

基于图像处理和深度学习的配网跳闸故障识别方法

杜焯鑫, 谢海宁, 宋杰, 周德生, 邹晓峰, 陈冉, 曾平

(国网上海市电力公司电力科学研究院, 上海 200437)

摘要: 针对当前配网故障类型人工判别工作量大且准确度不高的问题, 提出了一种基于三遥信息处理和深度学习技术的配网故障类型识别方法. 首先通过图像处理技术将遥测电流波形图转为电流数值组, 提取遥信、遥控信号特征, 共同组成特征向量, 并对电流值进行归一化处理; 然后以故障特征为基础, 训练深度神经网络, 实现故障类型识别; 最后对隐含层层数及神经元数目进行调整, 实现模型优化. 实验结果表明, 该方法可实现对配网故障类型的快速判断, 准确率达到 92.4%, 具有实用价值.

关键词: 故障识别; 图像处理; 深度学习; 故障判据; 归一化; 隐含层

中图分类号: TP391 **文献标识码:** A **doi:** 10.3969/j.issn.0253-2778.2020.01.005

引用格式: 杜焯鑫, 谢海宁, 宋杰, 等. 基于图像处理和深度学习的配网跳闸故障识别方法[J]. 中国科学技术大学学报, 2020, 50(1): 39-48.

DU Zhaoxin, XIE Haining, SONG Jie, et al. A trip fault identification method of distribution network based on image processing and deep learning[J]. Journal of University of Science and Technology of China, 2020, 50(1): 39-48.

A trip fault identification method of distribution network based on image processing and deep learning

DU Zhaoxin, XIE Haining, SONG Jie, ZHOU Desheng, ZOU Xiaofeng, ZENG Ping

(State Grid Shanghai Electric Power Research Institute, Shanghai 200437, China)

Abstract: The currently trip fault identification method for distribution networks is mainly based on manual discrimination, which causes the problem of larger workload and lower accuracy. By combining image processing and deep learning technology, automatic identification of distribution network fault types can be realized. First, the telemetry current waveform is converted to a current value group with time stamps by image processing technology. Then feature vectors are constructed with telecommunicating signal, telecontrol signal and normalized current value. Based on the fault type criterion, the deep neural network model is built and trained to realize fault type identification. Finally, the model is optimized by adjusting the number of hidden layers and neurons in the deep neural network. The experimental results show that the types of trip fault can be identified quickly with the proposed method, that and the accuracy is better than existing methods, which means the new method is practical and effective.

Key words: fault identification; image processing; deep learning; fault type criterion; normalized processing; hidden layer

收稿日期: 2019-05-15; 修回日期: 2019-09-28

作者简介: 杜焯鑫(通讯作者), 男, 1992年生, 硕士/工程师, 研究方向: 智能电网. E-mail: duzx01@126.com

0 引言

随着电网规模的快速扩大,电网结构日趋复杂,由于设备基数的增加,设备老化、失效等问题不可避免,配网跳闸故障情况逐渐暴露.由于天气原因,如台风、雷暴等极端气象条件造成的配网跳闸故障也不可避免,因此在跳闸故障发生后,能够快速有效地对故障类型进行识别,对配网故障情况下的安全稳定运行至关重要.

当前配网故障统计方式一般为,以配网遥信、遥测、遥控信息为判断基础,辅以专业人员的判断,进行故障确认,并将跳闸故障按照跳闸方式,分为直接跳闸、重合成功、重合失败和非故障跳闸 4 类.配网故障统计需要处理的数据量较大,每年的故障信息可达到数万条;遇到恶劣天气时,当日故障信息可达数百条,这也导致单纯依靠人工方法分析配网故障情况,不仅工作量大,而且准确性和效率均一般^[1-3],因此,采用辅助算法进行配网故障分析是实现提高故障识别效率,减少人力投入的重要手段.

对于大量配网故障数据的处理分析,通常可采用人工智能方法,如使用人工神经网络、专家系统、模糊系统、概率模型等^[4-6].人工神经网络因其结构简单、学习能力强、泛化能力好的特点,具备一定的优势,但仍然存在特征提取能力不够强、无法建立较为完备的训练样本等,导致配网故障识别的准确

度不高等问题.专家系统可以根据知识库内容进行数据归类,准确度有所提升,但存在知识库信息量大,建立难度大,需要对知识库进行反复更新,无法进行实时配网故障分析等问题.模糊系统作为更高级的专家系统,具有更加完备的推理体系,尤其是容错性方面有较大提升,但同样存在规则库维护难度大、缺乏自学能力.对于概率模型来说,其与人工神经网络类似,均需要进行模型搭建与训练,且所需的数据量更大,训练难度更高,同时计算结果为概率值,无法对配网故障类型进行精准分类.

近年来兴起的深度学习技术^[7-10]采用了更深的神经网络、更优的激活函数和学习算法,相较于传统人工神经网络,有着更强的特征提取能力,更能挖掘蕴含在故障数据中的特征.为此,本文将图像处理技术与深度学习技术相结合^[11-15],以配网三遥信息中的遥测波形图及遥信、遥控变位信号作为判定条件,以故障特征作为判定依据,形成一种可以有效提高配网故障类型识别准确度和速度的判定方法.

1 数据来源

1.1 历史故障数据获取

图 1 所示为上海电网当前的配网故障信息系统.通过该系统可获得遥信变位告警信号、遥测采样数据、遥控操作记录等数据,形成原始的历史故障数据.

| 序号 | 供电公司 | 厂站 | 新站器 | 新站器类型 | 电压等级 | 发生时间 | 内容 | 确认标记 | 数据来源 | 事件来源 | 备注 | 备注情况 | 操作详情 |
|----|------|-----------|--------------|-------|------|---------------------|--------------------------------|------|------------|----------|----|------|------|
| 1 | 松江 | 35kV数据开关站 | 数据30141_开关 | 线路 | 35kV | 2018-05-10 11:00:17 | [SCADA]35kV数据开关站 数据30141_开关 分 | 非故障 | 间接事件: 遥信变位 | GFER3000 | | 直接跳闸 | |
| 2 | 松江 | 35kV数据开关站 | 数据953_开关 | 线路 | 35kV | 2018-05-08 16:38:18 | [SCADA]35kV数据开关站 数据953_开关 分 | 非故障 | 间接事件: 遥信变位 | GFER3000 | | 直接跳闸 | |
| 3 | 松江 | 35kV数据开关站 | 数据953_开关 | 线路 | 35kV | 2018-05-10 11:05:26 | [SCADA]35kV数据开关站 数据953_开关 分 | 非故障 | 间接事件: 遥信变位 | GFER3000 | | 直接跳闸 | |
| 4 | 松江 | 35kV数据开关站 | 数据199_开关 | 线路 | 35kV | 2018-06-15 15:02:33 | [SCADA]35kV数据开关站 数据199_开关 分 | 非故障 | 间接事件: SOE | GFER3000 | | 直接跳闸 | |
| 5 | 松江 | 35kV数据开关站 | 数据3012_开关 | 线路 | 35kV | 2018-06-15 15:04:03 | [SCADA]35kV数据开关站 数据3012_开关 分 | 非故障 | 间接事件: SOE | GFER3000 | | 直接跳闸 | |
| 6 | 青浦 | 9018新康站 | 夏康3627_小车开关 | 线路 | 35kV | 2018-11-20 10:59:57 | [SCADA]9018新康站 夏康3627_小车开关 分 | 非故障 | 直接事件: 事故分闸 | GFER3000 | | 直接跳闸 | |
| 7 | 青浦 | 9018新康站 | 夏康3620_小车开关 | 线路 | 35kV | 2018-11-20 09:19:19 | [SCADA]9018新康站 夏康3620_小车开关 分 | 非故障 | 直接事件: 事故分闸 | GFER3000 | | 直接跳闸 | |
| 8 | 青浦 | 9018新康站 | 夏康3620_小车开关 | 线路 | 35kV | 2018-11-20 09:19:48 | [SCADA]9018新康站 夏康3620_小车开关 分 | 非故障 | 直接事件: 事故分闸 | GFER3000 | | 直接跳闸 | |
| 9 | 青浦 | 9018新康站 | 夏康3627_小车开关 | 线路 | 35kV | 2018-11-20 12:17:01 | [SCADA]9018新康站 夏康3627_小车开关 分 | 非故障 | 直接事件: 事故分闸 | GFER3000 | | 直接跳闸 | |
| 10 | 青浦 | 9018新康站 | 夏康3620_小车开关 | 线路 | 35kV | 2018-11-20 10:47:55 | [SCADA]9018新康站 夏康3620_小车开关 分 | 非故障 | 直接事件: 事故分闸 | GFER3000 | | 直接跳闸 | |
| 11 | 青浦 | 9018新康站 | 夏康36017_小车开关 | 线路 | 35kV | 2018-11-20 11:19:59 | [SCADA]9018新康站 夏康36017_小车开关 分 | 非故障 | 间接事件: 遥信变位 | GFER3000 | | 直接跳闸 | |

图 1 配网故障信息系统

Fig. 1 Interface of distribution network trip fault information system

本文采用的快速识别技术将主要依托于对遥信变位告警、遥测采样图像进行细化分析并经过深度学习后,形成自主判别功能.

1.2 电流数据提取

图 2(a)所示为系统中遥测采样图像原图,将遥测采样图像数据化是数据处理中的关键步骤.本文

采用图像二值处理法^[16-17],根据像素颜色(深度)差异进行数值提取,将满足图形颜色的像素点取值为 1,不满足图形颜色的像素点取值为 0,由此形成一个二值逻辑数组.将取值为 1 的点显示为白色,取值为 0 的点显示为黑色,由此得到一组具有典型波形元素特征的二值化图像,如图 2(b)、(c)、(d)所示.

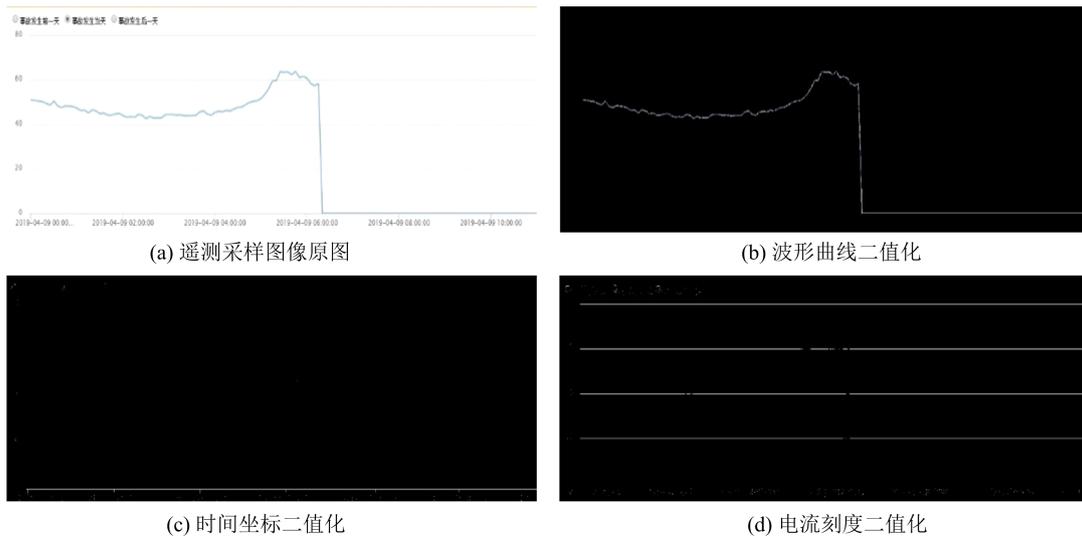


图 2 二值化处理结果

Fig. 2 Image binarization results

图像细化算法对于条纹信息的提取有重要作用^[18-19],因此使用图像细化算法处理电流波形,可提取出电流曲线的像素坐标.经过细化算法处理后的电流波形如图 3 所示.



图 3 细化后的电流波形

Fig. 3 Current image after refinement algorithm

横坐标上的点表示电流数据的时间标签,从坐标轴直线的尺度来看,与其垂直的短刻度线可以看作角点,使用 Harris 角点检测算法^[20-21]提取横轴上的原点及各坐标点间距 Δx ,如图 4 所示.

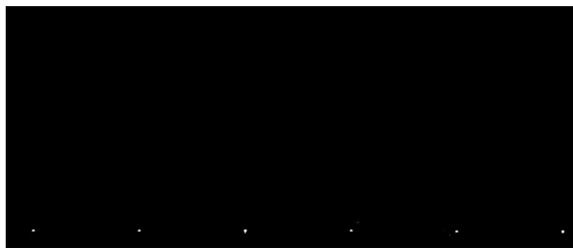


图 4 横轴坐标点提取

Fig. 4 Extraction of abscissa points

霍夫变换^[22-24]可用于识别图像中的特定几何形状,因此可使用霍夫变换检测电流刻度图中的直线,得到像素坐标,并根据端点坐标可计算出直线间距离 Δy .

对于像素矩阵化的原始遥测图像,设定横、纵坐标单位间距代表的真实尺度为 a 、 b (在遥测图中, $a=2h$, $b=20$ A),横坐标第一个点为坐标轴原点 (x_0, y_0) ,则对于离散电流坐标点 (x_k, y_k) ,其真实时刻 t 和电流值 I 可以用公式计算得到,即

$$t = \frac{(y_k - y_0) * a}{\Delta x} \quad (1)$$

$$I = \frac{(x_0 - x_k) * b}{\Delta y} \quad (2)$$

使用描点法对计算电流值进行重新绘图,结果如图 5 所示.

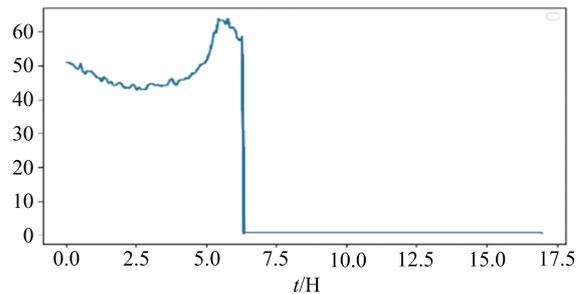


图 5 计算电流值波形图

Fig. 5 Waveform of recalculated current value

对该图像采用线性插值法拟合,即可提取任意时刻的电流值.本文采用开关动作时间为分界点,采样间隔为 5 min,提取包括动作时间前 5 点、后 6 点在内共 12 个时间点的电流数据,作为判断依据.如提取 $t=6.42$ (6 时 25 分) 时刻前后半个小时的 12 个数据点,采用保留小数点后一位的值,结果如表 1 所示.

表 1 6 时 25 分前后电流拟合结果

Tab. 1 Current fitting results before and after 6:25

| 时间刻度 | 实际时间 | 电流值/A |
|------|------|-------|
| 6.00 | 6:00 | 61.1 |
| 6.08 | 6:05 | 59.3 |
| 6.17 | 6:10 | 57.9 |
| 6.25 | 6:15 | 58.0 |
| 6.33 | 6:20 | 26.7 |
| 6.42 | 6:25 | 0.0 |
| 6.50 | 6:30 | 0.0 |
| 6.58 | 6:35 | 0.0 |
| 6.67 | 6:40 | 0.0 |
| 6.75 | 6:45 | 0.0 |
| 6.83 | 6:50 | 0.0 |
| 6.92 | 6:55 | 0.0 |

2 样本数据处理

2.1 样本输入

样本的输入共包括 3 部分:第一部分为遥控信号;第二部分为遥信信号,即配网跳闸动作信号;第三部分为电流信号,其中除电流信号需通过图像处

理进行数据化,遥控信号和跳闸动作信号均可直接从系统中导出。

是否具有遥控信号数据,可以作为此次开关是否人为遥控操作的判据.若为遥控操作则直接进行非故障判定.遥控信号可通过是否有遥控操作记录进行判别.样本中,将遥控信号用 1 位数表示,如图 6 所示.其中,1 表示开关动作是人为遥控,0 表示开关动作非人为遥控。



图 6 遥控操作信号处理示意图

Fig. 6 Processing of telecontrol signal

配网跳闸动作信号如图 7 所示.在一组动作信号中,1 表示开关动作,0 表示无开关动作.正常重合闸动作信号为分合分,占用 3 位数;较恶劣情况会出现分合+分合分,占用 5 位数;同时存在检修操作中造成的开关反复动作.为保证能覆盖各类动作情况,样本共设置了 11 位数来表示其开关动作情况。

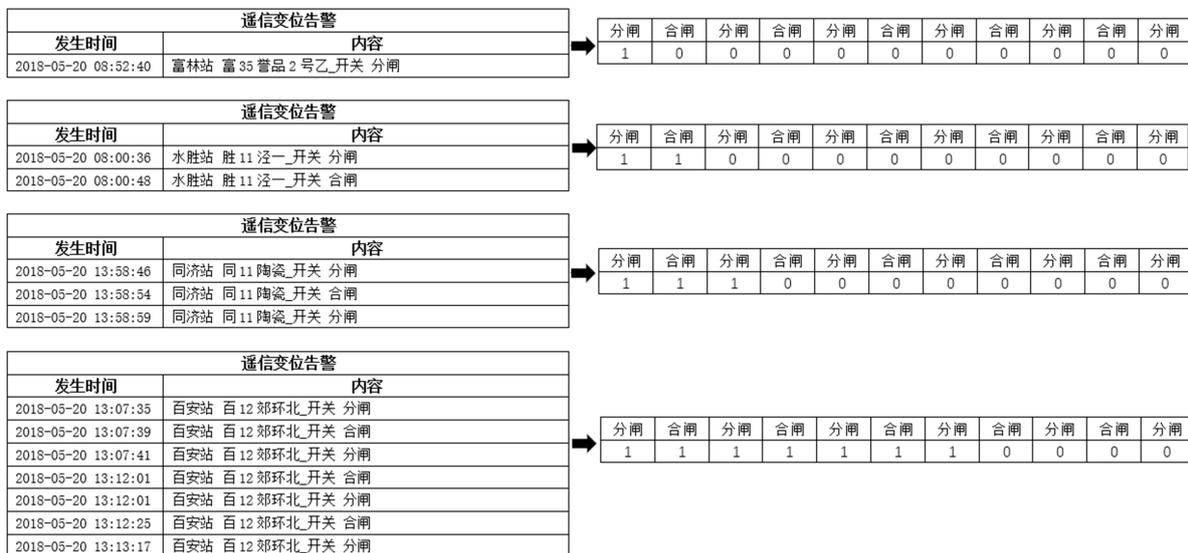


图 7 配网跳闸动作信号处理示意图

Fig. 7 Processing of telecommunicating signal

对于电流信号,如 1.2 节说明,共有 12 位数用来表示电流值.若出现故障点位于遥测图形末端,会导致故障点前后时间节点不够 12 个时刻.对于这种

情况,由于深度神经网络只能输入固定维度的数据,故本文采用以最后一个时刻的电流数据填充缺失部分的方法,将不足 12 位的电流信号补足至 12 位.该

方法可以避免填充电流数据的波动,而故障跳闸类型的识别依赖于电流波动情况,因此该填充方法不会影响最终的分类判断。

将遥控操作信号(1 维)、配网跳闸动作信号(11 维)和对应电流信号(12 维)堆叠在一起,便形成了 24 维的样本输入矩阵 $M_i = [I_1, I_2, \dots, I_{24}]$ 。

2.2 样本输出

样本的输出为配网故障跳闸类型,即直接跳闸、重合成功、重合失败、非故障跳闸、异常数据。样本的输出共 5 维,以矩阵 $M_o = [O_1, O_2, \dots, O_5]$ 表示,根据数值的不同分别表示 5 种类型,如表 2 所示。

表 2 故障类型矩阵
Tab. 2 Matrix of fault type

| 故障类型 | 矩阵构型 | | | | |
|------|------|---|---|---|---|
| 直接跳闸 | 1 | 0 | 0 | 0 | 0 |
| 重合成功 | 0 | 1 | 0 | 0 | 0 |
| 重合失败 | 0 | 0 | 1 | 0 | 0 |
| 非故障 | 0 | 0 | 0 | 1 | 0 |
| 异常数据 | 0 | 0 | 0 | 0 | 1 |

针对每一类型的故障,根据遥控信号、开关动作信号及电流信号,通过判别方式^[25]为各样本打上标签。在进行样本训练的过程中,样本数据的标签需要人工判别及设置。

2.2.1 直接跳闸判定

- (I) 遥控信号:非遥控操作;
- (II) 开关动作信号:开关执行分闸操作;
- (III) 电流信号:电流数值随即掉零(特指电流值小于 5A)。

2.2.2 重合成功判定

- (I) 遥控信号:非遥控操作;
- (II) 开关动作信号:开关先执行分闸操作,并于 30 s 内执行合闸操作;

(III) 电流信号:电流数值随开关动作变化先下降、后上升。

2.2.3 重合失败判定

- (I) 遥控信号:非遥控操作;
- (II) 开关动作信号:开关先执行分闸操作,并于 30s 内执行合闸操作,后于 30 s 内执行分闸操作;

(III) 电流信号:电流数值随开关动作变化先下降、后上升,最后掉零。

2.2.4 非故障跳闸判定

非故障跳闸主要包括以下几种情况:

(I) 遥控操作;

(II) 开关先后执行了分闸、合闸操作,但分闸前和分合闸后 30 min 内的电流始终保持小于 5 A;

(III) 开关仅执行了分闸操作,但分闸前后 30 min 内的电流始终保持小于 5 A;

(IV) 在 15 min 内,开关连续执行分闸、合闸操作大于或等于 6 次,且电流随开关动作同步发生波形大幅波动;

(V) 在 15 min 内,开关连续执行分闸、合闸操作大于或等于 6 次,且电流始终保持小于 5 A。

2.2.5 异常数据判定

异常数据主要包括以下几种情况(均为非遥控情况下):

(I) 开关执行分闸操作后,电流数据却并未掉零;

(II) 开关在断开情况下,先后执行了合闸、分闸操作,但开关经过合闸、分闸前后 30 min 内,电流始终未掉零;

(III) 在 15 min 内,开关连续执行分闸、合闸操作大于或等于 6 次,且电流始终未掉零;

(IV) 电流值与跳闸动作信号时间不匹配,导致电流数据所覆盖的时刻并未包含故障发生时刻的情况。

2.3 数据归一化

在整理好样本的输入、输出后,采用 z -score 标准化方法对样本数据进行归一化处理^[26-28]。

由于样本数据存在特殊性,样本中的遥控信号和跳闸信号的值均为 0 或 1,无需归一化,因此只需对电流数据进行了归一化预处理。常规的 z -score 方法是先计算每一维数据的均值和标准差,然后对每一维的数据进行归一化处理。考虑到跳闸故障类型的判断依赖于电流数据的波动,若对每一维数据单独处理,由于不同维度数据的均值和标准差不同,可能会在归一化处理中造成电流数据波动发生改变,导致样本失真,从而影响识别结果,因此为使归一化前后的电流数据波动情况不发生改变,本文通过计算所有维度电流的均值和标准差,并使所有数据在执行归一化时均使用该均值和标准差,以克服此类情况的发生。

3 基于深度学习的故障类型识别算法

3.1 有监督训练算法

本文采用深度神经网络(deep neural network,

DNN)来实现配网跳闸故障的识别,DNN 的结构如图 8 所示.将归一化后的数据以矩阵形式输入到 DNN 模型中,DNN 模型将映射出对应的故障类型.

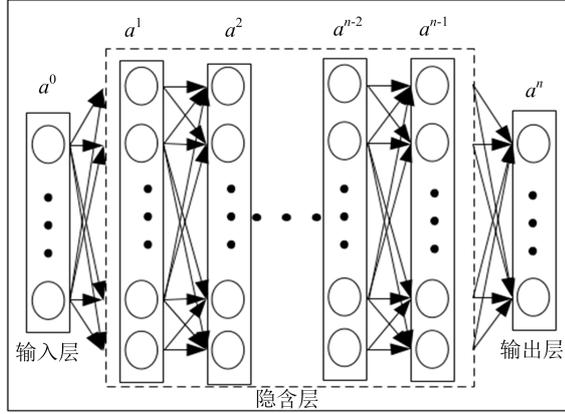


图 8 深度神经网络结构示意图

Fig. 8 Structure of deep neural network

DNN 由输入层、多个隐含层以及输出层构成,层与层之间以全连接的方式连接在一起. DNN 的前向数据传递函数为

$$\hat{y} = a^n = s(\mathbf{W}^n a^{n-1} + \mathbf{b}^n) \quad (3)$$

式中, a^n 代表第 n 层神经元的输出,输入 x 则表示为 a^0 , \mathbf{W}^n 为连接第 $n-1$ 层和第 n 层神经元的权值参数矩阵, \mathbf{b}^n 为第 n 层神经元的偏置参数矩阵.函数 $s(x)$ 为激活函数,本文在隐含层和输出层分别采用了不同的激活函数.

在隐含层,本文选用 LReLU (leaky rectified linear unit) 作为激活函数,即

$$s(x) = \max(0.01x, x) \quad (4)$$

LReLU 激活函数是一个分段线性函数,计算速度较快.当输入值 x 小于或等于零时,其输出值等于 $0.01x$;当输入值 x 大于零时,其输出值等于输入值 x .

在输出层,由于配网故障类型识别属于多分类问题,故选用 softmax 作为激活函数,即

$$s(x_i) = \frac{e^{x_i}}{\sum_k e^{x_k}} \quad (5)$$

式中, k 表示输出值 x 的第 k 维.

DNN 模型的训练包括前向传递和反向传播两个阶段^[29],其中反向传播的目的是当实际输出与样本实际标签误差较大时,可通过不断地修正自身的权重参数 \mathbf{W} 和偏置参数 \mathbf{b} ,使得 DNN 模型的输出和样本的实际标签一致. DNN 模型的输出和样本实际标签的差异可用损失函数 L 衡量.针对本文所涉及的多分类问题,本文选择了适用的对数似然函数

作为损失函数,即

$$L = \frac{1}{m} \sum_j \sum_k y_k \log \hat{y}_k \quad (6)$$

式中, m 为样本数, j 表示第 j 个样本, k 表示某一样本输出的第 k 维, y 表示样本的实际标签, \hat{y} 表示 DNN 的预测输出.

计算得到损失函数后,通过反向传播算法可实现神经网络参数的调整.本文中,反向传播算法采用均方根传播 (RMSProp) 与学习率衰减相结合的混合算法.均方根传播算法可以保持参数的平方梯度的移动平均数不变,使每个参数的步长自适应地更新,加快参数的收敛速度;学习率衰减算法可随着训练的进行逐渐降低学习率,避免算法来回振荡.本文所用反向传播算法的具体公式为

$$d\theta^{(k)} = \nabla_{\theta^{(k-1)}} L \quad (7)$$

$$r^{(k)} = \rho r^{(k-1)} + (1 - \rho) d\theta^{(k)} \odot d\theta^{(k)} \quad (8)$$

$$\Delta\theta^{(k)} = \frac{\alpha^{(k)}}{\sqrt{\delta + r^{(k)}}} \odot d\theta^{(k)} \quad (9)$$

$$\theta^{(k)} = \theta^{(k-1)} - \Delta\theta^{(k)} \quad (10)$$

$$\alpha^{(k)} = \begin{cases} \epsilon^{k-1} \alpha_0, & \text{if } \epsilon^{k-1} \alpha_0 > 0.00001 \\ 0.00001, & \text{if } \epsilon^{k-1} \alpha_0 < 0.00001 \end{cases} \quad (11)$$

式(7)计算了各参数的梯度,其中 $d\theta^{(k)}$ 是第 k 次更新时 θ 的梯度, $\theta^{(k-1)}$ 是在第 k 次更新之前的系数, $\nabla_{\theta^{(k-1)}} L$ 是在第 k 次更新时 θ 对于损失函数的偏导;式(8)计算了第 k 次更新时参数的平方梯度的移动平均数 $r^{(k)}$,其中 ρ 是衰减率, \odot 代表 Hadamard 乘积;式(9)计算了各参数在第 k 次更新时的改变量 $\Delta\theta^{(k)}$,其中 $\alpha^{(k)}$ 是在第 k 次更新时的学习率, δ 是为了防止出现 $\sqrt{r} = 0$ 而设置的常数;式(10)完成了对参数的调整,其中 $\theta^{(k)}$ 是在第 k 次更新后的参数;式(11)为本文所用的学习率调整策略,其中 α_0 代表学习率的初始值, ϵ 表示学习率的衰减率.公式的详细参数设置如表 3 所示.

表 3 参数设置表

Tab. 3 Parameter configuration list

| 参数 | 数值 |
|------------|-----------|
| ρ | 0.9 |
| δ | 10^{-8} |
| α_0 | 0.001 |
| ϵ | 0.95 |

由此完成了训练模型的搭建,其训练步骤如下:
Step1 初始化 DNN 模型参数,包括隐含层层

数、每层神经元数、权重参数、偏置参数、均方根传播参数和学习率衰减参数；

Step2 导入训练样本集，样本集由若干样本矩阵 M_i 组合而成；

Step3 执行数据前向传递运算，得到 DNN 的实际输出；

Step4 将 DNN 实际输出与样本实际标签对比，计算损失函数 L ；

Step5 根据损失函数 L 进行反向传播运算，得到各参数改变量，并进行参数调整；

Step6 更新参数后继续执行前向传递运算，直至损失函数降低至目标值 0.1 或迭代次数达到上限 5 万次。

完成训练后，DNN 可由历史故障数据直接映射得到对应的跳闸故障类型。

3.2 模型优化

DNN 模型的结构对最终训练效果有着重要影响。若 DNN 的结构太简单，将难以有效提取蕴含在故障数据中的特征，导致模型欠拟合，使得最终效果不理想；过于复杂的 DNN 模型结构，则会导致 DNN 所需调整寻优的参数过度，给训练过程带来困难，同时容易导致模型过拟合，使得最终效果不理想。由此可见，适当的模型结构复杂度对 DNN 模型的效果至关重要，但目前对于 DNN 模型结构的设定尚未有成熟的理论支撑，仍需经过大量的实验来确定最终的模型结构。

DNN 的输入层和输出层的维度由样本的输入和输出维度决定，故需要设定的模型结构参数为隐含层的层数以及每层的神经元数目。由于隐含层层数及每层神经元数目存在无数种搭配组合，不可能完全考虑到所有可能组合，因此首先固定隐含层层数为 6 层，然后调整每层神经元数目（每层神经元数目增加或减少 10 个），选取 300 个样本进行测试，实验结果如表 4 所示。

由表 4 可见，当 DNN 结构设为 6 层、每层 90 个神经元时，模型的准确率最高，为 93.00%。为了进一步寻找更优的结构，将隐含层神经元总数定为 $6 \times 90 = 540$ ，然后调整隐含层层数，进行模型结构的对比实验。隐含层层数为 7 和 8 时，为使隐含层神经元总数为 540，最后一个隐含层分别设为了 78 和 71。由表 5 可见，当 DNN 结构设为 5 层每层 108 个神经元时，模型的准确率最高，为 93.67%。

表 4 每层神经元数对准确率的影响

Tab. 4 Accuracy result under different layer neurons number

| 隐含层层数 | 每层神经元数 | 准确率 |
|-------|--------|--------|
| 6 | 10 | 89.33% |
| 6 | 20 | 90.33% |
| 6 | 30 | 91.67% |
| 6 | 40 | 91.00% |
| 6 | 50 | 91.33% |
| 6 | 60 | 89.00% |
| 6 | 70 | 91.00% |
| 6 | 80 | 92.33% |
| 6 | 90 | 93.00% |
| 6 | 100 | 91.33% |
| 6 | 110 | 91.67% |
| 6 | 120 | 90.00% |

表 5 隐含层层数对准确率的影响

Tab. 5 Accuracy result under different hidden layer number

| 隐含层层数 | 每层神经元数 | 准确率 |
|-------|--------|--------|
| 1 | 540 | 90.00% |
| 2 | 270 | 92.33% |
| 3 | 180 | 92.33% |
| 4 | 135 | 90.67% |
| 5 | 108 | 93.67% |
| 6 | 90 | 93.00% |
| 7 | 77 | 91.33% |
| 8 | 67 | 91.00% |
| 1 | 540 | 90.00% |
| 2 | 270 | 92.33% |
| 3 | 180 | 92.33% |
| 4 | 135 | 90.67% |

综上所述，最终选择的模型结构为 24-108-108-108-108-108-5，24 和 5 分别为输入层和输出层神经元数，108 为隐含层神经元数。

4 操作流程及仿真结果

本文所使用的基于深度神经网络的配网跳闸故障类型快速识别方法，其深度神经网络的训练及应用流程如图 9 所示，其应用具体步骤如下：

(I)通过上海电网目前具备的配网故障信息系统,获得历史故障数据,其中对于遥测波形图,采用图像识别技术将图像拟合为电流数值数据;

(II)通过输入、输出向量构造方法将历史故障数据转换成适用于作为 DNN 输入的形式,从而形成样本的输入,并为每一个样本打上标签,作为样本的实际输出。

(III)计算所有样本数据电流值的均值和标准差,采用 z -score 标准化方法对训练样本的电流数

据进行归一化预处理。

(IV)将归一化后的数据以矩阵形式全部输入训练好的 DNN 模型中,DNN 模型可一次性映射出所有故障数据对应的故障类型。

截至目前,共整理形成了 6 620 个样本.将其中 2 620 个作为训练样本,用来训练深度神经网络,剩余 4 000 个样本作为测试样本,测试网络的效果.经训练后,在训练样本集上的识别准确率为 93.51%,在测试集上的识别准确率为 92.43%。

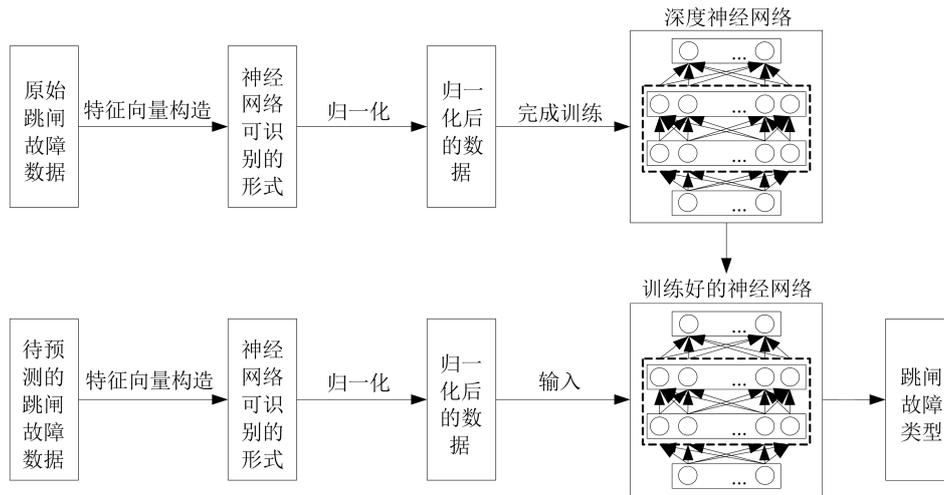


图 9 跳闸故障类型识别流程

Fig. 9 Processing of trip fault type identification

5 结论

本文针对配网跳闸故障识别处理中存在的数量大,人工判断耗时长且准确度待提升等问题,提出了基于图像处理和深度学习的配网跳闸故障识别方法.通过该方法,可以根据配网故障统计系统中配网开关变位遥信数据、电流遥测数据和遥控操作记录,对故障直接跳闸、故障重合闸成功、故障重合闸不成功、非故障跳闸等不同跳闸情况进行自动识别.该方法可实现对配网运行情况和故障情况的准确了解,同时可简化配网系统的运行操作步骤,提升配网跳闸事故分析及处理效率.同时,对异常数据进行标记,方便数据运维人员对异常数据出现的原因进行分析及处理.依托于深度神经网络技术,对配网运行架构中的人工智能应用场景进行进一步挖掘,将有助于推进配电网网架结构的优化、配网智能运维方式的变革和运行效率的提升。

参考文献(References)

[1] 张旭,魏娟,赵冬梅,等. 电网故障诊断的研究历程及展

望[J]. 电网技术,2013,37(10):2745-2753.

ZHANG Xu, WEI Juan, ZHAO Dongmei, et al. Research course and prospects of power grid fault diagnosis[J]. Power System Technology, 2013, 37(10):2745-2753.

[2] 陈永章. 10kV 配网运行事故原因分析及预防措施[J]. 机电信息,2014, (24):10-11.

[3] CHEN Wenhui. Online fault diagnosis for power transmission networks using fuzzy digraph models[J]. IEEE Transactions on Power Delivery, 2012, 27(2): 688-698.

[4] 侯仁政,张岩,张小易,等. 基于多源数据融合的电力系统故障诊断与评估平台开发[J]. 机电工程,2017, 34(10):1173-1179.

HOU Renzheng, ZHANG Yan, ZHANG Xiaoyi, et al. Power system fault diagnosis and evaluation platform based on multi-source data fusion[J]. Mechanical & Electrical Engineering Magazine, 2017, 34(10): 1173-1179.

[5] WEI L, GUO W, WEN F, et al. An online intelligent alarm-processing system for digital substations [J]. IEEE Transactions on Power Delivery, 2011, 26(3): 1615-1624.

- [6] ZHANG Y, CHUNG CY, WEN F S, et al. An analytic model for fault diagnosis in power systems utilizing redundancy and temporal information of alarm messages[J]. IEEE Transactions on Power Systems, 2016, 31(6): 4877-4886.
- [7] 孙达昌, 毕秀春. 基于深度学习算法的高频交易策略及其盈利能力[J]. 中国科学技术大学学报, 2018, 48(11): 923-932.
SUN Dachang, BI Xiuchun. Research on the high-frequency trading strategies based on deep learning algorithms and its profitability [J]. Journal of University of Science and Technology of China, 2018, 48(11): 923-932.
- [8] BRONSTEIN M M, BRUNA J, LECUN Y, et al. Geometric deep learning: going beyond Euclidean data [J]. IEEE Signal Processing Magazine, 2017, 34(4): 18-42.
- [9] KHADSE C B, CHAUDHARI M A, BORGHATE V B. Electromagnetic compatibility estimator using scaled conjugate gradient back-propagation based artificial neural network [J]. IEEE Transactions on Industrial Informatics, 2017, 13(3): 1036.
- [10] 陈东杰, 张文生, 杨阳. 基于深度学习的高铁接触网定位器检测与识别[J]. 中国科学技术大学学报, 2017, 47(4): 320-327.
CHEN Dongjie, ZHANG Wensheng, YANG Yang. Detection and recognition of high-speed railway catenary locator based on deep learning[J]. Journal of University of Science and Technology of China, 2017, 47(4): 320-327.
- [11] ZHONG P, GONG Z Q, LI S T, et al. Learning to diversify deep belief networks for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(6): 3516-3530.
- [12] 郑远攀, 李广阳, 李晔. 深度学习在图像识别中的应用研究综述[J/OL]. 计算机工程与应用, 2019, 55(12): 20-36.
ZHENG Yuanpan, LI Guangyang, LI Ye. Survey of application of deep learning in image recognition[J]. Computer Engineering and Applications, 2019, 55(12): 20-36.
- [13] 刘栋, 李素, 曹志冬. 深度学习及其在图像物体分类与检测中的应用综述[J]. 计算机科学, 2016, 43(12): 13-23.
LIU Dong, LI Su, CAO Zhidong. State-the-art on deep learning and its application in image object classification and detection [J]. Computer Science, 2016, 43(12): 13-23.
- [14] DONG Yu, LI Deng. Deep learning and its applications to signal and information processing[J]. IEEE Signal Processing Magazine, 2011, 28(1): 145-154.
- [15] 金连文, 钟卓耀, 杨钊, 等. 深度学习在手写汉字识别中的应用综述[J]. 自动化学报, 2016, 42(8): 1125-1141.
JIN Lianwen, ZHONG Zhuoyao, YANG Zhao, et al. Applications of deep learning handwritten Chinese character recognition: A review [J]. Acta Automatica Sinica, 2016, 42(8): 1125-1141.
- [16] 江辉, 郑岳怀, 王志忠, 等. 基于数字图像处理技术的暂态电能质量扰动分类[J]. 电力系统保护与控制, 2015, 43(13): 72-78.
JIANG Hui, ZHENG Yuehuai, WANG Zhizhong, et al. An image processing based method for transient power quality [J]. Power System Protection and Control, 2015, 43(13): 72-78.
- [17] 卢迪, 黄鑫, 柳长源, 等. 基于区域对比度增强的二值化算法[J]. 电子与信息学报, 2017, 39(01): 240-244.
LU Di, HUANG Xin, LIU Changyuan, et al. Binarization method based on local contrast enhancement [J]. Journal of Electronics & Information Technology, 2017, 39(01): 240-244.
- [18] 陈树, 杨天. 一种基于改进 ZS 细化算法的指针仪表检测[J]. 计算机工程, 2017, 43(12): 216-221.
CHEN Shu, YANG Tian. A pointer meter detection based on improved ZS refinement algorithm [J]. Computer Engineering, 2017, 43(12): 216-221.
- [19] 薛亚男, 辛化梅. ESPI 图像的细化算法改进[J]. 电子技术, 2018, 47(11): 35-37.
XUE Yanan, XIN Huamei. Refinement algorithm improvement for ESPI image [J]. Electronic Technology, 2018, 47(11): 35-37.
- [20] 董立红, 彭业勋, 符立梅. 基于 Sobel 边缘检测的圆周 Harris 角点检测算法[J]. 西安科技大学学报, 2019, 39(2): 374-380.
DONG Lihong, PENG Yexun, FU Limei. Circular Harris corner detection algorithm based on Sobel edge detection [J]. Journal of Xi'an University of Science and Technology, 2019, 39(2): 374-380.
- [21] 赵小强, 张源峰. 基于 Harris 自相关矩阵的迹和改进灰度值特征的高速匹配算法[J]. 兰州理工大学学报, 2018, 44(05): 108-113.
ZHAO Xiaoqiang, ZHANG Yuanfeng. High-speed image matching based on trace of Harris autocorrelation matrix and improved gray scale value feature [J]. Journal of Lanzhou University of Technology, 2018, 44(05): 108-113.
- [22] YU Xuemei, SUN Yaojie. Research on parking detecting analysis based on projection transformation and Hough transform [J]. Journal of Physics: Conference Series, 2019, 1187(4): 1-5.
- [23] 崔晓杰, 王家耀, 巩现勇, 等. 基于改进霍夫变换的环形

- 交叉口识别方法[J]. 测绘学报, 2018, 47(12): 1670-1679.
- CUI Xiaojie, WANG Jiayao, GONG Xianyong, et al. Roundabout recognition method based on improved hough transform[J]. Acta Geodaetica et Cartographica Sinica, 2018, 47(12): 1670-1679.
- [24] 姜成恒, 王剑峰, 王传旭. 基于霍夫变换的数字水印算法在电子印章中的应用[J]. 青岛科技大学学报, 2019, 40(2): 108-112, 118.
- JIANG Chengheng, WANG Jianfeng, WANG Chuanxu. Application of digital watermarking algorithm based on hough transform in electronic stamp[J]. Journal of Qingdao University of Science and Technology, 2019, 40(2): 108-112, 118.
- [25] 宋杰, 谢海宁, 杨增辉, 等. 基于多源异构数据挖掘的配电网故障信息统计分析[J]. 电力系统保护与控制, 2016, 44(3): 141-147.
- SONG Jie, XIE Haining, YANG Zenghui, et al. Statistical analysis of the distribution fault based on multiple source and isomerism data mining technology [J]. Power System Protection and Control, 2016, 44(3): 141-147.
- [26] 柳小桐. BP 神经网络输入层数据归一化研究[J]. 机械工程与自动化, 2010(3): 122-123, 126.
- LIU Xiaotong. Study on data normalization in BP neural network[J]. Mechanical Engineering & Automation, 2010(3): 122-123, 126.
- [27] 郭志军, 杨亚锋, 吴静波, 等. 基于小波包神经网络的开关电源电路故障诊断研究[J]. 现代电子技术, 2019, 42(7): 125-128.
- GUO Zhijun, YANG Yafeng, WU Jingbo, et al. Study on switching power supply circuit fault diagnosis based on wavelet packet neural network [J]. Modern Electronics Technique, 2019, 42(7): 125-128.
- [28] GASHTEROODKHANI O A, MAJIDI M, FADALI M S, et al. A protection scheme for microgrids using time-time matrix z -score vector [J]. International Journal of Electrical Power and Energy Systems, 2019, 110: 400-410.
- [29] 李智, 侯兴哲, 刘永相, 等. 基于深度学习的充电站容量规划方法[J]. 电力系统保护与控制, 2017, 45(21): 67-73.
- LI Zhi, HOU Xingzhe, LIU Yongxiang, et al. A capacity planning method of charging station based on depth learning [J]. Power System Protection and Control, 2017, 45(21): 67-73.