**引用格式**：刘永强，王金梅，关雪涛，等.基于语谱图和轻量化2D-DSCNN的电能质量扰动识别方法[J].电力科学与技术学报,2025,40(6):147-155.
**Citation**：LIU Yongqiang, WANG Jinmei, GUAN Xuetao, et al. Power quality disturbance recognition method based on spectrogram and lightweight 2D-DSCNN[J]. Journal of Electric Power Science and Technology,2025,40(6):147-155.

# 基于语谱图和轻量化2D-DSCNN的电能质量扰动识别方法

刘永强，王金梅，关雪涛，李　峰
（宁夏大学电子与电气工程学院，宁夏回族自治区 银川市 750021）

**摘　要**：针对复杂电能质量扰动（power quality disturbances，PQDs）信号难以精确分类识别的问题，提出一种基于语谱图和轻量化二维深度可分离卷积神经网络（2 dimensional depthwise separable convolution，2D-DSCNN）的PQDs识别方法。首先，采用时间－频率分析，将PQDs信号转换为语谱图，以图像形式呈现复杂信号数据；其次，采用深度可分离卷积技术，构建轻量级的2D-DSCNN模型，分类识别不同PQDs信号的语谱图；最后，用仿真试验验证所提方法的可行性与有效性。研究结果表明，该方法能有效识别和分类各种PQDs信号，具有较高的准确率和较强的抗噪声能力，且该模型轻量化程度较高，适用于边缘设备部署和实时监控。

**关　键　词**：电能质量扰动信号；二维卷积神经网络；语谱图；深度可分离卷积；扰动信号识别；轻量化神经网络
**DOI**：10.19781/j.issn.1673-9140.2025.06.014　　**中图分类号**：TM60　　**文章编号**：1673-9140(2025)06-0147-09

## Power quality disturbance recognition method based on spectrogram and lightweight 2D-DSCNN

LIU Yongqiang, WANG Jinmei, GUAN Xuetao, LI Feng
(School of Electronic and Electrical Engineering, Ningxia University, Yinchuan 750021, China)

**Abstract**: In response to difficulties in accurately classifying and recognizing complex power quality disturbance (PQD) signals, this paper proposes a novel PQD recognition method based on spectrogram and lightweight two-dimensional (2D) depth-separable convolutional neural network (2D-DSCNN). Time-frequency analysis is applied to convert PQD signals into spectrograms, so that complex signal data is presented in the form of images. A lightweight 2D-DSCNN model is constructed by using depth-separable convolution technology, and the spectrograms corresponding to different PQD signals are classified and identified. The feasibility and effectiveness of the proposed method are verified through simulation experiments. The experimental results show that the method can effectively recognize and classify various PQD signals with high accuracy and strong anti-noise capability, and the model is lightweight, which is suitable for the deployment of edge devices and real-time monitoring.

**Key words**: power quality disturbance signal; two-dimensional convolutional neural network; spectrogram; depth-separable convolution; disturbance signal recognition; lightweight neural network

随着智能电网的快速发展，更多的非线性负荷[1-2]和带有波动性的新能源[3-4]投入电网，这加剧了电能质量扰动（power quality disturbances，PQDs）问题。严重的PQDs可能对电网安全和新能源设备造成损害[5-7]，甚至导致大规模设备脱网。为保障电网的稳定运行，实时监控电网状态，并为扰动源的

**收稿日期**：2025-02-21；**修回日期**：2025-05-16
**基金项目**：国家自然科学基金（52167006）
**通信作者**：王金梅（1968—），女，博士，教授，主要从事新能源并网、电力系统稳定与控制等方面的研究；E-mail：wang_jm@nxu.edu.cn

定位和后续处理提供准确的信息支持，开发高效的PQDs识别方法显得尤为重要。传统的PQDs识别方法主要依赖信号处理技术，其通过预定义的特征提取来识别不同类型的扰动信号，文献[6]提出了一种结合变分模态分解（variational mode decomposition，VMD）与K近邻分类器（K-nearest neighbor，KNN）的识别方法，该方法通过VMD从电压波形中提取特征，并采用了Relief-F特征选择技术。文献[7]提出了一种基于遗传算法（genetic algorithm，GA）的最小二乘支持向量机（least squares support vector machine，LSSVM）的识别算法，该算法采用小波变换处理扰动信号得到特征集。

传统方法处理大规模数据的效率不高且不够灵活。近年来，机器学习特别是深度学习技术的快速发展，为PQDs信号的识别分类提供了新思路。文献[8]提出了基于格拉米角场和图卷积神经网络的识别算法，该算法先将一维PQDs数据转换成二维格拉米角场值密度图，再利用图卷积神经网络进行无监督特征学习，自动提取稀疏数据特征，最后，对这些稀疏数据特征进行分类识别，其识别精度较佳。文献[9]提出了一种多尺度卷积融合时间序列（multi-scale convolution fusion time series transformer，MCF-TST）模型，该模型采用不同尺度的卷积核对信号进行多维特征提取，并结合时间序列，深层次分析扰动信号的局部和全局特征，从而实现PQDs识别。文献[10]提出了一种基于径向基函数神经网络（radial basis function neural network，RBFNN）的电力质量扰动分类算法，该算法通过小波变换提取特征，其所需特征数量较少，且该算法优化了权重更新机制，提升了算法分类性能。这些研究大都关注传统信号处理方法和神经网络结构与类型，但对分析特征提取和特征类型的研究鲜见。

作为一种基于短时傅里叶变换（short time Fourier transform，STFT）的可视化时频表征工具，语谱图在语音识别和机械故障诊断中展现了其对非平稳信号的表征方面的独特优势，但其在电能质量扰动信号分析中的应用仍处于探索阶段。本文提出基于语谱图和轻量化二维深度可分离卷积神经网络（2 dimensional depthwise separable convolutional neural networks，2D-DSCNN）的PQDs信号识别方法，先将PQDs信号转换为语谱图，使信号的时间与频率信息在二维图像中体现，便于深度学习模型进行特征提取和识别；再应用2D-DSCNN模型识别PQDs信号的语谱图，从而实现对扰动的辨别；最后，通过仿真试验来验证所提方法的可行性与有效性。所提方法中的神经网络架构采用了深度可分离卷积，该卷积准确率和计算效率颇高，且实现了模型的轻量化。

## 1 理论基础

### 1.1 二维卷积神经网络

二维卷积神经网络（2 dimensional convolutional neural networks，2D-CNN）是一种在图像和视频处理领域被广泛使用的深度学习架构。2D-CNN通过多个不同的卷积层来自动学习图像的层次特征，从简单的边缘纹理到更复杂的图案元素部分，逐步提取特征[11]，对图像进行深入理解和分析。其二维卷积核沿高度和宽度这两个方向移动，处理图像的空间特征[12]。在这一过程中，网络能捕获图像的空间关系，识别不同的空间排列模式（如形状和纹理等），从而深入理解图像内容。对第$i$层的第$j$个特征图中位于$(x,y)$处的点$v_{ij}^{xy}$的卷积计算式为

$$v_{ij}^{xy}=f\left(\sum_{k=1}^{m}\sum_{l=0}^{L_i-1}\sum_{w=0}^{W_i-1}\omega_{ijk}^{lw}v_{(i-1)k}^{(x+l)(y+w)}+b_{ij}\right) \quad (1)$$

式中，$L_i$和$W_i$分别为二维卷积核的高度和宽度；$\omega_{ijk}^{lw}$为卷积核中的权重；$b_{ij}$为第$i$层的第$j$个特征图的偏置项；$f$为线性激活函数；$m$为卷积层所接收的输入通道数。

卷积操作后，常采用非线性激活函数ReLU等[13]来增加网络的非线性能力，使其能学习更复杂的特征。紧随卷积层之后的通常是池化层，该池化层通过减少特征图的空间尺寸来减少参数数量和计算量，并保留重要特征信息。在经过若干个卷积层和池化层提取和压缩特征后，2D-CNN通常包含数个全连接层。这些全连接层将前面学习到的高级特征映射到最终的输出类别上。每个卷积核和全连接层中的权重和偏置均通过反向传播算法在以最小化预测值与实际标签之间的差异为目标[14]的训练过程中不断调整。

### 1.2 深度可分离卷积神经网络

随着深度学习技术的不断发展，网络模型结构变得越来越复杂，伴随而来的是模型参数数量和计算成本的显著增加[15]。这不仅提高了对存储空间的需求[16]，还延长了网络训练时间，对计算资源提出了更严格的要求。为推动深度学习在更多领域的应用，应开发既准确又轻量级的模型，提高训练

效率，减少对高端计算资源的依赖。

标准的二维卷积操作涉及的参数数量多，计算成本高。谷歌的 MobileNet[17-18] 提出的深度可分离卷积技术为模型轻量化提供了有效的策略。深度可分离卷积特别适用于移动和嵌入式设备上的图像分类任务，其能大幅度缩减模型大小、提高模型运行效率。与传统二维卷积不同，深度可分离卷积将卷积操作分解为 2 个连续的步骤：深度卷积和逐点卷积[19]。在深度卷积阶段，该策略通过在每个输入通道上独立应用 $W \times W$ 的卷积核来提取空间特征，但不改变通道数；在逐点卷积阶段，该策略通过 $1 \times 1$ 的卷积核对所有输入通道的特征进行聚合，增加输出特征图的数量[20]。深度可分离卷积结构如图 1 所示。

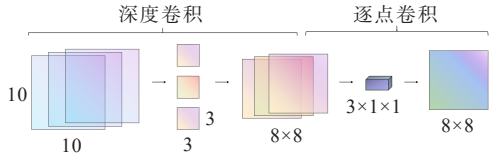


**图 1**　深度可分离卷积结构

**Figure 1**　Depth-separable convolution structure

考虑一个 $3 \times 3$ 的二维卷积核，其输入特征图的通道数为 3，输出特征图的数量为 $N$。在深度可分离卷积中，深度卷积使用 $3 \times 3$ 的卷积核，而逐点卷积使用 $1 \times 1$ 的卷积核。标准二维卷积的参数量为 $27N$，而深度可分离卷积的参数量为 $27+3N$。因此，这 2 种卷积方式的参数量之比为

$$\frac{3 \times 3 \times 3 + 1 \times 1 \times 3 \times N}{3 \times 3 \times 3 \times N} = \frac{1}{N} + \frac{1}{9} \tag{2}$$

这表明，随着输出特征图数量 $N$ 的增加，与标准二维卷积相比，深度可分离卷积具有更少的参数量和计算量，故其效率得以提升[21]。通过这种方式，深度可分离卷积不仅减少了参数量，还维持了在提取图像空间特征方面的优势，这对于构建轻量级和高效的深度学习模型至关重要。

## 2　基于语谱图和轻量化 2D-DSCNN 的识别方法

### 2.1　基于语谱图的特征重构

语谱图是一种将信号的时频特性展现在二维平面上的技术，其被广泛用于增强语音识别系统的性能[22-23]。而 PQDs 信号本质上和语谱信号一样，也是一种随时间变化的序列数据。利用语谱图技术对 PQDs 信号进行处理，可得到不同扰动类型对应的语谱图。通过语谱图，能从 PQDs 信号中提取出丰富的频谱信息，并对信息进行有效的可视化，提取关键特征，对信号特征重构，基于语谱图的扰动特征重构示意图如图 2 所示。

语谱图的生成步骤分为 5 步。

1）选用汉明窗为窗函数。

2）构建离散形式的汉明窗函数，并用集合 $W=\{\omega(0),\omega(1),\cdots,\omega(N-1)\}$ 表示。其中，$\omega(0)$ 为

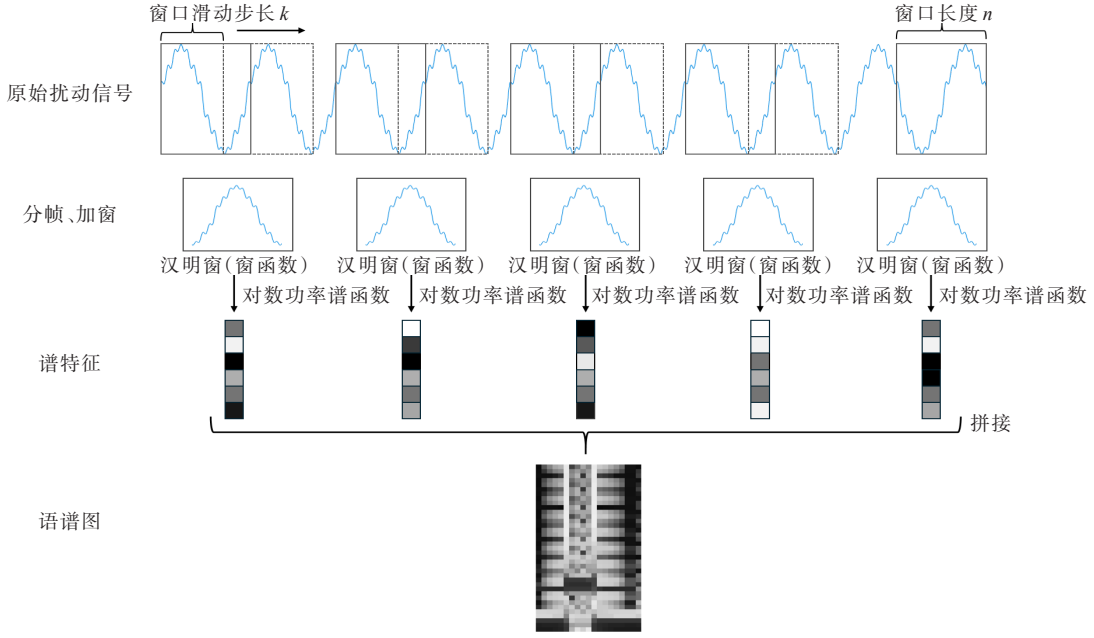


**图 2**　基于语谱图的扰动特征重构示意图

**Figure 2**　Schematic diagram of disturbance feature reconstruction based on spectrogram

$$\omega(0)=0.54-0.46\cos\left(\frac{2\pi n}{N-1}\right) \tag{3}$$

式中，$\omega(n)$为窗函数在第$n$个样本点的值；$N$为窗口的总长度；$n$为窗口内的样本点索引，$n$的取值范围为$0,1,\cdots,N-1$。

3）使用汉明窗函数对原始扰动信号进行加窗处理，即

$$S_x(m,f)=\sum_{n=-\infty}^{\infty}x(n)\omega(n-m)\mathrm{e}^{-j2\pi fn} \tag{4}$$

式中，$S_x(m,f)$为在时间帧$m$和频率$f$下信号$x$的STFT值；$m$为当前帧的中心点索引；$x(n)$为输入的离散时间信号。

4）将$S_x(m,f)$转化为谱特征$P_x(t,f)$，该值可表征在时间和频率下信号的语谱图强度，即

$$P_x(t,f)=10\log_{10}\left(\left|S_x(m,f)\right|^2\right) \tag{5}$$

5）通过谱特征绘制出语谱图。

采用汉明窗作为窗函数，能减少频谱泄露和边缘效应，提高语谱图质量。汉明窗通过平滑信号的边缘来优化频谱分析，平衡了主瓣宽度和旁瓣高度，适合复杂频谱的信号分析[24]。在STFT中，快速傅里叶变换（fast Fourier transform，FFT）点数设置为72，以获得足够的频率分辨率，并保证足够的计算效率。时间点数设为19，这能在保持较好时间分辨率的同时，有效控制数据量和处理时间。12种电能质量扰动信号语谱图如图3所示。

图3为单一类型PQDs信号和复合类型PQDs信号的语谱图。在图3中，该生成语谱图高度为37，宽度为19，总共包含703个像素点。语谱图中，水平轴代表时间，垂直轴代表频率，各像素的深浅程度对应信号的幅度大小。语谱图深色区域为其高频部分，浅色区域为其低频部分。通过将原始PQDs信号映射到语谱图中，实现了从时域到时频域的数据转换，信号中的特征得到了有效的归纳和重组。

从图3中可以看出不同扰动信号在语谱图中的特征：暂降与中断扰动区的亮度暗于正常区域的亮度；暂升扰动区亮度明显提升；谐波扰动区的高频成分随谐波阶数增加而增强，底部深色高频部分扩大；振荡扰动区频率和幅度同步增加，其表现为亮度提升与高频部分扩大；波动扰动区幅度不稳定导致亮度明暗交替变化；“谐波＋暂降”扰动区的高频部分扩大且亮度降低；“谐波＋暂升/脉冲”扰动区的高频部分扩大且亮度提升；“振荡＋暂降”扰动区的频率和幅度同步增加且亮度降低；“谐波＋暂降＋波动”的扰动区存在高频部分扩大、亮度降低和明暗波动的情况。显然，不同PQDs语谱图可明显区分不同类型的PQDs信号。

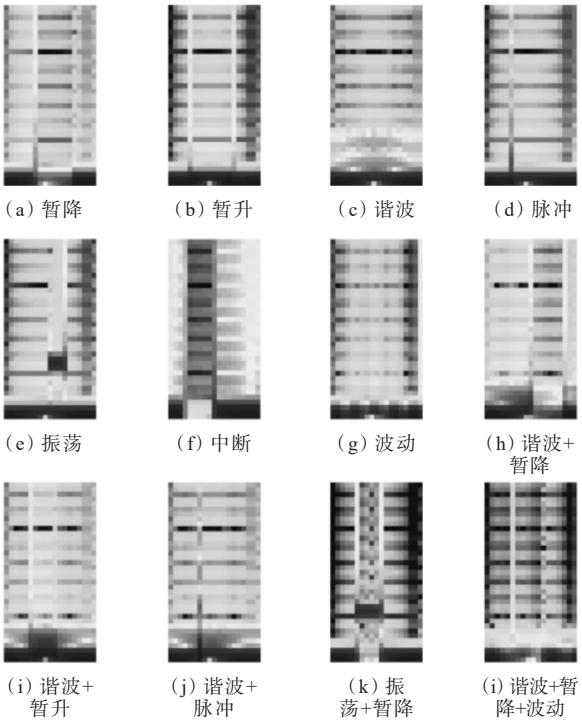


**图3** 12种电能质量扰动信号语谱图

**Figure 3** Spectrograms of 12 kinds of PQD signals

## 2.2 建立二维深度可分离卷积神经网络

二维卷积神经网络结构示意图如图4所示。在图4中，$a\times b\times c$表示该层的高度为$a$，宽度为$b$，通道数为$c$，而对于密接层，$c$表示该层有$c$个神经元，不同深浅代表不同种类的层。

从图4中可以看出，该网络包含6个数据处理层。首先，将深度可分离卷积、批量归一化和ReLU激活函数合并为一个自定义层（ConvBNReLU），在简化模型结构的同时，提高效率。其次，为减少参数和计算量，自定义层内使用了深度可分离卷积。第一个自定义层中，卷积层的卷积核大小为$2\times 2$，通道数为4。第一个自定义层后连接第一个最大池化层，池化窗口为$2\times 2$，最大池化层可以选出区域中最重要的信息[25]，减少计算量，提高网络对小变化的不变性。第二个自定义层接在第一个最大池化层之后，通道数为8，后面同样连接第二个最大池化层。最后，在第二个最大池化层后连接Flatten层和Dense层。

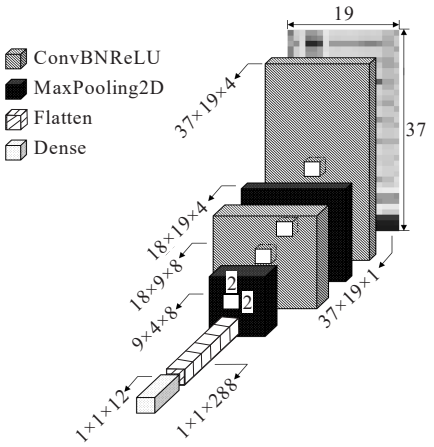


**图 4**　二维卷积神经网络结构示意图

**Figure 4**　Schematic diagram of 2D convolutional neural network structure

## 3　仿真试验结果

### 3.1　数据集生成

数据集由训练集和验证集组成。为模拟实际电网中扰动情况，选择 IEEE Std. 1159[26] 提供的数学模型，该模型由 MATLAB 2023 生成，包括单种扰动和多种复合扰动共 12 种类型。其中，单扰动共 7 种：电压暂降（$C_1$）、电压暂升（$C_2$）、中断（$C_3$）、波动（$C_4$）、脉冲（$C_5$）、振荡（$C_6$）、谐波（$C_7$）。复合扰动共 5 种：谐波暂降（$C_8$）、谐波暂升（$C_9$）、谐波脉冲（$C_{10}$）、振荡暂降（$C_{11}$）、谐波暂降波动（$C_{12}$）。对于每种类型的扰动信号，修改扰动信号的参数，随机得到 1 000 个不同的扰动信号，生成 1 000 张不同的语谱图，这 12 种扰动类型共有 12 000 张语谱图作为训练集。通过对扰动信号扩展扰动参数范围、轻微时移等操作，生成每种类型 100 张语谱图。这 12 种扰动类型共有 1 200 张语谱图作为验证集。

为模拟实际电网中复杂的噪声场景，引入 5 种噪声：非高斯噪声（$\alpha$ 稳定分布）、非高斯噪声（随机脉冲）、时变噪声（逐渐变大）、时变噪声（周期脉冲）和高斯噪声，含有 5 种噪声的扰动信号如图 5 所示。

对验证集扰动信号添加不同类型噪声信号并进行语谱图转换，得到含噪扰动信号识别仿真试验验证集，含噪声扰动信号语谱如图 6 所示。

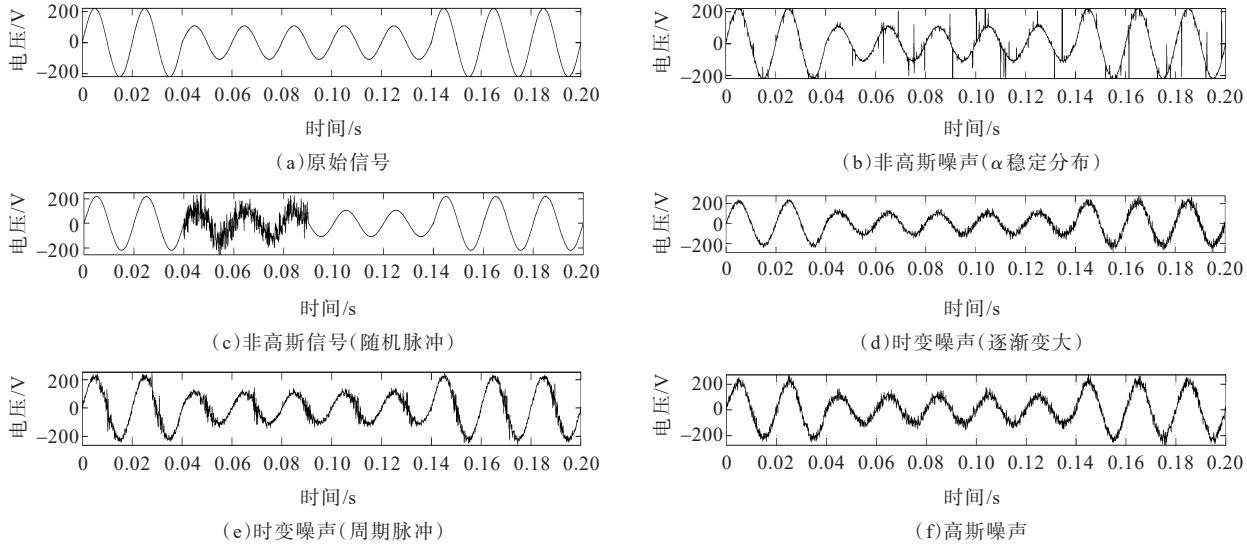


**图 5**　含有 5 种噪声的扰动信号

**Figure 5**　A disturbed signal with 5 types of noise

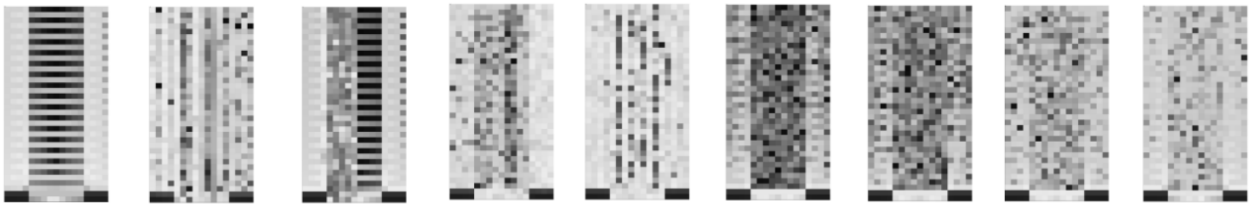


**图 6**　含噪声扰动信号语谱

**Figure 6**　Spectrograms of disturbed signals with noise

从图 6 中可以看出，在将含有各种噪声的暂降扰动信号转换为语谱图后，暂降扰动开始后的语谱图颜色变暗，这说明其仍能展现扰动特征。

### 3.2 训练二维深度可分离卷积神经网络

使用训练集对神经网络进行批次训练，批次大小设置为 32，每一轮参与训练的样本总数为 12 000，每轮的迭代次数为 375。训练使用 Adam 优化器，初始学习率设置为 0.001。损失函数为 categorical_crossentropy。准确率和损失率随轮次变化的过程如图 7 所示。

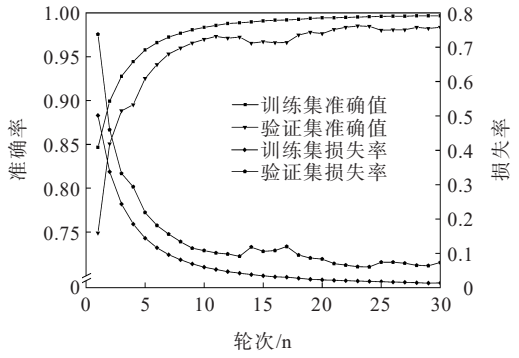


**图 7** 准确率和损失率随轮次变化的过程

**Figure 7** Variations of accuracy and loss rate with epoch

从图 7 中可以看出，当训练至 20 轮次左右时，训练集准确率趋于 1，损失率收敛于 0。这说明该模型训练成功，且其识别准确率较高。

训练完的模型仅包含 3 468 个参数，程序大小仅为 14.00 kB，实现了模型的轻量化。

### 3.3 识别结果

使用验证集对训练好的神经网络模型进行验证测试。为测试方法的识别准确性和抗噪性能，仿真分别生成无噪声和信噪比分别为 50、40、30 和 20 dB 的扰动信号验证集。使用 2D-CNN 模型进行验证测试，得到每种扰动类型的预测输出。预测准确率用来评估模型在实际应用中预测未知数据的能力。不同信噪比下的分类性能见表 1。由表 1 可知，2D-CNN 模型在无噪声、50、40、30、20 dB 信噪比场景下的所有验证集的平均验证准确率分别为 98.13%、95.58%、91.17%、85.54%、79.25%，且对于所有扰动类型均具有良好的识别准确率。这说明该模型具有良好的适应性和较强的抗干扰能力。

为进一步验证该模型的性能，对引入非高斯噪声和时变噪声的扰动信号语谱图进行识别分类仿真实验，通过对扰动信号在信噪比分别为 50、40、30 和 20 dB 的场景下进行分类识别试验，不同信噪比下的分类性能见表 2。

**表 1** 不同信噪比下的分类性能

**Table 1** Classification performance under different signal-to-noise ratios

| 信噪比/dB | 单类扰动/% | | | | | | | 复合扰动/% | | | | |
|---|---|---|---|---|---|---|---|---|---|---|---|---|
| | $C_1$ | $C_2$ | $C_3$ | $C_4$ | $C_5$ | $C_6$ | $C_7$ | $C_8$ | $C_9$ | $C_{10}$ | $C_{11}$ | $C_{12}$ |
| 0 | 100.00 | 100.00 | 99.00 | 100.00 | 100.00 | 98.50 | 97.00 | 99.00 | 85.50 | 100.00 | 99.00 | 99.50 |
| 50 | 99.50 | 100.00 | 97.50 | 98.00 | 100.00 | 98.50 | 95.50 | 96.00 | 84.50 | 98.00 | 83.00 | 96.50 |
| 40 | 95.50 | 96.00 | 96.50 | 92.50 | 93.50 | 93.50 | 90.00 | 91.50 | 84.00 | 92.50 | 77.50 | 91.00 |
| 30 | 87.50 | 88.00 | 90.50 | 86.50 | 87.50 | 91.00 | 85.50 | 84.00 | 80.50 | 86.00 | 76.50 | 83.00 |
| 20 | 79.50 | 80.50 | 84.00 | 79.50 | 81.50 | 85.00 | 78.50 | 78.00 | 79.50 | 81.50 | 71.00 | 72.50 |

**表 2** 不同噪声下分类准确率随信噪比的变化

**Table 2** Changes in classification accuracy with signal-to-noise ratio under different noise conditions

| 信噪比/dB | 非高斯噪声/% | | 时变噪声/% | |
|---|---|---|---|---|
| | α稳定分布 | 随机脉冲 | 逐渐变大 | 周期脉冲 |
| 50 | 85.25 | 96.42 | 92.50 | 93.08 |
| 40 | 83.16 | 93.08 | 88.08 | 88.33 |
| 30 | 79.33 | 86.92 | 85.58 | 86.75 |
| 20 | 77.16 | 85.08 | 83.16 | 82.42 |

由表 2 可知，各类噪声场景下的平均分类准确率分别为：α稳定分布噪声 81.23%，随机脉冲噪声 90.38%，逐渐变大时变噪声 87.33%，周期脉冲时变噪声 87.65%。在非高斯噪声场景下，随机脉冲为短暂脉冲噪声，其对语谱图干扰较小，其识别效果较好，其识别率均值为 90.38%。α稳定分布噪声大小和时间随机，其识别效果一般，但仍能保持 81.23% 的总识别率。在这两种时变噪声场景下，语谱图在噪声干扰后仍能较好地保留特征，总体识别率分别

保持在 87.5% 左右，识别效果良好。

### 3.4　不同轻量化神经网络模型对比

轻量化神经网络既对模型的大小有要求，也要求模型的识别准确率保持在较高水准之上。本文分别使用 2D-DSCNN、卷积神经网络（convolutional neural network，CNN）、ShuffleNet 神经网络、Xception 神经网络对训练集进行训练，并使用验证集进行测试，不同神经网络模型对比见表 3。不同神经网络模型混淆矩阵对比如图 8 所示。

由表 3 可知，CNN 通过经典局部特征提取，性能均衡但资源消耗较高，准确率为 97.417%。ShuffleNet 通过通道混洗增加特征交互，但复杂通道交互设计导致参数量大且需要权衡复杂度，模型参数比 2D-DSCNN 高了 922.29 kB。Xception 神经网络为基于 Inception 的极端版本，其参数量较小但识别精度较差，准确率仅为 89.917%。而 2D-DSCNN 通过分解卷积操作，参数数量和模型大小均为最小，且识别成功率为 98.080%，识别性能最佳。

**表 3**　不同神经网络模型对比

**Table 3**　Comparison of different neural network models

| 模型 | 模型参数数量 | 模型大小/kB | 准确率/% |
|---|---|---|---|
| 2D-DSCNN | 3 584 | 14.00 | 98.080 |
| CNN | 8 268 | 32.30 | 97.417 |
| ShuffleNet 神经网络 | 239 690 | 936.29 | 96.417 |
| Xception 神经网络 | 15 884 | 62.05 | 89.917 |

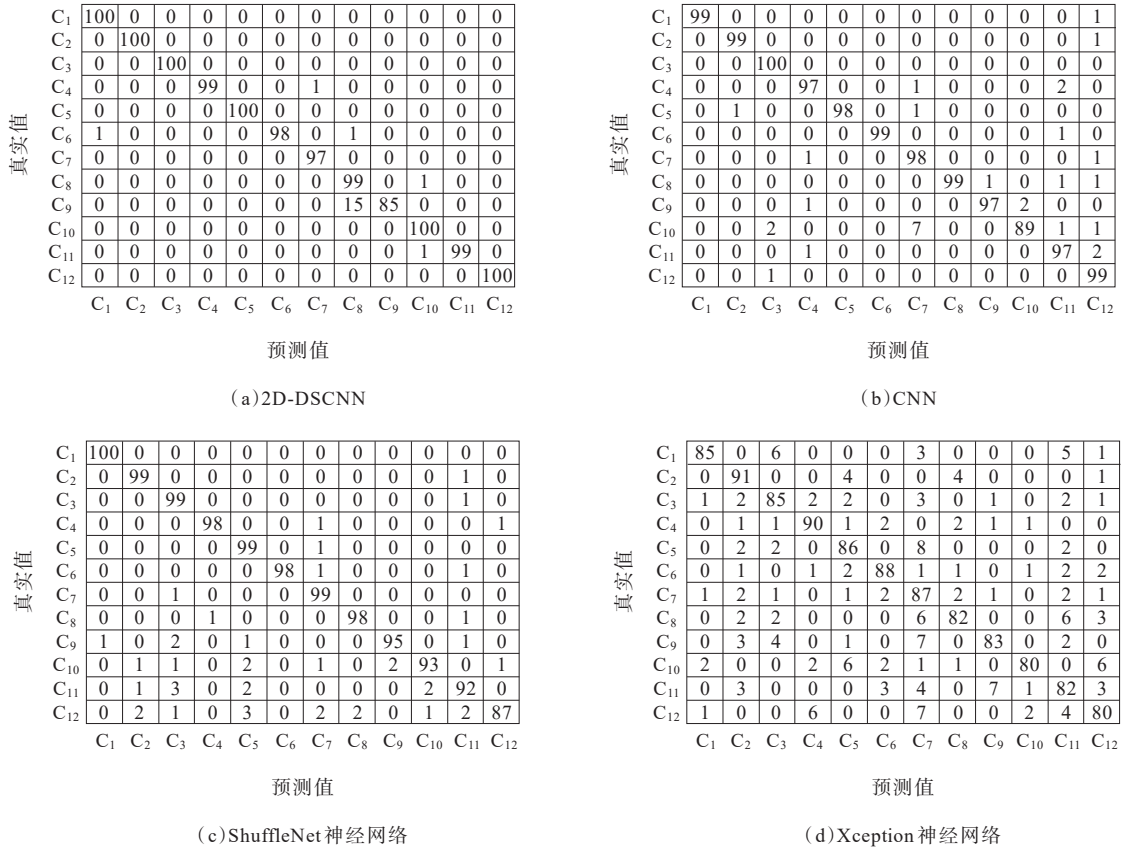


（a）2D-DSCNN　（b）CNN

（c）ShuffleNet 神经网络　（d）Xception 神经网络

**图 8**　不同神经网络模型混淆矩阵对比

**Figure 8**　Comparison of confusion matrices of different neural network models

从图 8 中可以看出，经过模型识别，2D-DSCNN 验证集 1 200 张图片成功识别 1 177 张，总体验证成功率为 98.08%。其中，暂升、暂降、波动、脉冲、谐波、中断、谐波＋暂降扰动识别效果最好。对比其他模型，所提方法误分类样本相对较少，且在复合扰动类型的识别中优势明显。

### 3.5　电能质量扰动信号识别算法对比

为进一步验证基于语谱图和 2D-DSCNN 识别方法的识别性能，选择传统电能质量扰动信号识别方法和同样基于神经网络的分类识别方法进行对比，将其与基于 S 变换的识别方法、基于 S 变换＋希尔伯特－黄变换（Hilbert-Huang transform，HHT）

的识别方法和离散小波变换(discrete wavelet transform,DWT)+径向基函数神经网络(radial basis function neural network,RBFNN)方法[10]进行对比试验,试验结果如图9所示。

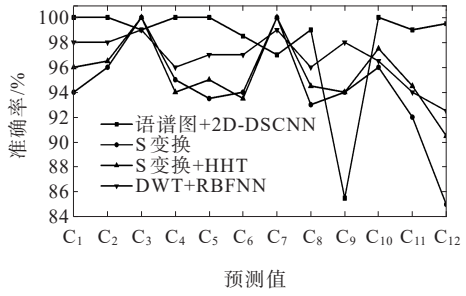


**图9** 识别分类方法仿真实验对比

**Figure 9** Comparison of simulation experiments of recognition and classification methods

从图9中可以看出,基于语谱图和轻量化2D-DSCNN的识别方法对于大部分扰动类型的识别性能优于其他3种方法的,对于复合类型扰动尤其明显。这4种方法总识别率分别为98.08%、94.38%、95.50%、96.75%,基于语谱图和2D-DSCNN识别方法总体识别率最高,适合电能质量扰动信号实时监测。

## 4 结语

本文提出了一种基于语谱图和轻量化2D-DSCNN的PQDs信号识别方法。将复杂PQDs信号转换为语谱图,使得信号的时间和频率信息在二维图像中体现,通过深度可分离卷积实现神经网络模型的轻量化,利用模型识别PQDs信号对应语谱图实现扰动识别。主要结论如下:

1)基于语谱图和轻量化2D-DSCNN的PQDs信号识别方法精准识别了不同的PQDs信号,不仅保持了较高的识别性能,还具备良好的泛化能力。

2)在不同噪声类型及信噪比条件下的测试。结果表明,该方法具有良好的抗噪性和适应性,即使在较低信噪比的情况下也能保持较高的识别准确率。

3)相比其他轻量级神经网络,2D-DSCNN在识别准确率、模型大小和模型数量上都具有更好的性能。对比其他电能质量扰动信号识别方法,基于语谱图和轻量化2D-DSCNN识别方法拥有最佳的识别效果,表明该方法识别性能优秀,且适合部署在边缘设备上,实现实时PQDs监测和分类。

**参考文献:**

[1] 刘瑞平,袁亮,胡铭欣,等.含构网型新能源发电单元的孤立电网暂态稳定性提升策略[J].电力科学与技术学报,2024,39(6): 152-161.
LIU Ruiping,YUAN Liang,HU Mingxin,et al.A transient stability improvement strategy of isolated power grids with grid-forming-based renewable energy power generation units[J]. Journal of Electric Power Science and Technology,2024,39(6): 152-161.

[2] 林涛,林政阳,李晨,等.基于TCN的跟网/构网混合型新能源场站并网系统小干扰稳定性快速评估[J].电力科学与技术学报,2024,39(4): 169-177.
LIN Tao, LIN Zhengyang, LI Chen, et al. Small signal stability assessment of grid-connected system for grid-following/grid-forming hybrid new energy stations based on TCN[J]. Journal of Electric Power Science and Technology,2024,39(4): 169-177.

[3] XU W G, WANG J K, JI S P. Study on overvoltage suppression method of phase modulation of hydroelectric generating units and its cooperative optimization in new energy grid[J]. Journal of Physics: Conference Series,2024,2728(1): 012015.

[4] 张岩,杨晓辉.计及源荷灵活协调响应和氢能精细化利用的区域综合能源系统低碳优化[J].电力科学与技术学报,2025,40(4): 217-232.
ZHANG Yan, YANG Xiaohui. Low-carbon optimization of regional integrated energy systems considering flexible and coordinated source-load response and refined utilization of hydrogen energy[J]. Journal of Electric Power Science and Technology, 2025, 40(4): 217-232.

[5] 张可儿,包继刚.基于光伏新能源系统无功接入和谐波研究[J].电力电子技术,2021,55(4): 111-114.
ZHANG Keer, BAO Jigang. Research on reactive power access and harmonic based on photovoltaic new energy system[J].Power Electronics,2021,55(4): 111-114.

[6] BEHZADI M, ASKARI M T, AMIRAHMADI M, et al. Dual identification of multi-complex and non-stationary power quality disturbances using variational mode decomposition in hybrid modern power systems[J]. Arabian Journal for Science and Engineering, 2022, 47 (11): 14389-14409.

[7] 彭宇文,李瑞,李沁雪,等.基于小波变换和GA-LSSVM的电能质量扰动识别与分类[J].黑龙江电力,2023,45(1): 1-9.
PENG Yuwen, LI Rui, LI Qinxue, et al. Identification and classification of power qualifications based on wavelet transform and GA-LSSVM[J]. Heilongjiang Electric Power,2023,45(1): 1-9.

[8] 牛罡,张凯,郭祥富,等.格拉米角场和图卷积神经网络识别复杂电能质量扰动[J].中国测试,2022,48(7): 169-176.
NIU Gang, ZHANG Kai, GUO Xiangfu, et al. Complex power quality disturbance identification based on Gramian angular field and graph convolution neural

network[J]. China Measurement & Test, 2022, 48(7): 169-176.

[9] 李贝奥,李开成,肖贤贵,等.基于多尺度卷积融合时间序列 Transformer 的复合电能质量扰动识别[J].电网技术,2025,49(6): 2511-2520.
LI Beiao, LI Kaicheng, XIAO Xiangui, et al. Compound power quality disturbances identification based on multi-scale convolution fusion time series transformer[J]. Power System Technology,2025,49(6): 2511-2520.

[10] KANIRAJAN P, SURESH KUMAR V. Power quality disturbance detection and classification using wavelet and RBFNN[J]. Applied Soft Computing, 2015, 35: 470-481.

[11] SHAH A A,MALIK H A M,MUHAMMAD A,et al.Deep learning ensemble 2D CNN approach towards the detection of lung cancer[J]. Scientific Reports, 2023, 13 (1): 2987.

[12] 谢锋云,汪淦,王玲岚,等.STFT 结合 2D CNN-SVM 的齿轮箱故障诊断方法[J].噪声与振动控制,2024,44(4): 103-109.
XIE Fengyun, WANG Gan, WANG Linglan, et al. Fault diagnosis method of gearbox based on STFT and 2DCNN-SVM[J]. Noise and Vibration Control, 2024, 44 (4): 103-109.

[13] 王坚坚,廖与禾,杨磊,等.基于多维复向特征融合与 CNN-GRU 的转子不平衡量识别方法[J].中国机械工程,2025,36(9): 1905-1915.
WANG Jianjian, LIAO Yuhe, YANG Lei, et al. Rotor unbalance recognition based on multidimensional complex feature fusion and CNN-GRU[J]. China Mechanical Engineering,2025,36(9): 1905-1915.

[14] 廖玉诚,赵建华,安士杰,等.基于 2DCNN 的柴油机供油提前角异常故障诊断[J].兵器装备工程学报,2021,42 (5): 250-255.
LIAO Yucheng, ZHAO Jianhua, AN Shijie, et al. Fault diagnosis of abnormal diesel engine fuel supply advance angle based on 2DCNN[J]. Journal of Ordnance Equipment Engineering,2021,42(5): 250-255.

[15] 段宇晨,方振宇,郑江滨.神经网络轻量化综述[J].计算机科学与探索,2025,19(4): 835-853.
DUAN Yuchen,FANG Zhenyu,ZHENG Jiangbin.Review of neural network lightweight[J]. Journal of Frontiers of Computer Science and Technology,2025,19(4): 835-853.

[16] 曹希彧,陈鑫,魏同权.基于 RISC-V 的深度可分离卷积神经网络加速器[J].计算机学报,2024,47(11): 2536-2551.
CAO Xiyu, CHEN Xin, WEI Tongquan. Efficient accelerator for depthwise separable convolutional neural networks based on RISC- V [J]. Chinese Journal of Computers,2024,47(11): 2536-2551.

[17] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications[EB/OL]. (2017-04-17) [2024-10-20]. http://doi.org/10.4850/ arXiv.1704.04861.

[18] 叶武剑,谢林峰,刘怡俊,等.基于 MobileNet 的轻量化云检测模型[J].自然资源遥感,2025,37(3): 95-103.
YE Wujian, XIE Linfeng, LIU Yijun, et al. A MobileNet-based lightweight cloud detection model[J]. Remote Sensing for Natural Resources,2025,37(3): 95-103.

[19] 高鹏,刘嘉良,栾军,等.基于 MobileNet 的电缆局部放电模式识别方法[J].电子设计工程,2023,31(21): 93-98.
GAO Peng, LIU Jialiang, LUAN Jun, et al. Partial discharge pattern recognition method of cable based on MobileNet[J]. Electronic Design Engineering, 2023, 31 (21): 93-98.

[20] BARADARAN F, FARZAN A, DANISHVAR S, et al. Customized 2D CNN model for the automatic emotion recognition based on EEG signals[J].Electronics,2023,12 (10): 2232.

[21] 温博阁.基于深度可分离卷积的多目标追踪神经网络研究[J].大连交通大学学报,2021,42(5): 111-114.
WEN Boge. Multi-target tracking neural network based on depthwise separable convolutions[J]. Journal of Dalian Jiaotong University,2021,42(5): 111-114.

[22] 姜囡,庞永恒,高爽.基于注意力机制语谱图特征提取的语音识别[J].吉林大学学报(理学版),2024,62(2): 320-330.
JIANG Nan, PANG Yongheng, GAO Shuang. Speech recognition based on attention mechanism and spectrogram feature extraction[J]. Journal of Jilin University (Science Edition),2024,62(2): 320-330.

[23] 段云,邵玉斌,龙华,等.基于非线性语谱图联合判决的语种识别[J].微电子学与计算机,2024,41(5): 99-108.
DUAN Yun, SHAO Yubin, LONG Hua, et al. Language identification based on joint decision of nonlinear spectrograms[J]. Microelectronics & Computer, 2024, 41 (5): 99-108.

[24] 徐全,于力,袁智勇,等.基于多级自校验和多重切换的自适应相量算法[J].南方电网技术,2019,13(4): 18-24+36.
XU Quan, YU Li, YUAN Zhiyong, et al. Adaptive phasor algorithm based on multi-self-calibration and multi-switching[J]. Southern Power System Technology, 2019, 13(4): 18-24+36.

[25] 肖白,黄钰茹,姜卓,等.数据匮乏场景下采用生成对抗网络的空间负荷预测方法[J].中国电机工程学报,2020, 40(24): 7990-8001+8236.
XIAO Bai,HUANG Yuru,JIANG Zhuo,et al.The method of spatial load forecasting based on the generative adversarial network for data scarcity scenarios[J]. Proceedings of the CSEE,2020,40(24): 7990-8001+8236.

[26] IEEE. IEEE recommended practice for monitoring electric power quality: IEEE Std 1159-2019[S/OL]. [2024-10-20]. https://ieeexplore. ieee. org/document/ 8796486.