

DOI: 10.19783/j.cnki.pspc.190288

基于卷积-长短期记忆网络的电能质量扰动分类

曹梦舟, 张艳

(上海海事大学物流工程学院, 上海 201306)

摘要: 为了提高电能质量扰动分类准确率, 针对扰动信号时序性的特点, 采用了基于卷积-长短期记忆网络的电能质量扰动分类方法。首先, 将扰动信号进行采样作为输入。然后, 通过卷积神经网络(CNN)提取特征数据, 再对提取到的特征数据以序列的形式作为长短期记忆网络(LSTM)的输入, 对特征数据进行筛选更新。最后, 再对输出的特征数据进行学习分类。仿真结果显示, 该方法对电能质量扰动信号的平均分类准确率为 99.6%, 优于单一的 CNN 法和单一的 LSTM 法。

关键词: 电能质量; 扰动分类; 深度学习; 卷积神经网络; 长短期记忆网络

Classification for power quality disturbances based on CNN-LSTM network

CAO Mengzhou, ZHANG Yan

(Logistics Engineering College, Shanghai Maritime University, Shanghai 201306, China)

Abstract: In order to improve the power quality disturbance classification accuracy, aiming at the characteristics of timing, a power quality disturbance classification method based on convolution-long short-term memory is used. Firstly, the disturbance signal is sampled as input. Secondly, the feature data is extracted via convolutional neural network. Then the extracted feature data is used as input of long and short term memory network in the form of sequence, and the feature data is screened and updated. Finally, the output feature data is classified by learning. The simulation results show that the average classification accuracy of this method for power quality disturbance signals is 99.6%, which is better than the single CNN method and the single LSTM method.

This work is supported by National Natural Science Foundation of China (No. 61503240 and No. 61603246).

Key words: power quality; disturbance classification; deep learning; convolutional neural network; long short-term memory

0 引言

随着电力电子技术在电力系统的广泛应用与高速发展, 电能质量问题日益突出, 引起了供电部门和广大电力用户的普遍重视。同时电力用户和用电设备也对供电质量提出了更高要求, 因此准确有效地对电能质量信号进行分类具有重要的意义^[1]。分类的重点在于对电能扰动信号的特征提取, 如何有效快速地提取特征是一个难点。

传统的电能质量扰动信号分类主要分为两个步骤: 首先对去噪后的电能质量信号进行特征提取^[2], 如傅里叶变换^[3]、小波变换^[4]、S 变换^[5]等, 然后以提取的特征信息作为输入对电能质量信号进行分类, 如支持向量机^[6]、决策树^[7]、神经网络^[8]等。

文献[9]利用小波变换将电流信号进行分解, 并计算各频段的信号能量, 从而获得能量谱作为电流信号的特征向量。结合 BP 神经网络训练网络参数, 实现对故障电弧的分类。文献[10]利用 S 变换提取特征值并配上决策树对电能质量扰动进行分类; 文献[11]利用小波变换提取特征向量并搭配 SVM 向量机对电能质量扰动进行分类。文献[12]利用 S 变换和傅里叶变换提取特征搭配改进的向量机对电能质量扰动进行分类。文献[13]利用改进小波变换提取特征结合反向神经网络对电能质量扰动进行分类。文献[14]利用小波变换提取特征结合多标签决策树集成算法对电能质量扰动进行分类。文献[15]利用离散小波变换提取特征结合并行马尔可夫模型对电能质量扰动进行分类。文献[16]利用粒子群算法提取有用的特征结合向量机对电能质量扰动进行分类。上述几种方法的共同缺陷在于人为凭借经验构

基金项目: 国家自然科学基金项目资助(61503240, 61603246)

建特征样本, 使得特征提取比较复杂, 并且提取到的特征不够全面, 从而导致分类准确率不高。随着深度学习的研究不断成熟, 近年来涌现出不少优秀的深度学习算法, 例如卷积神经网络(CNN)、玻尔兹曼机(RBM)等, 它们能自动提取特征, 很好地弥补了现有方法提取特征值难的问题。文献[17]用 Wigner-Ville 分布(WVD)与卷积神经网络相结合的混合方法, WVD 技术将一维电压扰动信号传输到 2D 图像文件中, 然后用卷积神经网络自动从图像文件中提取特征图并分类。文献[18]用受限玻尔兹曼机对扰动序列信号的波形固有抽象特征进行提取, 并完成分类。文献[19]分别利用降噪堆栈自编码和深度置信网对电能质量扰动进行特征提取并完成分类。上述三种方法的优点在于强大的自动提取特征的能力, 它们的不足在于缺少时间相关性的考虑。

本文用卷积神经网络和长短期记忆网络结合(CLSTM)的方法。先用 CNN 提取出扰动信号的特征序列, 再用 LSTM^[20]对特征序列筛选更新并输出, 最后对输出的特征进行学习并分类。本文通过 CLSTM、LSTM 和 CNN 三种方法之间的仿真对比, 实验结果表明了 CLSTM 方法对电能质量扰动信号分类的有效性。

1 电能质量扰动信号模型

在参考文献[21]的基础上, 本文分类识别以下 10 种扰动类型: 电压暂升、电压中断、电压暂降、电压闪变、暂态振荡、谐波、瞬态冲击、电压暂升+谐波、电压暂降+谐波与标准信号, 其中包括 7 类单一类型的扰动信号, 2 类混合类型的扰动信号, 1 类标准信号。

设置采样频率 f_s 为 12.8 kHz, 每个样本信号采集 0.3 s (这里为 15 个周期, 信号长度为 3840 采样点)。电能质量扰动信号具有较强的周期性, 因此以上述的等长截取信号作为深度学习的输入具有实际意义。

这 10 类信号具有可表述的特征, 在实际情况中由于电压值和信号幅度的不同, 为了适应不同的电压值的情形, 本文在 Matlab 上对这 10 类扰动信号进行归一化处理。如图 1 所示。

2 基于卷积神经网络的分类方案

2.1 卷积神经网络的分类结构及方案

卷积神经网络(CNN)能处理不同维度的信号。本文的扰动信号属于一维信号, 所以用一维 CNN。由于本文的电能质量扰动信号具有时序性, CNN

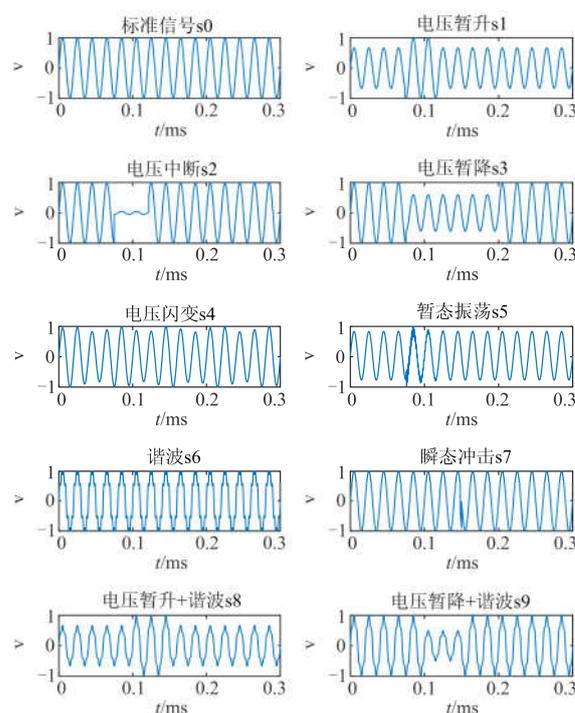


图 1 10 类电能质量扰动归一化后的波形

Fig. 1 10 types of power quality disturbances normalized waveforms

提取到的特征缺少时间依赖性, 因此分类准确率可能会比较低。

CNN 分类网络结构如图 2 所示。其结构分别为输入层、卷积层、归一化层、激励层、池化层、退出层、全连接层和分类层。

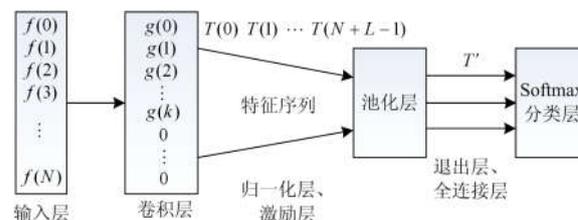


图 2 CNN 分类网络结构

Fig. 2 CNN classification network structure

在图 2 中, 卷积层的目的是为了提取特征, 是整个 CNN 的关键一环。本文是对一维的时序信号进行卷积, 运算公式为

$$T[n] = (f * g)[n] = \sum_{m=0}^{N-1} f(m)g(n-m) \quad (1)$$

式中: $T[n]$ 为卷积后的数据序列即特征序列; N 为输入数据 $f(n)$ 的长度; $g(n)$ 表示卷积的核函数序列, 随机生成, 长度等于卷积核的长度 L 。卷积后的序列长度为 $N+L-1$ 。上述卷积的流程可概括

为：输入数据序列 f 与核函数序列 g 做卷积，其结果就是提取到的特征序列 T 。

归一化层是为了对提取到的特征归一化，为了加快卷积神经网络的训练。激励层是促进归一化后的特征映射。池化层起到降维的作用。退出层为了防止过拟合。全连接层是为了减少特征信息的损失。分类层则是将特征值进行分类识别。

其中激励函数选用 relu 函数，其表达式为

$$y = \max(0, x) \quad (2)$$

分类层的计算过程为

$$\text{Soft max}(a_i) = \frac{\exp(a_i)}{\sum_{k=1}^k \exp(a_k)}, i = 1, 2, \dots, k \quad (3)$$

式中， k 为类别数。 Softmax 的输出结果代表输入数据被分类到每个标签的概率。

其分类方案大致如下：首先将电能质量扰动信号样本 f 传到输入层，其次通过卷积层内的核函数序列 g 做卷积运算后形成特征序列 T ，然后经过归一化层对特征序列归一化，再经过激励层对其激活并经过池化层对其冗余部分删除，最后处理后的特征序列 T' 通过连接层输出，并对输出特征进行训练及分类。

2.2 卷积神经网络的训练方法

本文 CNN 方法采用的是随机梯度下降法^[22] (SGD)。SGD 法具体如下。

样本的目标函数为

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m \frac{1}{2} (y^{(i)} - h_{\theta}(x^{(i)}))^2 \quad (4)$$

式中： θ 为初始参数； m 表示训练集的记录条数； i 表示第 i 个样本； $(x^{(i)}, y^{(i)})$ 代表训练样本集； $h_{\theta}(x^{(i)})$ 表示拟合函数。

样本的损失函数为

$$\text{cost}(\theta, (x^{(i)}, y^{(i)})) = \frac{1}{2} (y^{(i)} - h_{\theta}(x^{(i)}))^2 \quad (5)$$

每个样本的损失函数对 θ 求偏导，更新 θ ：

$$\theta'_j = \theta_j + (y^{(i)} - h_{\theta}(x^{(i)}))x_j^{(i)} \quad (6)$$

式中， θ'_j 是更新的参数。

其优点是在迭代过程中参数的更新速度加快，收敛速度快。

3 基于长短期记忆网络的分类方案

3.1 长短期记忆网络的分类结构及方案

长短期记忆网络(LSTM)能处理各种长短不一的时序信号。它不能进行特征提取，只适合于序列

建模。LSTM 能自动学习时序信号的相关性。本文的电能质量扰动信号是一时序信号，LSTM 能很好地迎合电能质量扰动信号的时序性特点，对其分类会比 CNN 要好得多。

LSTM 分类网络结构包括输入层、细胞状态 (cell state)、全连接层、分类层，如图 3 所示。

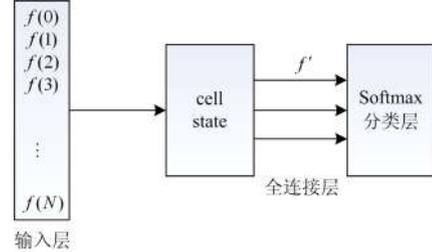


图 3 LSTM 分类网络结构

Fig. 3 LSTM classification network structure

图 3 中全连接层和分类层与 CNN 类似。这里不再重述。“cell state”为输入的数据提供了时间依赖性，赋予了数据时间特征。“cell state”中包括了三个门：遗忘门、输入门、输出门，在图 4 中的位置分别对应应在左中右。

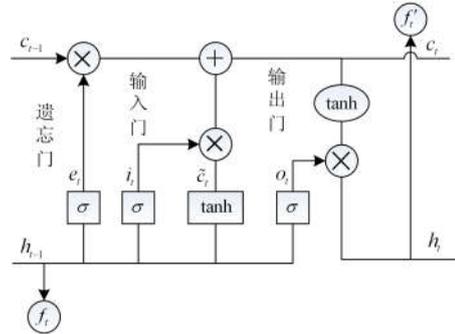


图 4 cell state 结构

Fig. 4 Structure of cell state

cell state 能很好地完成对输入时序信号的筛选更新，赋予它时间依赖性，有利于时序信号的分类识别。具体的工作原理如下。

如图 4 中遗忘门的作用体现在决定丢弃什么输入信息，其表达式为

$$e_t = \sigma(W_f \cdot [h_{t-1}, f_t] + b_f) \quad (7)$$

式中： e_t 表示遗忘门限； h_{t-1} 为上一个输出的信息； f_t 为输入数据信息； b_f 为遗忘门的偏置项。它们都经过 Sigmoid 函数保留一部分忘记一部分。

如图 4 中输入门的作用是确定保留的信息并更新信息，其表达式为

$$i_t = \sigma(W_i \cdot [h_{t-1}, f_t] + b_i) \quad (8)$$

$$\tilde{c}_i = \tanh(W_c \cdot [h_{t-1}, f_t] + b_c) \quad (9)$$

$$c_i = e \cdot c_{t-1} + i_i \cdot \tilde{c}_i \quad (10)$$

式(8)中: i_i 表示输入门限; b_i 是输入门的偏置项。式(9)中: \tilde{c}_i 表示前一刻的 cell 状态; b_c 表示 cell 状态偏置项。式(10)中, c_i 表示当前 cell 状态。Sigmoid 函数和 tanh 函数训练两个权值 W_i 、 W_c 。Sigmoid 函数决定着需要更新的信息, tanh 函数决定着忘记的早期信息。式(10)中: $e \cdot c_{t-1}$ 表示忘记的信息; $i_i \cdot \tilde{c}_i$ 表示更新的信息, 它们的累加就是当前的 cell 状态 c_i , 即表示信息筛选更新的程度。

如图 4 中输出门的作用则是确定输出的信息, 其表达式为

$$o_i = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (11)$$

$$f'_i = o_i \cdot \tanh(c_i) \quad (12)$$

式中: o_i 表示输出门限; b_o 表示输出门的偏置项。通过 sigmoid 函数将提取出的信息输出, tanh 函数处理状态量 c_i 得到一个处于 $[-1, 1]$ 的值, 再将它和 sigmoid 的输出相乘, 即为最后输出的部分 f'_i 。

LSTM 的分类方案大致如下: 首先将电能质量扰动信号采样成 f 后输入到 cell state, 然后经过 cell state 对 f 进行筛选更新形成新的 f' , 并对输出的数据学习和分类。

3.2 长短期记忆网络的学习方法

本文 LSTM 用的是自适应时刻估计方法^[23] (ADAM), 它能计算每个参数自适应的学习率, 其表达式为

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \varepsilon}} \hat{m}_t \quad (13)$$

式中: \hat{m}_t 为梯度的第一时刻平均值; \hat{v}_t 为梯度的第二时刻非中心方差值。

ADAM 法的优点在于其收敛速度快, 可以纠正其他优化技术中存在的问题, 如梯度消失、收敛过慢或学习率消失等问题。

4 基于卷积-长短期记忆网络分类方案

由于卷积神经网络(CNN)的优势在于特征的提取, 长短期记忆网络(LSTM)的优势在于赋予了特征信号的时序相关性, 使 CNN 提取到的特征经过 LSTM 加工后更加具有时间依赖性, 更好地囊括出电能质量扰动信号的特征。其分类比单一的 CNN 和 LSTM 要更好。

CLSTM 网络结构包括输入层、卷积层、归一化层、激励层、池化层、cell state、全连接层、分

类层, 如图 5 所示。其中, 每个层的作用已在第 2 节、第 3 节介绍过, 不再重述。

其分类方案如下: 首先将扰动信号样本 f 作为 CNN 的输入, 然后通过卷积层与核函数序列 g 做卷积形成特征序列 T , 归一化层、激励层、池化层进行特征处理形成 T' , 随后再进入 LSTM 层中, cell state 对提取到的特征筛选更新形成新的特征 T'' , 最后再对输出后的特征进行训练并分类。其训练方式用 SGD 法训练。

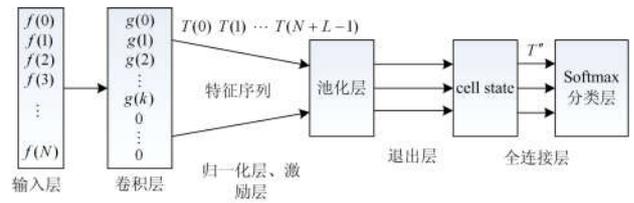


图 5 CLSTM 分类网络结构

Fig. 5 CLSTM classification network structure

5 仿真实验

在本节中, 通过对比使用 CNN、LSTM 和 CLSTM 法对本文表 1 的 10 类信号进行分类, 对每类信号分别加入 20 dB、30 dB、40 dB 的高斯白噪声, 共产生 500 个样本, 十类信号共生成 5 000 个样本。随机选择 4 500 个样本作为训练集, 剩余的 500 个样本为验证集和测试集, 其中验证集的设立是为了防止过拟合情况的出现。首先载入数据, 其次给对应的数据加上分类的标签。下面使用 Matlab 中 deep learning 工具箱分别对数据集合在三类算法框架下进行分类, 具体的参数如下所示。

先用 CNN 法进行分类。对 CNN 结构层进行设计, 具体如下: 输入层 imageInputLayer 参数设为 $1 \times 3\,000 \times 1$, 分类数 numclasses 设为 10。共有 5 个卷积层, 其卷积核 filterSize 大小分别设为 1×21 、 1×23 、 1×25 、 1×27 、 1×29 ; 数字过滤器 numFilters 则对应设为 4、16、32、64、128; 使用 padding 和 same 作为输入映射填充。使用 batchNormalizationLayer 进行归一化处理。使用 reluLayer 进行激活。有三个池化层, 最大池层 PoolSize 参数大小均设为 1×3 , 跨度为 1×2 。退出层 dropoutLayer 概率参数 probability 设为 0.2。使用 softmaxLayer 函数将输出规范化。使用 classificationLayer 函数进行分类。用 SGD 法训练网络, 最小批尺寸 Minbatchsize 参数设置为 200。初始学习率 InitialLearnRate 设为 $1e-3$, 最大训练设置 MaxEpochs 为 120。学习比例系数 LearnRateDropFactor 设为 0.2。学习进度 LearnRate DropPeriod 设为 20。

接下来用 LSTM 法进行分类。对 LSTM 结构层进行设计，具体如下：通道数 inputSize 设为 1，分类数设为 10，隐藏单元 numHiddenUnits 分别设为 60、40。规范函数和分类函数与 CNN 法类似。用 ADAM 法训练网络，执行环境指定为 gpu，梯度阈值 GradientThreshold 设为 1，最小批尺寸为 80，最大训练设置为 120。序列长度指定为 longest。

最后用 CLSTM 法进行分类。先对 CNN 层设计，与 CNN 法相同。再对 LSTM 层设计，其通道数和分类数与 CNN 法、LSTM 法相同。隐藏单元设为 128。训练方式与 CNN 法相同。规范函数和分类函数与 CNN 法、LSTM 法类似。

以 CLSTM 为例，其分类混淆矩阵如图 6 所示。得到的验证曲线如图 7、图 8 所示。三种方法的分类准确率如表 1 所示。

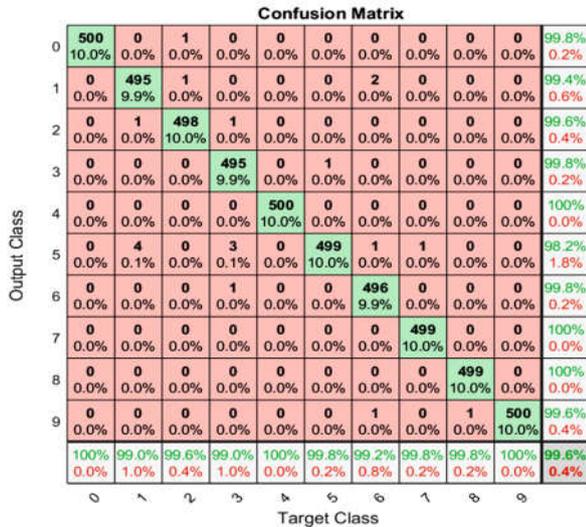


图 6 CLSTM 预测分类混淆矩阵

Fig. 6 CLSTM predictive classification confusion matrix

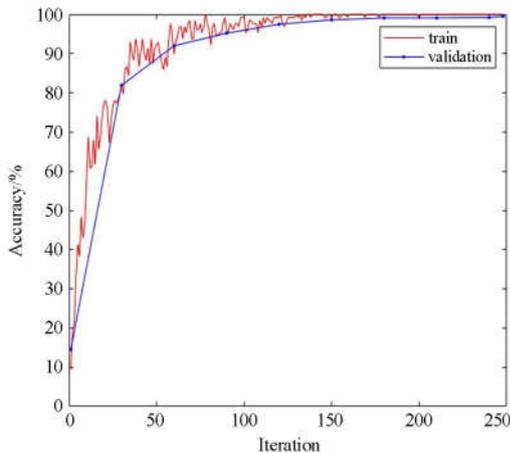


图 7 CLSTM 的分类准确率曲线

Fig. 7 CLSTM classification accuracy curve

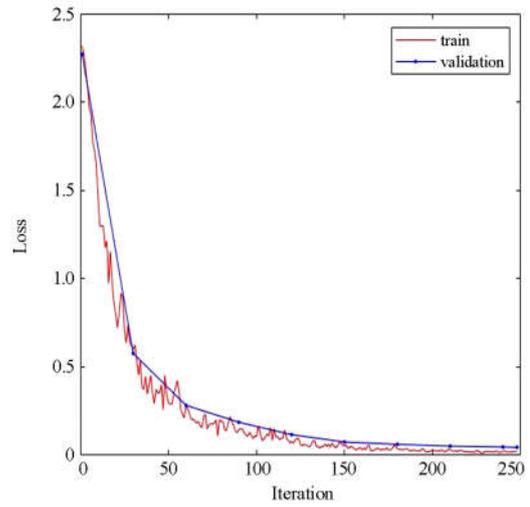


图 8 CLSTM 的损失曲线

Fig. 8 CLSTM loss curve

图 6 的矩阵含义如下：分别为 11 行 11 列。底下的数字 0 到 9 表示待分类的十类扰动信号，左边的数字 0 到 9 表示预测的分类。最后一行的格子(右下角除外)上面的百分比表示所用方法对某一扰动的正确分类的准确率；下面的百分比表示所用方法对某一扰动的分类错误率。最后一列的格子(右下角除外)上面的百分比表示所用方法分类为某一扰动的准确率；下面的百分比表示所用方法分类为某一扰动的错误率。

图 7 中训练分类准确率、测试分类准确率曲线都通过 iteration 迭代数不断升高趋于 1，说明其分类效果越来越好。

图 8 中训练损失、测试损失曲线都随着迭代数增加而趋于 0，说明其模型训练不断地完善。

表 1 电能质量扰动信号在三种方法下的分类准确率

Table 1 Power quality disturbance signals classification accuracy based on three methods

	CNN	LSTM	CLSTM
标准信号(s0)	90.2%	99.4%	100%
电压暂升(s1)	95.4%	98.2%	99.0%
电压中断(s2)	85.8%	99.2%	99.6%
电压暂降(s3)	84.2%	96.8%	99.0%
电压闪变(s4)	96.2%	99.8%	100%
暂态振荡(s5)	95.0%	99.4%	99.8%
谐波(s6)	91.6%	97.8%	99.2%
瞬态冲击(s7)	91.0%	99.2%	99.8%
电压暂升+谐波(s8)	84.4%	99.8%	99.8%
电压暂降+谐波(s9)	90.8%	98.6%	100%
平均值	90.5%	98.9%	99.6%

由表 1 可以得出:

1) CNN 方法的平均分类准确率较 LSTM 和 CLSTM 低, 只有 90.5%。而 LSTM 和 CLSTM 的平均分类准确率则相对高出不少, 分别是 98.9%和 99.6%。这是由于电能质量扰动信号是一个随时间变化的序列, CNN 只能对扰动信号特征进行提取, 提取到的特征并不具备时间依赖性, 故分类准确率比较低; 而 LSTM 则直接对输入扰动信号筛选更新, 为它赋予了时间依赖性, 相对契合了时序信号的特点, 故比 CNN 高出不少; 而 CLSTM 则在 CNN 提取特征的基础上也具备了时间依赖性, 所以它的分类准确率最高, 分类效果也最好。综合分析比较得出: CLSTM 法最好, LSTM 法其次, CNN 法比较差。

2) CLSTM 法对二重扰动信号的分类比较好, 其对 s8(电压暂升+谐波)、s9(电压暂降+谐波)的分类准确率分别高达 99.8%和 100%。一重扰动信号中, CLSTM 对它们的分类准确率都比另外两种方法好, 其中对 s0(标准信号)和 s4(电压闪变)达到了 100%。

6 结语

本文结合卷积神经网络(CNN)和长短期记忆网络(LSTM)的优势, 用 CNN 和 LSTM 的组合模型克服了单一的 CNN 模型学习特征后缺少时间相关性的问题, 同时克服了 LSTM 模型无法提取特征的缺陷。仿真结果表明, CLSTM 法比单一的 CNN 法分类准确率提高了 9.1%, 比单一的 LSTM 法分类准确率提高了 0.7%, 很好地弥补了另外两种方法的局限性。未来的工作在于增加多重电能质量扰动信号的分类, 以及在多个噪声组合下对其分类。

参考文献

- [1] 徐文远, 雍静. 电力扰动数据分析学—电能质量监测数据的新应用[J]. 中国电机工程学报, 2013, 33(19): 93-101.
XU Wilsun, YONG Jing. Power disturbance data analytics—new application of power quality monitoring data[J]. Proceedings of the CSEE, 2013, 33(19): 93-101.
- [2] 徐冠华, 赵景秀, 杨红亚, 等. 文本特征提取方法研究综述[J]. 软件导刊, 2018, 17(5): 13-18.
XU Guanhua, ZHAO Jingxiu, YANG Hongya, et al. Review of text feature extraction methods[J]. Software Guide, 2018, 17(5): 13-18.
- [3] KOCHMANN J, MANJUNATHA K, GIERDEN C, et al. A simple and flexible model order reduction method for FFT-based homogenization problems using a sparse sampling technique[J]. Computer Methods in Applied Mechanics and Engineering, 2018.
- [4] 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), Bangalore, 2015: 157-161.
- [5] 易吉良. 基于 S 变换的电能质量扰动分析[D]. 长沙: 湖南大学, 2010.
YI Jiliang. Power quality disturbance analysis based on S-transform[D]. Changsha: Hunan University, 2010.
- [6] 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.
- [7] SAINI R, MAHELA O P, SHARMA D. An algorithm based on hilbert transform and rule based decision tree classification of power quality disturbances[C] // 2018 IEEE 8th Power India International Conference (PIICON), 2018, Kurukshetra India: 1-6.
- [8] 张弘喆, 赵康, 李乐蒙, 等. 基于多层人工神经网络的电力系统恢复过电压预测[J]. 智慧电力, 2018, 46(8): 67-73.
ZHANG Hongzhe, ZHAO Kang, LI Lemeng, et al. Overvoltage forecast during power system restoration based on multilayer artificial neural network[J]. Smart Power, 2018, 46(8): 67-73.
- [9] 严国平, 陈昊, 谭风雷, 等. 基于电流特征提取的故障电弧识别方法[J]. 智慧电力, 2018, 46(6): 101-105.
YAN Guoping, CHEN Hao, TAN Fenglei, et al. Fault arc identification method based on current feature extraction[J]. Smart Power, 2018, 46(6): 101-105.
- [10] 周祖宁. 基于 S 变换的电能质量扰动识别算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.
ZHOU Zuning. Research on power quality disturbance identification algorithm based on S-transform[D]. Harbin: Harbin University of Technology, 2017.
- [11] 雷志国, 金月, 谭万禹. 基于 SVM 的电能质量扰动分类[J]. 电测与仪表, 2014, 51(23): 69-72.
LEI Zhiguo, JIN Yue, TAN Wanyu. Classification of power quality disturbances based on SVM[J]. Electrical Measurement and Instrumentation, 2014, 51(23): 69-72.
- [12] 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.
- [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] 瞿合祚, 刘恒, 李晓明, 等. 基于多标签随机森林的电能质量复合扰动分类方法[J]. 电力系统保护与控制, 2017, 45(11): 1-7.
QU Hezuo, LIU Heng, LI Xiaoming, et al. Recognition of multiple power quality disturbances using multi-label random forest[J]. Power System Protection and Control, 2017, 45(11): 1-7.
- [15] 谢善益, 肖斐, 艾芊, 等. 基于并行隐马尔科夫模型的电能质量扰动事件分类[J]. 电力系统保护与控制, 2019, 47(2): 80-86.
XIE Shanyi, XIAO Fei, AI Qian, et al. Parallel hidden Markov model based classification of power quality disturbance events[J]. Power System Protection and Control, 2019, 47(2): 80-86.
- [16] 王新环, 刘志超, 卢彩霞. 基于 PSO-LSSVM 的煤矿电能质量扰动识别研究[J]. 软件导刊, 2018, 17(7): 196-199.
WANG Xinhuan, LIU Zhichao, LU Caixia. Research on coal mine power quality disturbance identification based on PSO-LSSVM[J]. Software Guide, 2018, 17(7): 196-199.
- [17] MOHAN N, SOMAN K P, VINAYAKUMAR R. Deep power: deep learning architectures for power quality disturbances classification[C] // 2017 International Conference on Technological Advancements in Power and Energy (TAP Energy), 2017, Kollam: 1-6.
- [18] 马建, 陈克绪, 肖露欣, 等. 基于受限玻尔兹曼机的电能质量复合扰动识别[J]. 南昌大学学报(理科版), 2016, 40(1): 30-34.
MA Jian, CHEN Kexu, XIAO Luxin, et al. Recognition of power quality compound disturbance based on restricted Boltzmann machine[J]. Journal of Nanchang University (Science Edition), 2016, 40(1): 30-34.
- [19] 肖露欣. 基于深度学习的电能质量扰动识别[D]. 南昌: 南昌大学, 2017.
XIAO Luxin. Disturbance recognition of power quality based on deep learning[D]. Nanchang: Nanchang University, 2017.
- [20] 张亚宁. 基于 LSTM 模型的短期负荷预测[J]. 科技与创新, 2018(12): 18-21.
ZHANG Yanning. Short-term load forecasting based on LSTM model[J]. Science and Technology and Innovation, 2018(12): 18-21.
- [21] 张杨, 刘志刚. 一种基于时频域多特征量的电能质量混合扰动分类新方法[J]. 中国电机工程学报, 2012, 32(34): 83-90, 13.
ZHANG Yang, LIU Zhigang. A new method for power quality hybrid disturbance classification based on multi-characteristic variables in time-frequency domain[J]. Proceedings of the CSEE, 2012, 32(34): 83-90, 13.
- [22] 王功鹏, 段萌, 牛常勇. 基于卷积神经网络的随机梯度下降算法[J]. 计算机工程与设计, 2018, 39(2): 441-445, 462.
WANG Gongpeng, DUAN Meng, NIU Changyong. Random gradient descent algorithm based on convolution neural network[J]. Computer Engineering and Design, 2018, 39(2): 441-445, 462.
- [23] 赵小强, 宋昭漾. Adam 优化的 CNN 超分辨率重建[J]. 计算机科学与探索, 2019(5): 858-865.
ZHAO Xiaoqiang, SONG Zhaoyang. Adam optimized CNN super-resolution reconstruction[J]. Journal of Frontiers of Computer Science and Technology, 2019(5): 858-865.

收稿日期: 2019-03-18; 修回日期: 2019-05-09

作者简介:

曹梦舟(1995—), 男, 硕士研究生, 研究方向为电能质量, 电力系统运行与分析; E-mail: 1078646767@qq.com

张艳(1977—), 女, 博士, 副教授, 研究方向为复杂系统的控制与优化。E-mail: zhangyan@shmtu.edu.cn

(编辑 魏小丽)