

DOI: 10.19783/j.cnki.pspc.191421

# 基于循环神经网络的电能质量扰动识别

武昭旭, 杨岸, 祝龙记

(安徽理工大学电气与信息工程学院, 安徽 淮南 232000)

**摘要:** 针对电能质量扰动信号识别算法复杂、识别率低等问题, 提出一种将长短时记忆神经网络应用于电能质量扰动信号识别分类的新方法。首先在 Tensorflow 中搭建长短时记忆神经网络, 建立电能质量扰动信号分类模型。其次利用分类模型对电能质量扰动信号原始数据进行有监督学习, 提取扰动信号的深层次特征, 并将其连接到 Softmax 分类器输出各扰动信号的识别率。最后将电能质量扰动信号通过递归图生成的二维轨迹图像作为分类模型的输入, 通过训练模型实现扰动信号的分类。仿真结果表明, 该分类模型对电能质量扰动信号的一维和二维表示均有较好的分类准确率, 可以有效识别 7 种单一扰动和 6 种复合扰动信号。

**关键词:** 递归图; 循环神经网络; LSTM; 电能质量扰动信号; 分类

## Power quality disturbance recognition based on a recurrent neural network

WU Zhaoxu, YANG An, ZHU Longji

(School of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232000, China)

**Abstract:** Given the problems of a complex identification algorithm and the low recognition rate of a power quality disturbance signal, a new method of applying a long-short term memory neural network to power quality disturbance signal recognition and classification is proposed. First, a long-short term memory neural network is built in Tensorflow to establish a power quality disturbance signal classification model. Secondly, the classification model is used to supervise the original data of the power quality disturbance signal, and the deep features of the disturbance signal are extracted and connected. The Softmax classifier outputs the recognition rate of each disturbance signal. Finally, a two-dimensional trajectory image generated by the power quality disturbance signal through the recursive map is used as the input of the classification model, and the disturbance model is classified by the training model. The simulation results show that the classification model has good classification accuracy for the one-dimensional and two-dimensional representation of power quality disturbance signals, and can effectively identify seven single disturbances and six composite disturbance signals.

This work is supported by National Natural Science Foundation of China-Shanxi Coal-based Low-carbon Joint Foundation (No. U1610120).

**Key words:** recursive graph; recurrent neural network; LSTM; power quality disturbance signal; classification

## 0 引言

随着电力系统的不断发展和电源接入形式的多样化, 电力系统的电能质量<sup>[1-5]</sup>越来越差; 同时, 各种用电设备对电能质量的标准有着极高的要求。因此, 准确、快速地对电能质量扰动信号进行识别和分类, 是保障电网稳定、安全、高效运行的前提。

**基金项目:** 国家自然科学基金-山西煤基低碳联合基金 (U1610120)

目前, 国内外学者针对电能质量扰动信号的分类提出了诸多方法。一般是先利用各种特征值提取方法对不同扰动信号进行特征值提取, 然后通过不同的分类器实现对特征值的分类, 以达到最终对扰动信号的识别。信号特征值提取方法有: DQ 变换<sup>[6]</sup>、S 变换<sup>[7]</sup>、曲线变换<sup>[8]</sup>、压缩感知<sup>[9]</sup>、相空间重构<sup>[10]</sup>、小波变换<sup>[11]</sup>、稀疏自动编码器<sup>[12]</sup>等; 分类器主要有: BP 神经网络<sup>[13]</sup>、深度信念网络<sup>[14]</sup>、决策树<sup>[15]</sup>、支持向量机<sup>[16]</sup>等。文献[17]利用分段改进 S 变换, 将时域分辨率和频域分辨率进行分段处理, 通过分析

改进 S 变换得到的模时频矩阵, 绘制了能够反映扰动信号不同突变参数的特性曲线, 利用局部逼近的径向基神经网络对扰动信号实现分类, 但是其在复合扰动下特征量提取困难, 通用性较差。文献[18]利用稀疏自动编码器对原始扰动信号进行无监督学习, 自动提取扰动信号数据特征的稀疏表达, 并使用分类器进行训练, 获得各种扰动信号的分类准确率, 解决了传统神经网络中权值初始随机性的缺点, 但编码过程复杂。

本文首先通过递归图算法获得电能质量扰动信号的二维图像, 然后将电能质量扰动信号原始数据及其通过递归图生成的二维轨迹图像分别作为长短时记忆神经网络的输入, 实现电能质量扰动信号的分类。

## 1 递归图

### 1.1 递归图原理

递归图<sup>[19]</sup>是一种从二维图像可以直观地观察时间序列内部具有的递归特征的分析方法, 由黑、白两点构成二维平面图像。该方法首先对时间序列进行相空间重构, 根据嵌入理论, 选择合适的延迟时间  $\tau$  和嵌入维度  $m$  进行相空间重构, 则重构后的向量为

$$\mathbf{x}_i = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}), i = 1, 2, \dots, N \quad (1)$$

式(1)中,  $N = n - (m-1)\tau$ , 定义重构后任意两点的距离  $D_{i,j}$  为式(2)。

$$D_{i,j} = \|\mathbf{X}_i - \mathbf{X}_j\|, i = 1, 2, \dots, N \quad (2)$$

选取合适的阈值  $\varepsilon$ , 可得递归矩阵为

$$\mathbf{R}_{i,j} = \theta(\varepsilon - D_{i,j}) \quad (3)$$

式(3)中,  $\theta(\cdot)$  表示 Heaviside 函数, 其表达式为

$$\theta(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4)$$

递归图可以直观地将时间序列高维相空间内的运动状态映射到一个二维平面图像中, 从而反映其递归特性。当  $X_i$  和  $X_j$  之间的距离  $D_{i,j}$  小于  $\varepsilon$  时, 表示  $X_i$  和  $X_j$  之间的状态非常相似, 即运动状态出现递归; 反之, 当  $X_i$  和  $X_j$  之间的距离  $D_{i,j}$  大于  $\varepsilon$  时, 则两者之间的运动状态相差很大。

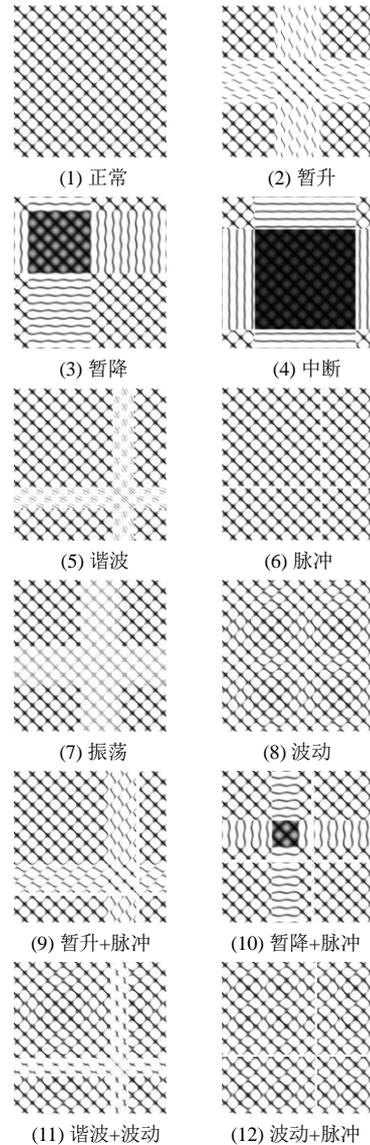
阈值  $\varepsilon$  是递归图算法中的关键参数, 一般根据经验选取。若是  $\varepsilon$  选取较大, 则会使大部分相空间之间的状态都是相似的; 若是  $\varepsilon$  选取较小, 则难以发现相空间之间状态的相似性。不合理的  $\varepsilon$  会使递归图丢失大量的信息, 从而无法反映信号的相关特

征。因此, 为了保留电能质量扰动信号中所有的特征信息, 本文将电能质量扰动信号转换为无阈值递归图。

### 1.2 电能质量扰动信号的递归图轨迹图像

电能质量扰动信号作为一维时间序列, 多种类型的扰动信号相互叠加会导致其时、频域特征改变。利用递归图算法将扰动信号高维相空间内的运动状态映射为一个二维轨迹图像, 得到的递归图像保留了其一维时间序列的重要特征。

针对电能质量扰动问题, 使用 Matlab 仿真 14 种扰动信号, 分别是正常信号(S1)、暂升(S2)、暂降(S3)、中断(S4)、谐波(S5)、脉冲(S6)、振荡(S7)、波动(S8)、暂升+脉冲(S9)、暂降+脉冲(S10)、谐波+波动(S11)、波动+脉冲(S12)、谐波+暂升+脉冲(S13)和谐波+波动+振荡(S14)等信号。图 1 为电能质量扰动信号的递归图轨迹图像。



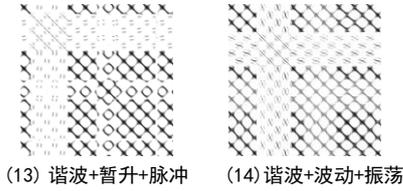


图 1 正常信号和扰动信号的递归图

Fig. 1 Recursive graph of normal and disturbance signals

## 2 循环神经网络

### 2.1 循环神经网络基本原理

循环神经网络<sup>[20-26]</sup>(Recurrent Neural Network, RNN) 是一类具有短期记忆能力的神经网络, 多用于语音识别、机器翻译等领域, 可以充分刻画出序列数据之间的相互关系。在 RNN 中, 神经元不仅可以接受其他神经元的信息, 还可以接受自身的信息, 形成一个环路结构。图 2 所示为 RNN 结构图。

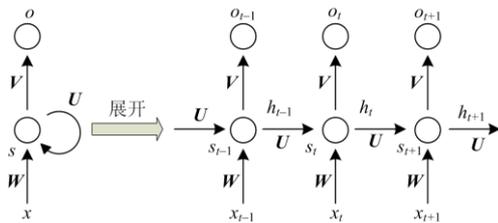


图 2 RNN 结构图

Fig. 2 RNN structure diagram

图 2 左图为 RNN 的折叠形式, 右图为其展开形式。与一般神经网络不同的是, RNN 的隐藏层存在有向反馈, 正是这种反馈赋予了 RNN 记忆能力。RNN 中的每一个神经元接受上一时刻隐藏层神经元输出  $h_{t-1}$  和当前时刻的输入  $x_t$ , 计算隐藏层神经元输出  $h_t$  以及输出  $o_t$ , 其计算公式表示为

$$\begin{cases} s_t = \mathbf{W}x_t + \mathbf{U}h_{t-1} \\ h_t = f(s_t) \\ o_t = g(\mathbf{V}h_t) \end{cases} \quad (5)$$

式(5)中:  $f$  为隐藏层函数;  $g$  为输出层函数;  $s_t$  为  $t$  时刻隐藏层的输入;  $h_t$  为  $t$  时刻隐藏层的输出;  $\mathbf{U}$ 、 $\mathbf{V}$ 、 $\mathbf{W}$  为不同时间隐藏状态的共享矩阵。

### 2.2 长短时记忆神经网络

传统的 RNN 在训练过程的梯度下降中, 偏向于以距当前时刻较近的序列的权值进行更新, 即旧的输入序列对权值更新起到的作用较小, 同时由于随着隐藏层的增加出现的梯度消失和爆炸的现象, RNN 无法很好地处理长时间序列。长短时记忆(Long-Short Term Memory, LSTM)神经网络作为 RNN 的改进网络, 相比普通的 RNN, LSTM 神经

网络的改进在于增加了遗忘门、输入门和输出门三种门结构。LSTM 神经网络通过门结构学习长时间窗中的依赖关系, 网络中的激活函数实现短期记忆, 权重的更新用于长时记忆。图 3 所示为 LSTM 神经网络某时刻的细胞结构图。

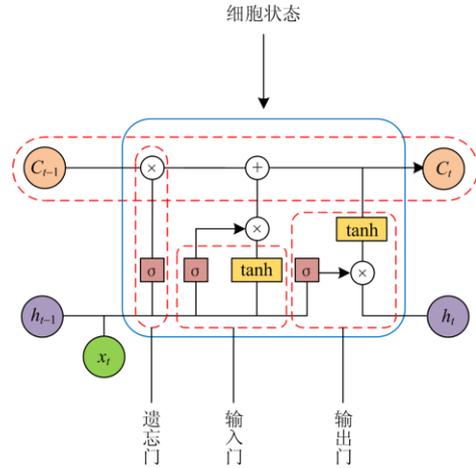


图 3 LSTM 神经网络细胞结构图

Fig. 3 LSTM neural network cell structure diagram

图 3 中, 遗忘门  $f_t$  决定细胞应该保留信息的多少, 控制着上一时刻信息  $C_{t-1}$  的通过程度。可以表示为

$$f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, x_t] + b_f) \quad (6)$$

式(6)中:  $f_t$  将上一时刻隐藏状态信息和当前输入信息传递给激活函数  $\sigma$ ;  $\mathbf{W}_f$  为权重;  $b_f$  为偏置。

输入门  $i_t$  确定如何更新细胞状态, 也就是将新的信息选择性存储到细胞中, 控制着新信息  $C_t$  写入长期记忆的程度。可以表示为

$$\begin{cases} i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, x_t] + b_i) \\ C_t = \tanh(\mathbf{W}_c \cdot [h_{t-1}, x_t] + b_c) \\ C_t = f_t \cdot C_{t-1} + i_t \cdot C_t \end{cases} \quad (7)$$

式(7)中,  $h_{t-1}$  和  $x_t$  传递给  $\sigma$  函数, 同时将其传入  $\tanh$  激活函数, 得到细胞状态候选值  $C_t$ , 两者共同决定新的细胞状态  $C_t$ 。 $\mathbf{W}_i$ 、 $\mathbf{W}_c$  为权值,  $b_i$ 、 $b_c$  为偏置。

输出门  $o_t$  决定当前隐藏状态的输出, 与输入门类似,  $h_t$  由  $o_t$  和  $C_t$  确定。可以表示为

$$\begin{cases} o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = o_t \cdot \tanh(C_t) \end{cases} \quad (8)$$

式(8)中:  $\mathbf{W}_o$  为权重项;  $b_o$  为偏置项。LSTM 神经网络中这种跨层连接的设计有效地减弱了梯度消失

的影响, 使其对于长序列的记忆能力大大提高。

### 2.3 RNN 的学习算法

RNN 的权值可以通过随时间反向传播算法 (Back Propagation Through Time, BPTT) 进行学习更新。BPTT 算法是在时间上反转的梯度下降算法, 其核心思路是把网络按时间顺序展开, 将其视为一个在各时刻权值共享的网络, 将网络各个时刻的内部状态展开成前馈网络, 按照时间的逆序将错误信息依次向前传递, 最终更新整个网络的参数。

在 RNN 的训练中, 其目的是计算  $\nabla V$ 、 $\nabla U$ 、 $\nabla W$  的值, 然后以此来优化网络的权值参数  $V$ 、 $U$ 、 $W$ , 计算公式为

$$\begin{cases} \nabla V = \frac{\partial E}{\partial V} = \sum_t \frac{\partial E_t}{\partial V} = r_t^{(i)} \cdot h_t^{(j)} = \sum_{t=0}^T (y_t - \hat{y}_t) \otimes h_t \\ \nabla U = \frac{\partial E}{\partial U} = \sum_t \frac{\partial E_t}{\partial U} = \sum_t \sum_{k=0}^t \delta_k \otimes h_{k-1} \\ \nabla W = \frac{\partial E}{\partial W} = \sum_t \frac{\partial E_t}{\partial W} = \sum_t \sum_{k=0}^t \delta_k \otimes x_k \end{cases} \quad (9)$$

式 (9) 中:  $E = \sum_t E_t$  表示损失函数的总和;

$r_t^{(i)} = (y_t - \hat{y}_t)^{(i)}$  表示残差向量第  $i$  个分量;  $h_t^{(j)}$  表示  $h_t$  的第  $j$  个分量,  $\delta_k = \partial E / \partial s_k$ 。由以上计算过程可知: 在 BPTT 算法中, 前向传播是按照时间顺序依次计算网络神经元的输出值, 反向传播是从最后时刻将网络累积的残差传递回来。该训练方式得到的结果相对较优, 相比传统训练算法的优势在于对历史信息的保存效果, 它的拓展形式能把误差反传得更远, 就好像把原来的神经网络在时间上铺开了一样。

### 2.4 电能质量扰动信号分类模型的构建

本文通过 Tensorflow 搭建 LSTM 神经网络, 电能质量扰动信号原始数据每个样本采样 1000 个数据点, 将每 10 个数据点作为一个时间序列, 即每个样本存储为 [100,10] 的向量, 全连接层的输出结果是一个 [1,14] 的向量, 即输入样本属于对应标签的可能性大小, 最后输出扰动信号的 14 分类识别率。设置模型参数为: Epoch 为 100, 损失函数为 Categorical\_crossentropy, Optimizer 为 Adam。

本文将递归图轨迹图像的每一行当成一个时间序列, 通过 LSTM 神经网络识别图像每一行的变化从而实现数据集的分类。在每一个时间步, 维数 [n\_batch, 128] 的数据输入 LSTM 神经网络, 一共有 128 行, 也就是 128 个时间步, 因此输入数据的维数是 [n\_batch, 128, 128], 输出数据的维数是 [n\_batch, n\_units, 128], 然后经过一个 [n\_units, n\_classes] 的矩

阵变换得到 [n\_batch, n\_classes] 的输出结果, 再和标准的结果比较计算 Loss。设置模型参数: Epoch 为 100, n\_batch 为 64, 隐藏层个数 n\_units 为 128, n\_classes 为 14, Learning\_rate 为 0.001, 损失函数为 Cross\_entropy, Optimizer 为 Adam。

## 3 仿真分析

本文采用 Matlab 仿真 14 种电能质量扰动信号, 正常信号和每类扰动各生成 600 个随机样本, 共 8400 个数据样本, 每类扰动叠加 40 dB 的噪声信号。基波频率为 50 Hz, 每个扰动信号样本采集 10 个基频周期, 每个基频周期采样 100 个点, 即共采样 1000 个数据点。每类扰动选取 500 个样本作为训练集, 100 个样本作为验证集。

### 3.1 原始数据输入的电能质量扰动识别

数据集包括 8400 个数据样本, 所有样本被存储为 (8400, 100, 10) 的 numpy 数组, 并且都关联了对应的类别标签。图 4、图 5 分别为训练损失曲线和识别率曲线。由图 4、图 5 可知, 不论是无噪声扰动信号或者是含 40 dB 噪声扰动信号, 二者的损失函数均在前 20 个 Epoch 内快速下降, 此后曲线依旧呈缓慢下降趋势, 最终稳定在一个较低的数值; 识别率则由一个较低的初始值迅速上升并保持在一个较高的数字。通过对比二者的分类效果可知, 随机噪声的增强使得网络的识别率有所下降, 但网络仍保持了较高的分类精度, 说明本方法具有一定程度的抗噪能力。

原始数据输入的电能质量扰动信号的分类准确率如表 1 所示。由表 1 可知, 从平均分类准确率上看, 本方法在不同的噪声强度下对扰动信号分类的准确率均较高。多种单一扰动和复合扰动的分类准确率可达到 100%。

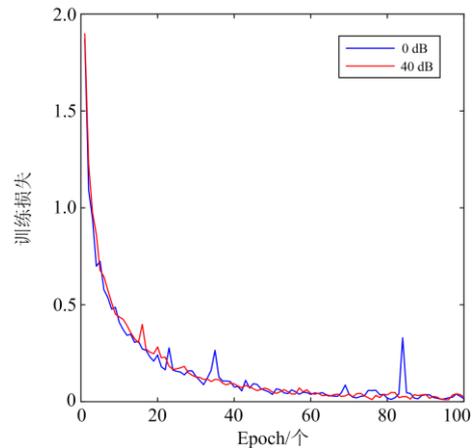


图 4 训练损失曲线

Fig. 4 Training loss curve

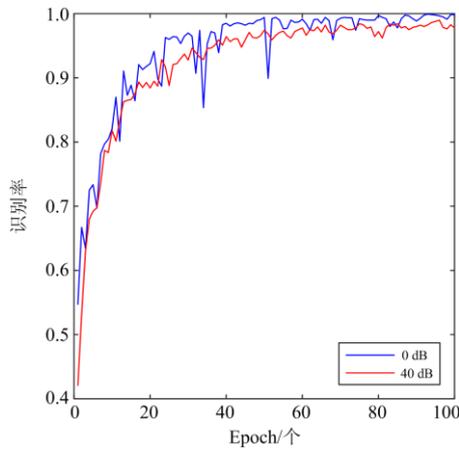


图 5 识别率曲线

Fig. 5 Recognition rate curve

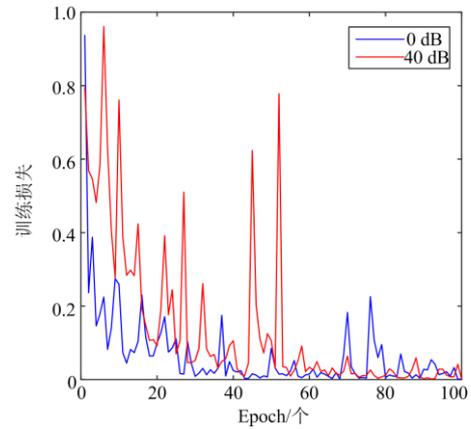


图 6 训练损失曲线

Fig. 6 Training loss curve

表 1 不同扰动信号的分类准确率

Table 1 Classification accuracy of different disturbance signals

扰动类型	分类准确率/%	
	0 dB	40 dB
S1	100.00	100.00
S2	100.00	99.00
S3	100.00	95.00
S4	99.00	93.00
S5	100.00	99.00
S6	100.00	100.00
S7	100.00	100.00
S8	100.00	100.00
S9	99.00	97.00
S10	100.00	96.00
S11	100.00	93.00
S12	100.00	99.00
S13	100.00	100.00
S14	100.00	98.00
平均	99.86	97.79

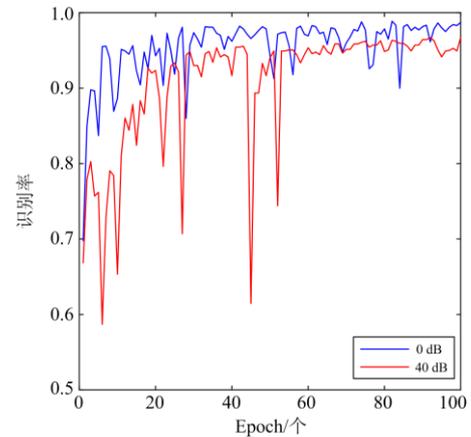


图 7 识别率曲线

Fig. 7 Recognition rate curve

表 2 不同扰动信号的分类准确率

Table 2 Classification accuracy of different disturbance signals

扰动类型	分类准确率/%	
	0 dB	40 dB
S1	97.00	90.00
S2	98.00	97.00
S3	97.00	99.00
S4	99.00	95.00
S5	100.00	99.00
S6	100.00	99.00
S7	99.00	95.00
S8	99.00	97.00
S9	99.00	98.00
S10	99.00	95.00
S11	99.00	99.00
S12	99.00	98.00
S13	99.00	95.00
S14	98.00	98.00
平均	98.71	96.71

### 3. 2 递归图表示的电能质量扰动识别

数据集包括 8 400 张 128×128 像素的递归图轨迹图像, 每张图片被存储为一个(128,128)的向量, 8 400 张图像被存储为(8 400,128,128)的 numpy 数组, 所有图像都关联了对应的类别标签。图 6 为训练损失曲线, 图 7 为识别率曲线。由图 6 和图 7 可知, 随着 Epoch 的增加, 网络的训练损失越来越低, 识别率越来越高, 经过约 60 个 Epoch 的训练, 曲线趋于平稳, 说明网络已经收敛。在前 60 个 Epoch 中, 曲线虽然波动较大, 但是由整体趋势可知模型在持续地优化完善, 网络稳定性不断增加, 最终保持在一个较高的识别率。

递归图表示的电能质量扰动信号的分类准确率如表 2 所示。由表 2 可知, 随着噪声的加入, 扰动

信号的分类准确率稍微下降, 准确率下降是因为随机噪声对不同扰动生成的递归图的影响不同, 在高维相空间里出现递归重叠现象。但是整体的分类准确率较高, 适合于不同扰动信号的识别。

#### 4 结语

本文提出了一种将 LSTM 神经网络应用于电能质量扰动信号识别分类的新方法, 包括数据准备、模型构建与训练等内容。LSTM 神经网络既可以对一维电能质量扰动信号原始数据进行识别; 又可实现对扰动信号的二维递归图轨迹图像分类, 从图像处理的角度出发, 将扰动信号转化为递归图可以简化对扰动原始数据复杂特征的提取, 但是也容易丢失重要信息。由仿真结果可知, 无论是将扰动信号直接输入分类模型或是将其转换为递归图后输入分类模型, 二者均能够识别多种单一扰动及复合扰动, 有较高的分类准确率。

#### 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] 高健, 崔雪, 邹晨露, 等. 基于改进能量集中度的 S 变换与随机森林的电能质量扰动识别[J]. 电测与仪表, 2019, 56(1): 8-14, 21.  
GAO Jian, CUI Xue, ZOU Chenlu, et al. Modified S-transform based on energy concentration measure and identification of power quality disturbance in random forest[J]. Electrical Measurement & Instrumentation, 2019, 56(1): 8-14, 21.
- [3] 瞿合祚, 李晓明, 陈陈, 等. 基于卷积神经网络的电能质量扰动分类[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.
- [4] 王凌云, 李开成, 肖夏颖, 等. 基于稀疏分解的复合电能质量扰动分类[J]. 电测与仪表, 2018, 55(1): 14-20, 33.  
WANG Lingyun, LI Kaicheng, XIAO Xiaying, et al. Classification for multiple power quality disturbances based on sparse decomposition[J]. Electrical Measurement & Instrumentation, 2018, 55(1): 14-20, 33.
- [5] 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.
- [6] 王鑫, 王卓, 郑璐. 基于 dq 变换和 S 变换的电能质量扰动识别[J]. 电子设计工程, 2012, 20(19): 139-141.  
WANG Xin, WANG Zhuo, ZHENG Lu. Power quality disturbance identification based on dq conversion and S transform[J]. Electronic Design Engineering, 2012, 20(19): 139-141.
- [7] 吴禹, 唐求, 滕召胜, 等. 基于改进 S 变换的电能质量扰动信号特征提取方法[J]. 中国电机工程学报, 2016, 36(10): 2682-2689.  
WU Yu, TANG Qiu, TENG Zhaosheng, et al. Feature extraction method of power quality disturbance signals based on modified S-transform[J]. Proceedings of the CSEE, 2016, 36(10): 2682-2689.
- [8] LIU H, FIDA H, SHEN Y, et al. Complex power quality disturbances classification via curvelet transform and deep learning[J]. Electric Power Systems Research, 2018, 163: 1-9.
- [9] 吴志宇, 朱云芳, 侯怡爽, 等. 电能质量扰动识别的小波压缩感知方法[J]. 电力系统及其自动化学报, 2019, 31(5): 1-7.  
WU Zhiyu, ZHU Yunfang, HOU Yishuang, et al. Power quality disturbance recognition method based on wavelet compressive sensing[J]. Proceedings of the CSU-EPSCA, 2019, 31(5): 1-7.
- [10] 陈伟, 何家欢, 裴喜平. 基于相空间重构和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, 2018, 46(14): 87-93.  
CHEN Wei, HE Jiahuan, PEI Xiping. Classification for power quality disturbance based on phase-space reconstruction and convolution neural network[J]. Power System Protection and Control, 2018, 46(14): 87-93.
- [11] SEBASTIAN P, D'SA P A. Implementation of a power quality signal classification system using wavelet based energy distribution and neural network[C] // 2015 International Conference on Power and Advanced Control Engineering (ICPACE), August 12-14, 2015, Bangalore, India: 157-161.
- [12] 朱瑞金, 郭威麟, 龚雪娇. 基于自编码器和卷积神经网络的电能质量扰动分类[J]. 电力系统及其自动化学报, 2019, 31(7): 70-75.  
ZHU Ruijin, GUO Weilin, GONG Xuejiao. Classification of power quality disturbances based on auto-encoder and convolutional neural network[J]. Proceedings of the

CSU-EPISA, 2019, 31(7): 70-75.

[13] 何巨龙, 王根平, 刘丹, 等. 基于提升小波和改进 BP 神经网络的配电网系统电能质量扰动定位与识别[J]. 电力系统保护与控制, 2017, 45(10): 69-76.  
HE Julong, WANG Genping, LIU Dan, et al. Localization and identification of power quality disturbance in distribution network system based on lifting wavelet and improved BP neural network[J]. Power System Protection and Control, 2017, 45(10): 69-76.

[14] 陈伟, 何家欢, 裴喜平. 深度信念网络在电能质量复合扰动识别中的应用[J]. 电力系统及其自动化学报, 2018, 30(9): 75-82.  
CHEN Wei, HE Jiahuan, PEI Xiping. Application of deep belief network in power quality compound disturbance identification[J]. Proceedings of the CSU-EPISA, 2018, 30(9): 75-82.

[15] 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): 1272-1278.  
CHEN Huafeng, ZHANG Gexiang. Power quality disturbance identification using decision tree and support vector machine[J]. Power System Technology, 2013, 37(5): 1272-1278.

[16] ZHAO Liquan, GAI Meijiao, WANG Lin. Classification of multiple power quality disturbances based on the improved SVM[C] // 2017 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET), March 22-24, 2017, Chennai, India: 2625-2628.

[17] 杨剑锋, 姜爽, 石戈戈. 基于分段改进 S 变换的复合电能质量扰动识别[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.

[18] 屈相帅, 段斌, 尹桥宣, 等. 基于稀疏自动编码器深度神经网络的电能质量扰动分类方法[J]. 电力自动化设备, 2019, 39(5): 157-162.  
QU Xiangshuai, DUAN Bin, YIN Qiaoxuan, et al. Classification method of power quality disturbances based on deep neural network of sparse auto encoder[J]. Electric Power Automation Equipment, 2019, 39(5): 157-162.

[19] 王曦, 毕贵红, 祖哲. 基于递归特性分析和 BP 神经网络的电能质量扰动识别与定位(英文)[J]. 电网技术, 2012, 36(8): 215-222.  
WANG Xi, BI Guihong, ZU Zhe. Based on recursive feature analysis and BP neural network analyze identification and location of power quality disturbances[J]. Power System Technology, 2012, 36(8): 215-222.

[20] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(增刊 2): 1-6, 26.  
YANG Li, WU Yuxi, WANG Junli, et al. Research on recurrent neural network[J]. Journal of Computer Applications, 2018, 38(S2): 1-6, 26.

[21] XU X, CHEN R Q. Recurrent neural network based online fault diagnosis approach for power electronic devices[C] // Third International Conference on Natural Computation, August 24-27, 2007, Haikou, China: 700-704.

[22] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult[J]. IEEE Transactions on Neural Networks, 1994, 5(2): 157-166.

[23] ZHAO H, SUN S, JIN B. Sequential fault diagnosis based on LSTM neural network[J]. IEEE Access, 2018, 6: 12929-12939.

[24] SONG Q, WU Y L, SOH Y C. Robust adaptive gradient-descent training algorithm for recurrent neural networks in discrete time domain[J]. IEEE Transactions on Neural Networks, 2008, 29(11): 1841-1853.

[25] EBUBEKIR B, BANU D. Web page classification using RNN[J]. Procedia Computer Science, 2019, 154: 62-72.

[26] AHMADI A, TANI J. A novel predictive-coding-inspired variational RNN model for online prediction and recognition[J]. Neural Computation, 2019, 31(11): 2025-2074.

收稿日期: 2019-11-13; 修回日期: 2019-12-10

作者简介:

武昭旭(1993—), 男, 通信作者, 硕士研究生, 研究方向为电力系统自动化、电能质量监测; E-mail: 862583634@qq.com

杨岸(1965—), 男, 硕士, 副教授, 研究方向为电力系统自动化、电能质量监测与控制; E-mail: 1986034@aust.edu.cn

祝龙记(1964—), 男, 博士, 教授, 研究方向为电力系统自动化。

(编辑 魏小丽)