.00	95.00	98.00	92.00	94.00	100.00
$C_9$	—	89.00	96.00	—	100.00	98.00
$C_{10}$	97.00	81.00	96.00	97.00	82.00	100.00
$C_{11}$	—	94.00	100.00	—	95.00	100.00
$C_{12}$	—	85.00	100.00	—	85.00	100.00
$C_{13}$	—	88.00	96.00	—	100.00	100.00
$C_{14}$	99.00	87.00	97.00	100.00	91.00	99.00
$C_{15}$	100.00	96.00	100.00	100.00	100.00	100.00
$C_{16}$	100.00	100.00	98.00	100.00	100.00	97.00
$C_{17}$	100.00	99.00	100.00	100.00	100.00	100.00
$C_{18}$	95.00	—	99.00	100.00	—	98.00
$C_{19}$	100.00	—	100.00	100.00	—	100.00
$C_{20}$	100.00	—	99.00	99.00	—	98.00
平均 Top-1 识别准确率/%	97.00	93.59	98.40	96.85	96.00	99.20

## 6 结语

本文提出了一种基于MTF和深度学习识别框架进行PQDs分类的新方法。该方法从图像处理后进行识别的角度,利用MTF技术对PQDs信号进行可视化,再采用改进DenseNet进行自主学习,提取图像特

征并完成分类,提出的ASP-DenseNet较原始模型Top-1分类准确率更高。为了验证MTF-DenseNet的性能及抗噪性,对20种扰动信号在无噪声及不同信噪比下进行识别,分类准确率在无噪声环境下高达99.52%,20、30 dB下Top-1精度分别达到98.40%、99.20%,验证了所提方法的高性能和强鲁棒性。



## 参考文献:

- [1] PRAISELIN W J, EDWARD J B. A review on impacts of power quality, control and optimization strategies of integration of renewable energy based microgrid operation[J]. *International Journal of Intelligent Systems and Applications*, 2018, 10(3): 67-81.
- [2] 郑玉平, 吕鹏飞, 李斌, 等. 新型电力系统继电保护面临的问题与解决思路[J]. *电力系统自动化*, 2023, 47(22): 3-15.  
ZHENG Yuping, LÜ Pengfei, LI Bin, et al. Problems faced by relay protection in new power system and their solution ideas[J]. *Automation of Electric Power Systems*, 2023, 47(22): 3-15.
- [3] 汪飞, 全晓庆, 任林涛. 电能质量扰动检测与识别方法研究综述[J]. *中国电机工程学报*, 2021, 41(12): 4104-4121.  
WANG Fei, QUAN Xiaoqing, REN Lintao. Review of power quality disturbance detection and identification methods[J]. *Proceedings of the CSEE*, 2021, 41(12): 4104-4121.
- [4] 罗伟明, 吴杰康, 方梓康, 等. 基于WT和LDC综合算法的电能质量扰动源辨识方法[J]. *供用电*, 2022, 39(10): 58-65+83.  
LUO Weiming, WU Jiekang, FANG Zikang, et al. An identification method for disturbance source of power quality based on WT and LDC synthesis algorithm[J]. *Distribution & Utilization*, 2022, 39(10): 58-65+83.
- [5] SAHU G, DASH S, BISWAL B. Time-frequency analysis of power quality disturbances using synchro extracting transform[J]. *International Transactions on Electrical Energy Systems*, 2020, 30(4): e12278.
- [6] 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.
- [7] KUMAR V, GAWRE S K, KUMAR T. Power quality analysis using wavelet transform: a review[J]. *International Journal of Innovative Research in Science, Engineering and Technology*, 2014, 3(S3): 130-136.
- [8] 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.
- [9] ENSHAEE A, ENSHAEE P. A new S-transform-based method for identification of power quality disturbances [J]. *Arabian Journal for Science and Engineering*, 2018, 43(6): 2817-2832.
- [10] 陈向群, 杨茂涛, 刘谋海, 等. 基于模糊聚类分析的电能质量扰动模式识别方法[J]. *电力科学与技术学报*, 2022, 37(2): 79-85.  
CHEN Xiangqun, YANG Maotao, LIU Mouhai, et al. Disturbance pattern recognition method of power quality based on fuzzy clustering analysis[J]. *Journal of Electrical Power Science and Technology*, 2022, 37(2): 79-85.
- [11] LIU Z, CUI Y, LI W. A classification method for complex power quality disturbances using EEMD and rank wavelet SVM[J]. *IEEE Transactions on Smart Grid*, 2015, 6(4): 1678-1685.
- [12] 陈坚, 刘思议, 金涛. 基于SURE小波阈值消噪和MCEEMD-HHT的低频振荡分析[J]. *高电压技术*, 2020, 46(1): 151-160.  
CHEN Jian, LIU Siyi, JIN Tao. Analysis of low-frequency oscillation based on SURE wavelet threshold de-noising and MCEEMD-HHT method[J]. *High Voltage Engineering*, 2020, 46(1): 151-160.
- [13] 杨晓梅, 罗月婉, 肖先勇, 等. 基于自适应阈值和奇异值分解的电能质量扰动检测新方法[J]. *电网技术*, 2018, 42(7): 2286-2294.  
YANG Xiaomei, LUO Yuewan, XIAO Xianyong, et al. A new detection approach of power quality disturbances based on adaptive threshold and singular value decomposition[J]. *Power System Technology*, 2018, 42(7): 2286-2294.
- [14] BAGHERI A, MARDANEH M, RAJAEI A, et al. Detection of grid voltage fundamental and harmonic components using Kalman filter and generalized averaging method[J]. *IEEE Transactions on Power Electronics*, 2016, 31(2): 1064-1073.
- [15] 陈子璇, 席燕辉, 沈银. 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[J]. *电力系统保护与控制*, 2022, 50(7): 81-90.  
CHEN Zixuan, XI Yanhui, SHEN Yin. Recognition of multiple power quality disturbances based on a Kalman filter and deep belief network[J]. *Power System Protection and Control*, 2022, 50(7): 81-90.
- [16] MAHELA O P, SHAIK A G. Recognition of power quality disturbances using S-transform based ruled decision tree and fuzzy C-means clustering classifiers[J]. *Applied Soft Computing*, 2017, 59: 243-257.
- [17] 刘文浩, 吴毅江, 李文泽, 等. 基于随机决策森林的高压电缆局部放电模式识别[J]. *高压电器*, 2022, 58(6): 165-170.  
LIU Wenhao, WU Yijiang, LI Wenze, et al. Partial discharge pattern recognition of high-voltage cables based on random forest method[J]. *High Voltage Apparatus*, 2022, 58(6): 165-170.
- [18] 任子晖, 王琦. 基于优化DDAGSVM多类分类策略的电

- 能质量扰动识别[J]. 电力系统保护与控制,2018,46(5):82-88.
- REN Zihui, WANG Qi. Power quality disturbance recognition based on improved DDAGSVM multi-class classification strategy[J]. Power System Protection and Control,2018,46(5):82-88.
- [19] KAPOOR R, KUMAR R, TRIPATHI M M. Volterra bound interval type-2 fuzzy logic-based approach for multiple power quality events analysis[J]. IET Electrical Systems in Transportation,2018,8(3):188-196.
- [20] 郭庆来,兰健,周艳真,等. 基于混合智能的新型电力系统运行方式分析决策架构及其关键技术[J]. 中国电力,2023,56(9):1-13.
- GUO Qinglai, LAN Jian, ZHOU Yanzhen, et al. Architecture and key technologies of hybrid-intelligence-based decision-making of operation modes for new type power systems[J]. Electric Power,2023,56(9):1-13.
- [21] 徐敬伟,程杉,严潇,等. 基于WMM与HATF的含噪暂态电能质量扰动检测方法[J]. 电力科学与技术学报,2021,36(4):3-11.
- XU Jingwei, CHEN Shan, YAN Xiao, et al. Noisy transient power quality disturbance detection method based on WMM and HATF[J]. Journal of Electrical Power Science and Technology,2021,36(4):3-11.
- [22] 谢小英,牛益国,于惠慧,等. 基于相空间重构与原子分解的复杂电压暂降特征参数辨识[J]. 电力科学与技术学报,2020,35(5):103-10.
- XIE Xiaoying, NIU Yiguo, YU Huihui, et al. Voltage sag characteristic parameter identification method based on phase space reconstruction and atomic decomposition[J]. Journal of Electrical Power Science and Technology, 2020,35(5):103-10.
- [23] 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):6274-6285.
- 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):6274-6285.
- [24] 武昭旭,杨岸,祝龙记. 基于循环神经网络的电能质量扰动识别[J]. 电力系统保护与控制,2020,48(18):88-94.
- WU Zhaoxu, YANG An, ZHU Longji. Power quality disturbance recognition based on a recurrent neural network[J]. Power System Protection and Control,2020,48(18):88-94.
- [25] 董光德,李道明,陈咏涛,等. 基于粒子群优化与卷积神经网络的电能质量扰动分类方法[J]. 发电技术,2023,44(1):136-142.
- DONG Guangde, LI Daoming, CHEN Yongtao, et al. Power quality disturbance classification method based on particle swarm optimization and convolutional neural network[J]. Power Generation Technology, 2023, 44(1):136-142.
- [26] 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.
- [27] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Virtual, Online, United States, 2020.
- [28] 陈子文. 论文附录[EB/OL]. <https://pan.baidu.com/s/1je9tTpCvbwWeT1jl9vEiVg> (提取码: vb2q), 2023-03-06.
- CHEN Ziwen. Appendix to the paper[EB/OL]. <https://pan.baidu.com/s/1je9tTpCvbwWeT1jl9vEiVg> (extraction code: vb2q), 2023-03-06.
- [29] ZHAO X, SUN H, LIN B, et al. Markov transition fields and deep learning-based event-classification and vibration-frequency measurement for  $\varphi$ -OTDR[J]. IEEE Sensors Journal,2022,22(4):3348-3357.
- [30] HUANG G, LIU Z, VAN DER MAATEN, L, et al. Densely connected convolutional networks[C]//30th IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, United States, 2017.