

基于深度频域注意力网络的复合电能质量扰动识别方法

刘禹彤¹, 苏小玲², 刘可¹, 韩俊¹, 张文倩¹, 郭菡¹, 王少飞¹

(1. 国网青海省电力公司电力科学研究院, 西宁 810008; 2. 青海大学能源与电气工程学院, 西宁 810016)

摘要: 针对复合电能质量扰动(power quality disturbance, PQD)识别中的特征混叠问题, 基于离散余弦变换(discrete cosine transform, DCT)构建频域解耦层作为深度网络的输入层, 提出了一种适用于复合PQD识别的深度频域注意力网络(deep frequency attention network, DFAN)。首先, 基于DCT理论构建频域解耦层模块对PQD信号进行分解, 减少不同扰动之间的特征混叠。其次, 将不同频率的PQD分量作为多个通道输入, 结合卷积层提取包含不同频率信息的高维特征。同时, 采用注意力机制为每个频率通道自适应的分配权重, 实现频率分量选择和噪声去除。最后, 对所提频域解耦层的计算过程进行优化, 将部分参数在构建网络时计算并保存到网络结构中, 避免在网络训练的正向传播过程中反复计算, 减少网络的训练时间。仿真实验表明, 相比于其他常见PQD识别方法, 所提方法能有效处理多种PQD的混合问题, 对复合PQD识别的精度更高。

关键词: 电能质量; 频域信号分解; 注意力机制; 深度学习

Method for Identifying Composite Power Quality Disturbances Based on Deep Frequency Attention Network

LIU Yutong¹, SU Xiaoling², LIU Ke¹, HAN Jun¹, ZHANG Wenqian¹, GUO Han¹, WANG Shaofei¹

(1. Qinghai Electric Power Test and Research Institute, Xining 810008, China; 2. School of Energy and Electrical Engineering of Qinghai University, Xining 810016, China)

Abstract: In response to the problem of feature aliasing in the recognition of composite power quality disturbances (PQD), this paper constructs a frequency decoupling layer based on discrete cosine transform (DCT) as the input layer of the deep network, and a deep frequency attention network (DFAN) suitable for composite PQD recognition is proposed. Firstly, based on DCT theory, a frequency domain decoupling layer is constructed to decompose the PQD signal, reducing feature aliasing between different disturbances. Secondly, PQD components with different frequencies are used as input for multiple channels, and high-dimensional features containing different frequency information are extracted using convolutional layers. Then, attention mechanism is used to adaptively allocate weights for each frequency channel, achieving frequency component selection and noise removal. Finally, the calculation process of the proposed frequency domain decoupling layer is optimized. Some parameters are calculated and saved in the network structure during network construction, which avoids repeated calculations during the forward propagation process of network training and reduces the training time of the network. The simulation experiments show that compared to other common PQD recognition methods, the proposed method can effectively handle the mixed problem of multiple PQDs, and has higher accuracy in identifying composite PQDs.

Key words: power quality; frequency domain signal decomposition; attention mechanism; deep learning

基金项目: 国家自然科学基金资助项目(52167022); 青海省基础 Research 计划项目(2022-ZJ-935Q)。

Foundation item: Supported by the National Natural Science Foundation of China (52167022); the Basic Research Priorities Program of Qinghai Province(2022-ZJ-935Q).

0 引言

近年来,随着新能源的快速发展,越来越多的分布式电源、微电网系统等并入电力系统^[1-2]。各种分布式新能源包含的大量电力电子变换设备如光伏逆变器等给带来了大量非线性和波动性干扰^[3-4]。相比于传统电力系统,现代电网发生各种电能质量扰动(power quality disturbance, PQD)问题更加频繁,对电力系统的稳定安全运行造成严重影响^[5]。为了对电能质量扰动采取针对性的治理措施,准确识别出各类扰动十分关键。

复合 PQD 由多种不同的单一扰动相互叠加而成,比单一 PQD 更加复杂。由于不同 PQD 之间的特征混叠,准确识别全部扰动事件十分困难^[6-7]。为了准确识别复合 PQD,现有研究主要对 PQD 特征提取方法进行了改进。

传统 PQD 特征提取主要通过对 PQD 信号的时频特性分析提取时域和频域特征。文献[8]利用基于数学形态学提取 PQD 的幅值突变信息,是一种时域特征提取方法。文献[9]采用短时傅里叶变换弥补了傅里叶变换无法获取时频特性的缺点。文献[10]和[11]分别将小波变换和 S 变换及其改进算法用于 PQD 识别,能有效提取 PQD 信号的幅频特性。文献[10]将变分模态分解用于 PQD 分类中取得良好的效果,但难以避免模态混叠问题。文献[12-15]采用变分模态分解等信号分解方法对复合 PQD 进行分解,有效缓解了复合 PQD 特征混叠,进一步提高了复合 PQD 的识别精度。然而,上述方法仍需人工选择扰动特征,难以选择最优的特征组合。

近年来,许多研究者将各种端到端的深度学习方法应用到 PQD 识别中,实现了 PQD 特征的自动提取,取得了很多先进的研究成果^[16-21]。文献[16]和[17]分别采用长短时记忆网络(long short term memory, LSTM)和卷积神经网络(convolutional neural network, CNN)对 PQD 信号进行识别,有效提升了识别精度。文献[18]在卷积神经网络的基础上提出一种软阈值去噪模块,提升了在复杂噪声环境下的电能质量扰动识别精度。文献[19-20]基于格拉姆角场首先将 PQD 信号转换为二维图像,再采用卷积网络提取特征,所提方法具有较强的特征提取能力。上述深度学习方法实现了 PQD 特征的自动提取,有效提高了识别精度。但这类方法仅关

注 PQD 信号波形的时域特征,忽略了同样重要的频域信息,受不同 PQD 之间特征混叠的影响较大。文献[22]在深度识别模型之前采用时频分析方法提取 PQD 频域特征,有效利用了频域信息,但该方法依然依赖人工特征提取,而非能自动提取扰动特征的端到端深度网络模型。

基于上述分析,本文将频域特征提取过程直接设计在网络层中,提出一种能充分利用扰动频域信息的端到端模型:深度频域注意力网络(deep frequency attention network, DFAN)。首先,从理论上论证了采用离散余弦变换(discrete cosine transform, DCT)分解复合 PQD 信号对缓解不同扰动之间特征混叠问题的有效性。接着,基于深度学习框架将 DCT 变换过程构建为独立的频域解耦模块,作为深度识别模型的输入层。输入的 PQD 信号经频域解耦模块转化为不同频率通道的信号分量,每个通道对应不同的频率范围,从而实现不同扰动的特征解耦。最后,采用注意力机制为每个通道的信号分量分配权重,通过训练自适应的选择最有益于 PQD 识别的通道分量、去除冗余特征及噪声通道。仿真实验结果表明,相比于现有 PQD 识别方法,所提方法在不同噪声环境下对多种复合 PQD 具有更高的识别精度和更强的鲁棒性。

1 基于 DCT 的 PQD 信号分解

复合 PQD 信号由多种单一扰动组合而成,其特征的相互混叠导致识别出全部扰动十分困难。对于复合 PQD 信号,其特征混叠主要发生在时域波形上。例如,谐波和暂态振荡的波形叠加在一起时,由于暂态振荡持续时间短且振荡幅度快速衰减,其在时域波形上的特征容易被谐波掩盖。然而,由于 PQD 中谐波和振荡的频率往往差距较大,二者在频谱上的差距也很大,因此可以从频域对二者进行解耦。PQD 频域解耦的基本思路是对时域 PQD 信号进行离散傅里叶变换,得到信号频谱,然后对频谱的不同频率范围分别进行逆变换,得到包含不同频率信息的 PQD 信号分量。由于傅里叶变换包含复数运算,难以构建网络层插入到深度网络中。而离散余弦变换作为傅里叶变换的一种特殊形式,其加权和形式和神经网络中常用的均值池化层类似,可以视作带有权重系数的均值池化层,容易作为网络层插入到网络中。因此,本文采用 DCT

代替傅里叶变换进行 PQD 分解,其详细的方法流程如图 1 所示。




图1 基于DCT的PQD信号分解过程

Fig. 1 PQD decomposition process based on DCT

如图 1 所示,复合 PQD 信号经过上述分解过程,可以得到包含不同频率信息的分量,从而通过频域将信号中的不同扰动解耦。

2 基于 DCT 的频域解耦模块

为了构造端到端的深度网络,本节基于 DCT 原理分析设计频域解耦模块实现第 1 节所述的基于 DCT 的 PQD 信号分解过程。该频域解耦模块本质上是一个深度网络层,作为扰动识别模型的输入层实现复合 PQD 的频域解耦。

2.1 DCT 原理

DCT 变换是傅里叶变换的一种特殊形式,计算简单,具有良好的频域能量聚集度。相比于傅里叶变换,DCT 变换的频域系数没有虚数部分,可以采用简单的矩阵运算实现,在噪声处理、音频或图像压缩等方面应用广泛。对于长度为 N 的 PQD 信号,其 DCT 正变换的计算表达式如下。

$$f_k = \sqrt{\frac{2}{N}} \sum_{i=0}^{N-1} C(k) x_i \cos\left(\frac{(2i+1)k\pi}{2N}\right) \quad (1)$$

式中: f_k 为第 k 个 DCT 系数, k 的取值范围为 $[0, 1, 2, \dots, N-1]$; x_i 为输入 PQD 信号第 i 个元素; $C(k)$ 为正交因子,其表达式如下。

$$C(k) = \begin{cases} \frac{\sqrt{2}}{2}, & k = 0 \\ 1, & k = [1, 2, \dots, N-1] \end{cases} \quad (2)$$

对于给定的 DCT 系数,可以通过 DCT 反变换

得到原信号。DCT 反变换的计算表达式如下。

$$x_i = \sqrt{\frac{2}{N}} \sum_{k=0}^{N-1} C(k) f_k \cos\left(\frac{(2i+1)k\pi}{2N}\right) \quad (3)$$

2.2 频域解耦模块

从式(1)可以看到,DCT 变换的运算本质是对输入信号每个采样点 x_i 的加权和,其权重系数 B_k^i 可以表示如下。

$$B_k^i = \sqrt{\frac{2}{N}} C(k) \cos\left(\frac{(2i+1)k\pi}{2N}\right) \quad (4)$$

那么,DCT 变换可以表示如下。

$$f_k = \sum_{i=0}^{N-1} B_k^i x_i \quad (5)$$

同理,DCT 反变换可以表示为:

$$x_i = \sum_{k=0}^{N-1} B_k^i f_k \quad (6)$$

DCT 正反变换的加权和形式与神经网络中均值池化层类似,不同之处在于均值池化层中求和的权重系数均为 1。将式(5)~(6)表示的 DCT 变换过程构建为网络中两个特殊的池化层。在 DCT 正反变换的两个网络层之间,加入滑动窗函数对频谱进行滑动采样,得到包含不同频率信息的频谱分量。采用矩形窗构造滑动窗函数 $u(k)$,其表达式如下。

$$u(k) = \begin{cases} 1, & k \in [k_0, k_0 + k_w) \\ 0, & \text{其他} \end{cases} \quad (7)$$

式中: k_0 为频谱的采样起点,由滑动窗序号和滑动步长决定; k_w 为窗口宽度。输入的 PQD 信号经过 DCT 正变换层后得到频谱 f_k ,将频谱与滑动窗函数相乘再输入到 DCT 反变换层,即可得到不同频段的 PQD 信号分量。DCT 反变换层可以表示为:

$$x_i = \sum_{k=0}^{N-1} B_k^i u(k) f_k \quad (8)$$

上述 DCT 变换层和滑动窗函数的堆叠构成了频域解耦模块,其整体结构如图 2 所示。

在图 2 中,长度为 N 的 PQD 信号经过包含 C 个频谱采样窗口的频域解耦模块,最终得到通道为 C 的多通道 PQD 分量。不同通道的 PQD 分量包含不同频率的信息,可以将处在不同频率范围的扰动类别解耦,有效缓解复合扰动的特征混叠问题。

3 基于深度频域注意力网络(DFAN)的扰动识别方法

在本文提出的频域解耦模块基础上构建深度频




图 2 频域解耦模块

Fig. 2 Frequency domain decoupling module

域注意力网络进行复合扰动识别。首先,采用频域解耦模块作为网络的输入层,对复合扰动中处于不同频率范围的扰动进行解耦,得到多通道的PQD分量,每个通道对应一种频率范围。对于不同的PQD信号,其有效信息所在的频率范围不同。例如,暂升、暂降等扰动相比于基波信号仅在信号幅值上有所不同,而不包含其他频率成分,因此识别这两类扰动所需要的信息主要集中在基波频率上。而暂态振荡等扰动其主要信息集中在高频范围内,有效信息也在高频通道中。因此,在频域解耦模块输出不同频率范围的多通道信号分量之后,采用注意力机制模块自适应地为每个通道分配注意力系数作为该通道的权重,以表示不同通道的重要程度。然后,采用一维卷积层和快捷连接构建残差块对多通道PQD分量进行特征提取,得到多通道的特征图。接着,采用全局最大值池化层将特征图转化为一维特征向量。最后,基于全连接层构建扰动识别网络实现复合PQD的识别。所构建DFAN网络的整体架构如图3所示。主要包括频域解耦模块、注意力机制模块、残差网络以及分类器网络,下面对DFAN网络中每个模块的结构和参数进行详细介绍。

3.1 注意力机制模块

得到多通道的PQD分量之后,采用注意力机制为每个通道分配权重。为了能够根据输入的复合PQD自适应地为其不同分量计算通道权重,采用多个全连接层构建注意力机制模块。由于全连接层中




图 3 DFAN 网络的整体架构

Fig. 3 Framework of DFAN

包含可学习参数,经过训练之后,模块能够根据样本输入的多通道PQD特征图自适应地计算每个通道的注意力系数(即通道的权重系数)。

对于尺寸大小为 $C \times N$ 的输入多通道PQD特征图 F (C 是多通道PQD的通道数量,而 N 表示每个通道的序列大小),通过注意力机制模块能够得到同样尺寸的特征图 F' ,该注意力机制模块的作用过程的如图4所示。




图 4 注意力机制模块的作用过程

Fig. 4 Working process of the attention mechanism module

如图4所示,输入的多通道PQD特征图 F 首先经过全局均值池化得到一维特征向量。全局池化过程中每个通道仅保留一个特征值,采用均值池化能够有效记录通道的全部信息。均值池化的计算表达式如下:

$$f_j = \frac{1}{N} \sum_{i=1}^N \{x_i, x_i \in F_j\} \quad (9)$$

式中: f_j 为第 j 个通道的均值池化结果; F_j 为第 j 个通道的特征向量; N 为每个通道的序列长度。

在均值池化之后,采用两个全连接层对池化后的一维特征向量进行压缩拓展变换。两个全连接层的线性变换过程分别用 W_1 和 W_2 表示。在两个全连

接层之间,采用激活函数线性修正单元(rectified liner unit, Relu)做非线性变换,提高网络的非线性表达能力,降低训练过程中梯度弥散风险。最后,采用Sigmoid函数对输出进行归一化,得到注意力系数向量。上述过程的表达式如下。

$$\alpha = \delta(W_2 \times \sigma(W_1 \times f)) \quad (10)$$

式中: f 为输入的一维特征向量; W_1 和 W_2 分别为两个线性变换的全连接层,其中 W_1 的输入维度是特征向量长度 C ,输出维度是 $C/4$, W_2 的输入输出维度则相反,完成压缩和拓展运算;向量 α 为得到的注意力系数向量,长度等于特征向量长度 C ; σ 和 δ 分别为Relu函数和Sigmoid激活函数,其表达式如下。

$$\sigma(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (11)$$

$$\delta(x) = \frac{1}{1 + e^{-x}} \quad (12)$$

式中 x 为输入的值。

得到注意力系数向量 α 后,将其与原多通道PQD的特征图相乘,每个通道乘以对应的注意力系数,得到最终的包含通道重要性信息的特征图 F' 。

3.2 残差网络模块

所提DFAN网络的采用残差结构构建特征提取网络对多通道PQD输入进行特征提取。所构建的残差网络主体由3层残差块构成,每个残差块包含主分支和快捷连接分支。残差块的基本结构如图5所示。

如图5所示,残差块的主分支由两层卷积层构成。由于输出的是一维信号数据,采用一维卷积构建。一维卷积仅在信号序列维度上进行卷积操作,适用于提取一维阵列数据的特征。在两个卷积层之间,采用Relu激活函数进行连接,增加特征提取网络的非线性表达能力。残差块的快捷分支同样采用一维卷积,但其卷积核大小为 1×1 ,通道数与主分支的卷积层保持一致,仅用来保持输入输出的通道数相同,以便进行后续的逐元素相加。快捷分支的引入有效保留了卷积运算前后的特征信息,同时能够有效防止过拟合。

在残差块之间采用最大值池化缩短特征图中每个特征通道的序列长度。最大值池化层能够强制减少特征维度,具有特征选择和去除冗余特征的作用,同时减少了网络参数规模。

经过残差网络提取到二维特征图之后,采用全




图5 残差块结构

Fig. 5 Structure of the residual block

局最大值池化层将二维特征图转化为一维特征向量。全局最大值池化取每个通道中所有特征的最大值输出,能够引导网络保留最有效特征。全局最大值池化的表达式如下。

$$f_c = \max \{ x_i | x_i \in f_c \} \quad (13)$$

式中: f_c 为二维特征图中第 c 个通道向量; x_i 为特征向量的第 i 个元素; f_c 为池化后的最大特征值。

3.3 扰动识别模块

扰动识别模块本质是一个多分类器,根据特征判别输入扰动信号的类别。所提扰动识别模块主要由两层全连接层构成,其基本结构如图6所示。




图6 分类器结构

Fig. 6 Structure of the classifier

如图6所示,在两个全连接层之间,采用Dropout层缓解模型的过拟合风险。Dropout层采用随机断开部分神经元之间连接的策略防止模型过拟合,是一种简单且高效的防止过拟合手段。在网络最后,采用Softmax分类器将特征转化为输入信号属于每个类别的概率,其计算表达式如下。

$$y_i = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (14)$$

式中: y_i 为输入信号属于第 i 个扰动类别的概率; x_i 为输出层第 i 个特征。

Softmax将最终的网路输出归一化成0~1之间的概率值(即一种概率分布),为后续采用交叉熵损失函数计算多分类提供了概率输入。多分类交叉熵

损失函数能够描述模型预测的概率分布与真实概率分布之间的差异,以 Softmax 分类器相结合能够有效训练网络识别扰动,其计算表达式如下。

$$\text{Loss}(p, y) = -\frac{1}{M} \sum_{i=1}^M y_i \log(p_i) \quad (15)$$

式中: M 为 Softmax 输出类别概率的数量; p_i 和 y_i 分别为第 i 个类别概率的预测值和真实值。

4 仿真实验验证

4.1 复合 PQD 的 DCT 分解

为了验证所提频域解耦模块对分离复合 PQD 的有效性,单独采用本文第 2 节构建的频域解耦模块对复合扰动进行解耦变换,可视化其输出的多通道 PQD 分量。

根据电能质量的 IEEE Std. 1159 标准构建数学模型对复合 PQD 信号进行生成。首先根据该电能质量扰动标准及文献[13, 23–24]建立复合 PQD 信号仿真模型。考虑到真实环境下各类扰动发生的持续时间、严重程度等均不同,数学模型中的可变参数(例如,暂升数学模型中扰动发生时间、暂升幅值等参数,振荡暂态数学模型中振荡频率、衰减系数等参数)均采用均匀分布的随机数进行模拟。选择 7 种典型的单一扰动信号(暂升、暂降、中断、谐波、闪变、振荡暂态和脉冲暂态)进行排列组合,得到包括 7 种单一扰动、17 种两类复合扰动以及 17 种三类复合扰动共 41 种复合 PQD。典型的两类复合扰动和三类复合扰动波形如图 7 所示。

图 7 是典型的 PQD 扰动波形,图中波形的纵坐标为波形幅值的标幺值,纵坐标是采样点数(仿真时设置基波频率为 50 Hz,波形采样频率为 3.2 kHz,采样 10 个周期共 640 个采样点)。

采用频域解耦模块对图 7 中(c)所示的 3 类复合 PQD 进行 DCT 分解。频域解耦模块中的滑动窗口长度设为 150 Hz,滑动步长为 120 Hz, DCT 分解得到的各个分量波形如图 8 所示。

图 8 展示了频率范围在 0~600 Hz 的 5 个 DCT 分量,频率范围从上到下依次升高。复合 PQD 的有效频率成分主要集中在 500 Hz 以下,因此图中 DCT 分量 5 的幅值已经接近 0,可以忽略该分量。从图 8 中可以看到, DCT 分量 1 主要保留了低频成分,其暂降的特征最为明显; DCT 分量 2 和 3 可以看到是高次谐波的叠加,具有明显的谐波特征;而




图 7 典型 PQD 波形

Fig. 7 Typical PQD waveforms




图 8 复合 PQD 的 DCT 分量

Fig. 8 DCT components of PQD

DCT 分量 4 是高频振荡分量,很好地保留了振荡暂态的振荡衰减特性。对比图 7(c) 原始 PQD 波形可知,原波形中振荡暂态特征被谐波和暂降影响,容易被扰动识别模型忽略,而经过所提频域解耦模块分解为图 8 所示的 DCT 分量后,各扰动特征也被很好地分离,因此可以提高复合扰动识别精度。

4.2 模型参数与训练

对所提 DFAN 模型进行训练,训练的数据集采

用包含42种PQD的仿真样本(包括一种正常样本),数据集共包含 $(41+1) \times 500 = 21\,000$ 个样本,随机按6:2:2的比例划分为训练集、验证集和测试集。本文仿真数据集中的每类扰动样本数量均为500个,后续所有实验结果也都在样本类别均衡的测试集上测得。该仿真数据集仅用作方法的有效性验证,实际应用所提方法时可以通过调研先确定实际环境下各类扰动发生概率,再根据概率调整训练集分布,以达到最好的效果。考虑到实际采集的PQD信号往往包含噪声,在数据集的每个样本信号中随机添加20~50 dB的高斯白噪声。

所提DFAN网络的各部分参数设置如表1所示。

表1 DFAN参数设置

Tab. 1 Parameters setting of DFAN

DFAN模块	参数名称	数值
注意力机制模块	收缩系数	4
	输出层激活函数	Sigmoid
	各卷积层通道数	32, 64, 128
残差网络	卷积核大小	3×1
	卷积步长	1
	各卷积层激活函数	Relu
	池化层步长	2×1
分类器模块	输入层神经元数量	128
	输入层激活函数	Relu
	Dropout系数	0.3
	输出层神经元数量	42
	输出层激活函数	Softmax

采用Python 3基于Tensorflow深度学习框架实现上述所提DFAN深度网络。训练过程中的梯度更新策略采用Adam梯度下降算法,训练的批尺寸为256,迭代次数设为500。

4.3 实验结果与分析

频域解耦模块的窗口宽度决定了每个通道分量的频率范围,会影响模块对复合扰动的分解效果,从而影响模型的识别精度。理论上,滑动窗口越小,频域解耦模块的解耦分辨率越高,即能解耦的频率分量之间的频率差距越小,有益于解耦两种频率范围相似的扰动类型。然而,过小的滑动窗口可能导致同一种扰动的特征被分解到多个分量中,反而降低了此类扰动的特征显著性,可能导致模型的漏检。此外,高分辨率的解耦会得到更多频率范围

的PQD分量,但更多的PQD分量意味着模型冗余通道更多,增加了后续模型部署后的推理耗时;而当窗口太宽时,模型难以解耦频率范围接近的不同扰动,导致复合扰动的特征混叠对模型性能产生较大影响。而滑动步长只要取小于等于滑动窗长度的值,即可保证相邻两个滑动窗有重叠,从而不遗漏的对所有频率范围进行分解。本文取步长为滑动窗长度的80%作为滑动步长,即保证两个相邻滑动窗的具有20%的重叠部分。为了分析窗口宽度对模型性能的影响,找到最优的窗口宽度,采用不同窗口宽度的DAFN网络进行训练和测试。窗口宽度分别取50 Hz、100 Hz、150 Hz、200 Hz、250 Hz,测试结果如图9所示。




图9 不同窗口宽度的模型性能

Fig. 9 Performance of different window width

由图9可知,窗口宽度在150 Hz时(此时滑动步长为120 Hz),模型表现最优,正确率为98.49%。说明此时窗口宽度能够较好地实现复合PQD的解耦,且不至于输出过多冗余PQD分量。当窗口宽度缩小时,模型性能有所下降,此时模型的精度损失来源于冗余PQD通道分量的增加。而当窗口宽度变大时,可以看到模型正确率快速衰减,这是因为太宽的频域窗口难以解耦复合PQD。本文采用窗口宽度为150 Hz、滑动步长为120 Hz的DFAN模型作为最终模型,以下所有实验结果均在该模型上测得。

为了验证所提DFAN网络的优势,基于常用深度学习结构设计并构建扰动识别模型进行对比。由于深度学习算法的性能和参数规模呈正相关,即相同条件下参数规模越大,性能越好。为了公平客观地说明有效性,在构建对比网络时本文通过选取相同的网络层及参数(例如保持各个对比模型的卷积

层数一致、卷积层的核尺寸相同、分类器的结构参数相同等)得到同等数量级参数规模的不同深度学习模型。基于 CNN、Resnet、SE-net 以及 CNN-LSTM 4 种常见深度网络构建扰动识别模型与所提 DFAN 网络对比对比。为了验证所提方法在不同噪声条件下的识别效果,分别采用添加 20 db、30 db、40 db、50 db 以及随机信噪比的 5 种测试集测试个模型效果,对比结果如表 2 所示。

表 2 对比实验结果

Tab. 2 Compare test results

模型名称	参数规模	不同噪声条件下的正确率				
		20 db	30 db	40 db	50 db	随机
CNN	119,895	93.79	95.21	95.89	96.31	95.76
Resnet	130,873	94.68	95.80	96.67	96.94	96.48
SE-net	123,577	95.26	96.13	97.11	97.05	96.77
CNN-LSTM	136,377	93.97	94.09	96.39	96.61	95.91
DFAN	120,537	97.73	98.13	98.52	98.84	98.49

表 2 统计了不同深度扰动识别模型的参数规模和测试精度。从参数规模上看,所提模型与常用深度学习模型的复杂度基本一致。这是由于网络中的频域解耦模块均是数学运算,不包含额外的可学习参数,因此没有增加网络参数。而从测试集的识别精度上看,所提模型在各个噪声条件下均表现最优。随机噪声条件下,所提方法正确率达到 98.49%,相比于 CNN 提升约 3%。除基础 CNN 外,其他在 CNN 基础上改进网络均有不同提升。其中,Resnet 和采用注意力机制的 SE-net 提升最大,约为 1%,但仍低于本文所提 DFAN 模型。横向对比来看,相比于其他方法,所提方法在不同噪声水平下识别正确率的波动更小,具有一定的抗噪声能力,这是由于频域解耦过程也可以一定程度分解出噪声,进而降低了噪声对扰动特征的影响。上述对比实验结果表明所提 DFAN 扰动识别模型在各种噪声条件下对复合扰动识别精度上的优势,验证了频域解耦对提高复合 PQD 识别精度的有效性。

为了进一步说明所提方法对不同频率扰动的识别效果以及不同扰动组合方式的识别效果,分别测试模型对 7 种单一扰动、17 种两类复合扰动以及 17 种三类复合扰动的识别精度。扰动组合方式测试结果如表 3 所示,7 种不同频率扰动的测试结果如图 10 所示。

表 3 不同扰动组合方式的测试结果

Tab. 3 Results of different complex PQD

模型名称	不同扰动组合的正确率		
	单一扰动	两类复合扰动	三类复合扰动
CNN	97.03	95.69	94.16
Resnet	97.42	96.49	96.23
SE-net	97.86	96.89	96.07
CNN-LSTM	96.96	95.98	95.05
DFAN	98.71	98.63	98.27




图 10 不同频率扰动的测试结果

Fig. 10 Result of PQDs with different frequencies

表 3 是各个模型对不同扰动组合方式的识别结果对比,可以看到,在单一扰动、两类复合及三类复合扰动上所提方法精度均最高。整体上,各个模型对单一扰动的识别精度均高于复合扰动,对两类、三类复合扰动的识别精度差距较小。相比之下,所提 DFAN 模型对复合扰动的识别精度与单一扰动的差距最小,这表明所提频域解耦方法对提升复合扰动识别精度的有效性。

由图 10 可知,对于扰动信息集中在基频(50 Hz)的扰动,如暂升、暂降、中断,模型识别精度最高,均达到 100%。对于低频扰动如闪变(根据 IEEE std1159, 小于 25 Hz),模型识别精度有所下降。而对于中高频扰动如谐波的识别精度较基频扰动更低,但高于高频扰动如振荡和脉冲两类暂态扰动。由于暂态扰动持续时间短,识别难度较大,模型对这两类高频扰动的识别精度最低,仅为 96%左右。该测试结果表明,模型对中低频扰动的识别效果更好,在处理高频扰动方面存在一定局限。

5 结语

本文基于离散余弦变换理论构造了一种频域深

度学习方法解决复合PQD的特征混叠问题,提高了识别模型的精度。基于DCT原理设计的频域解耦模块,能够将复合PQD信号解耦成不同频率分量,便于后续网络独立提取不同扰动特征。注意力机制的引入使得网络能够在训练中自适应选择频率通道,去除冗余特征,进一步提高了深度模型的特征提取能力。所提DFAN方法在包含41种复合PQD信号数据集上的识别精度达到98.49%,优于CNN、Resnet、SE-net以及CNN-LSTM等四种常见的深度网络。实验结果表明,所提DFAN网络能够在不显著增加网络参数规模的前提下提高复合PQD的识别精度,在复合PQD识别方面优势显著。

参考文献

- [1] 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.
- [2] 郑蜀江,邓志祥,范瑞祥,等.计及分布式新能源选址的配电网最大供电能力研究[J].南方电网技术,2018,12(5):71-79.
ZHENG Shujiang, DENG Zhixiang, FAN Ruixiang, et al. Research on total supply capability of distribution network considering distributed new energy locating[J]. Southern Power System Technology, 2018, 12(5): 71-79.
- [3] 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.
- [4] YUAN D, LIU Y, LAN M, et al. A novel recognition method for complex power quality disturbances based on visualization trajectory circle and machine vision[J]. IEEE Transactions on Instrumentation and Measurement, 2022(71): 1-13.
- [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] 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, PP (99): 1-1.
- [7] 张淑清,李盼,师荣艳,等.基于改进S变换的电能质量扰动分类新方法[J].仪器仪表学报,2015,36(4):927-934.
ZHANG Shuqing, LI Pan, SHI Rongyan, et al. New method for power quality disturbance classification based on modified S transform[J]. Chinese Journal of Scientific Instrument, 2015, 36(4): 927-934.
- [8] 林顺富,汤继开,汤波,等.典型电能质量稳态指标预测模型研究[J].电网技术,2018,42(2):614-620.
LIN Shunfu, TANG Jikai, TANG Bo, et al. Study on forecasting model of typical power quality steady state indices[J]. Power System Technology, 2018, 42(2): 614-620.
- [9] 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.
- [10] KHOKHAR S. 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.
- [11] 赵俊,杨洪耕,李伟.利用S变换与变尺度模板标准化的短时电能质量扰动分类[J].南方电网技术,2010,4(3):72-76.
ZHAO Jun, YANG Honggeng, LI Wei. Classification of short duration power quality disturbance using S-transform and scale zooming standardization[J]. Southern Power System Technology, 2010, 4(3): 72-76.
- [12] ZHAO C. Novel method based on variational mode decomposition and a random discriminative projection extreme learning machine for multiple power quality disturbance recognition[J]. IEEE Transactions on Industrial Informatics, 2019, 15(5): 2915-2926.
- [13] 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.
- [14] ACHLERKAR P D, SAMANTARAY S R, MANIKANDAN M S. Variational mode decomposition and decision tree based detection and classification of power quality disturbances in grid-connected distributed generation system[J]. IEEE Transactions on Smart Grid, 2018, 9(4): 3122-3132.
- [15] 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. A classification and identification method for power quality disturbances based on VMD-SAST[J]. Electric Power, 2024, 57(2): 34-40.
- [16] 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.
- [17] 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.
- [18] 奚鑫泽,邢超,覃日升,等.基于深度卷积去噪网络的电能质量扰动识别方法[J].南方电网技术,2022,16(12):118-125.
XI Xinze, XING Chao, QIN Risheng, et al. Power quality disturbance identification method based on deep convolutional denoising network[J]. Southern Power System Technology, 2022, 16(12): 118-125.

(下转第172页 Continued on Page 172)