

基于CNN的电能质量扰动分类

刘 恒

(上海电力大学 上海 200135)

【摘 要】本文提出一种基于卷积神经网络的电能质量扰动的分类方法,本文构建一个CNN模型来对电能质量扰动进行分类。文章通过matlab产生八种电能质量扰动,以此作为CNN模型的输入来进行分类,实验结果表明CNN模型具有良好的分类准确率,准确率能达97%。

【关键词】CNN; 电能质量; matlab

[Abstract]This paper presents a classification method for power quality disturbances based on convolutional neural networks. This paper builds a simple CNN model to classify power quality disturbances. In this paper, eight kinds of power quality disturbances are randomly generated by matlab, which is used as the input of the CNN model for classification. The experimental results show that the CNN model has a good classification accuracy rate, and the accuracy rate can reach 97%.

[Keywords]CNN;power quality classification;matlab

引言

随着高比例电力电子设备等线性负载的大量使用,使得电能质量问题越来越严重,对电力系统的安全稳定造成了很大的影响。因此为了治理电能质量问题,准确高效识别并分类电能质量扰动是极为重要的一步,也为进一步的补救措施提供足够信息。

传统电能质量扰动分类一般分为两部分,一个是对扰动数据的特征提取,二是对扰动特征进行分类。在绝大部分文献中,都是通过将扰动数据提取与分类模型组合的方法对电能质量扰动数据进行分类。常见的特征提取方法有:离散傅里叶变换(DFT)、短时傅里叶变换(STFT)、小波变换(WT)、S希尔伯特-黄变换(HHT)等^[1]。离散傅立叶变换是针对频域,适用于稳态类电能质量扰动,具有一定局限性。短时傅立叶的窗口是一定的,并且时域频域的分辨率也是一定的,不适用于暂态扰动数据分析。小波变换虽然解决了短时傅立叶变换的窗口一定的缺点,并且对时域频域局部化有很好的效果,但是当有噪声时,效果很差并且对数据处理慢^[2-4]。采用希尔伯特-黄变换的话,虽然噪声对其影响小,但存在边界效应^[5]。扰动分类是对扰动数据进行区别,现阶段主要方法有:神经网络^[6]、决策树^[7](DT)、模糊分类^[8]和支持向量机^[9](SVM)等。决策树结构过于简单,对扰动数据进行区分时效果不佳,因此分类准确率低,在分类过程中容易发生拟合。支持向量机是一种数学统计算法,在处理小数据时有一定优势,泛化性能好,但是支持向量机需要数据非线性,不能处理大数据样本。

本文通过卷积神经网络(CNN)对扰动数据进行提取和分类,解决了需要对数据进行处理,减少了工作量,并且也能对扰动数据进行分类,不需要分为两部分,将两部分进行了整合,在一个模型里面进行数据处理和扰动分类。

1 原理

1.1 卷积神经网络

本文卷积神经网络结构由卷积层,池化层,全连接层所组成。卷积神经网络的最重要的是卷积层和池化层。卷积层是将扰动数据进行特征提取,池化层是对扰动数据的特征进一步提取,把特征进一步区分。本文卷积神经网络模型是采用梯度下降法最小化损失函数对网络中的权重参数逐层反向调节,通过多次的迭代训练提高网络的精度。全连接层是对特征提取结果进行分类^[10]。

1.1.1 卷积层

首先通过卷积层进行卷积,把输入的扰动信号的特征进行提取,把扰动数据进行卷积会使扰动数据变大。卷积层通过卷积核对数据进行卷积操作。卷积的结果与偏置后的结果即为扰动数据的特征图。卷积层的数学表达,如下式所示:

$$x_j^l = \sum_{i \in M_j} x_i^{l-1} \times k_{ij}^l + b_j^l \quad (1)$$

上式的 l 表示卷积层的层数; M_j 表示上一层中与所在层的第 j 个特征图有连接的特征图集合; x_j^l 为第 l 层输出的第 j 个特征图; x_i^{l-1} 为第 $l-1$ 层输出的第 i 个特征图; k_{ij}^l 为第 l 层的第 j 个特征图与前一层第 i 个特征图之间的卷积核; b_j^l 为第 l 层第 j 个特征图的偏置。

1.1.2 池化层

由于卷积层会使扰动数据变大,使得特征维数变大。为了使特征维数变低而且减少训练过程。在卷积层后引入池化层,池化层的作用是对上一层输入的特征图进行压缩。一是使特征图压缩,使整个模型变小,减少训练时间,优化了模型,不容易过拟合。池化层操作如下式所示:

$$x_j^l = \beta_j^l \text{pool}(x_i^{l-1}) + b_j^l \quad (2)$$

表1 8种扰动信号的数学模型

扰动类型	标号	模型	参考值取值范围
正常	C1	$\alpha \sin(\omega_0 t)$	$\alpha = 1$
暂升	C2	$[1 + \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega_0 t)$	$\alpha = 0.1 \sim 0.9; T < t_2 - t_1 < 8T$
暂降	C3	$[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega_0 t)$	$\alpha = 0.1 \sim 0.9; T < t_2 - t_1 < 8T$
中断	C4	$[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega_0 t)$	$\alpha = 0.9 \sim 1; T < t_2 - t_1 < 8T$
谐波	C5	$\alpha \sin(\omega_0 t) + \alpha_3 \sin(3\omega_0 t) + \alpha_5 \sin(5\omega_0 t) + \alpha_7 \sin(7\omega_0 t)$	$\alpha_3 = \alpha_5 = \alpha_7 = 0.02 \sim 0.1;$
闪变	C6	$[1 + \alpha \sin(b\omega_0 t)]\sin(\omega_0 t)$	$\alpha = 0.1 \sim 0.2; b = 0.1 \sim 0.5;$
振荡	C7	$\sin(\omega_0 t) + \alpha \exp(-(t-t_1) * \sin(\omega_n(t-t_1)) * (u(t-t_1) - u(t-t_2)))$	$\omega_n = (10 \sim 16)\omega_0; \alpha = 0.1 \sim 0.8;$ $0.5T < t_2 - t_1 < 3T$
脉冲	C8	$\sin(\omega_0 t) + \alpha(u(t-t_1) - u(t-t_2))$	$\alpha = 1 \sim 3; 1\text{ms} < t_2 - t_1 < 3\text{ms}$




图2 扰动信号




图3 实验结果准确率




图4 实验损失值

其中: $\text{pool}()$ 表示池化函数; β_j 为比例偏置; b_j^i 为加性偏置。

1.1.3 激活函数

传统卷积神经网络中通常采用sigmoid饱和非线性函数,但是sigmoid需要训练次数多收敛性差,更有可能出现在训练过程中出现梯度消失。因此本文选取不饱和非线性激活函数ReLU(rectified linear units) 作为CNN的激活函数,数学表达如下式所示:

$$y = \max(0, x) \quad (3)$$

1.1.4 训练方式

本文采用前馈式神经网络,通过bp反向传播算法来优化网络结构,求解网络中的未知参数。将训练样本送入输入层,经过卷积、池化提取扰动数据的特征,最后进入全连接层并在输出层输出样本的分类特征图。采用随机梯度下降算法相应地更新各层的卷积核和偏置系数。

1.1.5 CNN结构

本文中CNN结构由2层卷积,2层最大池化层组成,1层flatten和全连接层组成。如图1所示:




图1 本文CNN结构图

1.2 电能质量扰动模型

本文电能质量扰动信号分为8种,分别为:正常C1、暂升C2、暂降C3、中断C4、谐波C5、闪变C6、振荡C7、脉冲C8。它们的电能质量扰动信号数学模型如表1所示,8种扰动信号的数学模型如表1所示,波形图如图2所示。

2 实验设置与结果

本文参考文献[1]和文献[2],在MATLAB环境中随机产生暂升、暂降、中断、谐波、正常、闪变、振荡这8种单一扰动。Matlab产生总共有9000条信号,每条信号的长度是784。其中,前8000个分别是8种信号作为训练集,每种有1000个。后1000个也包括8种信号作为测试集,每种125个采样区间是10个周期也就是0.2s,每秒采样3915次,0.2秒只要采样783次即可,即784个采样点,信号基波频率为50Hz。

本文通过Matlab产生序列,在python中实现CNN,实验配置为MacBook Air (13-inch, 2017)处理器1.8 GHz Intel Core i5,内存8 GB 1600 MHz DDR3。实验python配置为python3.6。

实验分类总共进行50次,统计50次准确率及损失值的结果,准确率如图3所示,损失值如图4所示,最终求去平均值得到最终准确率和损失值,平均扰动准确率为:97.06%,损失值为9.1%。

3 结论

本文提出一种对电能质量进行分类的方法,采用搭建CNN模型来对电能质量进行扰动分类。该算法与以往方法的不同之处在于其得到的分类器不是基于事先确定的扰动模型,而是通过对扰动样本进行深度学习得到的,是一种基于数据的方法,能更好地契合样本的特征。进一步的研究将尝试通过改进卷积网络的结构、引入其他分类器等方式提升CNN的性能,并考虑将其推广运用于电能质量复合扰动的分类。

参考文献:

- [1] 瞿合祚, 李晓明, 陈陈, et al. 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(06): 534-9.
- [2] 王知芳, 杨秀, 潘爱强. 基于卷积神经网络的电能质量扰动分类[A]. 全国电压电流等级和频率标准化技术委员会. 第九届电能质量研讨会论文集[C]. 全国电压电流等级和频率标准化技术委员会: 全国电压电流等级和频率标准化技术委员会秘书处, 2018: 11.
- [3] 陈晓静, 李开成, 肖剑, 等. 一种实时电能质量扰动分类方法[J]. 电工技术学报, 2017, 32(03): 45-55.
- [4] 李晓娜, 沈兴来, 薛雪, 等. 基于改进HHT和决策树的电能质量扰动辨识[J]. 电力建设, 2017, 38(02): 114-121.
- [5] 李庚银, 王洪磊, 周明. 基于改进小波能熵和支持向量机的电能质量扰动识别[J]. 电工技术学报, 2009, 24(04): 161-167.
- [6] 秦英林, 田立军, 常学飞. 基于小波变换能量分布和神经网络的电能质量扰动分类[J]. 电力自动化设备, 2009, 29(07): 64-67.
- [7] 郭俊文, 李开成, 何顺帆, 等. 基于改进不完全S变换与决策树的实时电能质量扰动分类[J]. 电力系统保护与控制, 2013, 41(22): 103-110.
- [8] 尹柏强, 何怡刚, 朱彦卿. 一种广义S变换及模糊SOM网络的电能质量多扰动检测和识别方法[J]. 中国电机工程学报, 2015, 35(04): 866-872.
- [9] 郭俊文, 李开成, 何顺帆, 等. 基于改进不完全S变换与决策树的实时电能质量扰动分类[J]. 电力系统保护与控制, 2013, 41(22): 103-110.
- [10] 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(05): 1272-8.
- [11] 瞿合祚, 刘恒, 李晓明, et al. 一种电能质量多扰动分类中特征组合优化方法[J]. 电力自动化设备, 2017, 37(03): 146-52.