

引用格式: 蔡高凤, 王庆斌, 陈镇宇, 等. 基于离散小波变换和 GRU 的触电诊断分析 [J]. 南方能源建设, 2024, 11(4): 127-136. CAI Gaofeng, WANG Qingbin, CHEN Zhenyu, et al. Analysis on electrocution diagnosis based on discrete wavelet transform and GRU [J]. Southern energy construction, 2024, 11(4): 127-136. DOI: 10.16516/j.ceec.2024.4.13.

基于离散小波变换和 GRU 的触电诊断分析

蔡高凤[✉], 王庆斌, 陈镇宇, 徐桂培, 冯家琪, 罗棋昌

(广东电网有限责任公司云浮供电局, 广东 云浮 527300)

摘要: [目的]在低压配电网中, 作为用电安全的一种重要保障, 剩余电流保护装置可减小用电器发生漏电故障而带来的危害, 还可预防人体触电事故的发生。当前剩余电流保护装置依靠剩余电流信号大小作为保护机构动作的依据, 无法识别触电特征。针对这个问题, 文章提出了 1 种基于小波分解降噪与 GRU 的低压配电网触电信号特征提取及触电诊断的方法。[方法]文章对触电实验采集的剩余电流进行降采样和离散小波降噪等预处理; 采用滑动窗口法提取剩余电流的时频域触电特征参数, 利用傅里叶变换提取剩余电流对二次谐波幅值特征参数; 提取的全部特征参数组成 1 个高维特征空间向量; 采用主成分分析法对高维特征空间向量进行降维处理后得到 1 组新的三维特征向量; 建立触电诊断模型, 并将代表触电特征的三维特征向量作为该模型的输入量; 运用门控循环网络 (GRU) 等 5 种不同的触电诊断模型对触电信号进行对比实验。[结果]实验结果表明: 基于 GRU 的触电诊断模型的收敛效果较好, 识别率达到 98.33%。[结论]该方法对新一代的剩余电流保护装置的研究与开发提供了新的思路, 为用电安全提供了有效保障。

关键词: 低压配电网; 触电诊断; 小波降噪; 特征提取; 主成分分析法; GRU

中图分类号: TM7; TP309.7

文献标志码: A

文章编号: 2095-8676(2024)04-0127-10

DOI: 10.16516/j.ceec.2024.4.13

OA: <https://www.energychina.press/>



论文二维码

Analysis on Electrocution Diagnosis Based on Discrete Wavelet Transform and GRU

CAI Gaofeng[✉], WANG Qingbin, CHEN Zhenyu, XU Guipai, FENG Jiaqi, LUO Qichang

(Yunfu Power Supply Bureau, Guangdong Power Grid Corporation, Yunfu 527300, Guangdong, China)

Abstract: [Introduction] In the low-voltage distribution network, the residual current protection device, as an important guarantee of electricity safety, can reduce the harm caused by the leakage fault of electrical appliances and prevent human electrocution accidents. The current residual current protection device relies on the residual current signal size as the basis for the action of the protection mechanism, but has no function to identify the electrocution characteristics. To address this problem, this paper proposes a method for electrocution signal feature extraction and electrocution diagnosis in low-voltage distribution networks based on wavelet decomposition and denoising, as well as GRU. [Method] In this paper, the residual currents collected from electrocution experiments were pre-processed by downsampling and discrete wavelet denoising; The time and frequency domain electrocution characteristic parameters of the residual currents were extracted by the sliding window method, and the Fourier transform was used to extract the characteristic parameters of residual currents to the second harmonic amplitude. All the extracted feature parameters were used to form a high-dimensional feature space vector; which was subject to dimensionality reduction using the method of principal component analysis to obtain a new set of three-dimensional feature vectors. A diagnostic model for electrocution was established, and the three-dimensional feature vectors representing electrocution features were input into the model. Comparison experiments were conducted on electrocution signals using five different electrocution diagnostic models, such as recurrent gated network (GRU). [Result] The experimental results show that the

收稿日期: 2023-04-29 修回日期: 2023-08-03

基金项目: 广东电网有限责任公司云浮供电局科技项目“基于云边端架构的低压配网剩余电流保护及预警技术研究与应用”(0353002022030103YN00022)

convergence of the GRU-based electrocution diagnosis model is good, and the recognition rate reaches 98.33%. **[Conclusion]** The method provides new insights for the research and development of a new generation of residual current protection devices and offers an effective guarantee for electrical safety.

Key words: low-voltage distribution network; electrocution diagnosis; wavelet denoising; feature extraction; principal component analysis; GRU

2095-8676 © 2024 Energy China GEDI. Publishing services by Energy Observer Magazine Co., Ltd. on behalf of Energy China GEDI.

This is an open access article under the CC BY-NC license (<https://creativecommons.org/licenses/by-nc/4.0/>).

0 引言

近年来,由于电力需求的增加以及配电网线路受损或电气设备损坏造成漏电等原因,火灾和人身触电事故发生的次数也明显增多^[1-2]。因此,电力安全问题已经逐渐引起了人们的广泛关注。为了预防火灾和人身触电事故的发生,用于安全保障的剩余电流保护装置在低压配电网中得到广泛使用。目前广泛运用的剩余电流保护装置其原理是通过判断总剩余电流有效值是否达到额定动作值,来判断线路是否发生触电事故^[3-4]。这种剩余电流保护装置极易受到电气环境变化等因素影响而发生误动或拒动,同时也无法识别触电事故的类型^[5-6]。

国内外学者针对剩余电流保护装置进行了大量的研究,表明了开发新型剩余电流保护装置的关键技术之一在于提取触电信号的特征进行触电类型识别。用于识别触电类型的特征提取方法常见的有时频域特征分析、小波变换、傅里叶变换和统计特征提取等。文献[7]利用统计相关理论提取了生物触电的时域和频域特征参数,再结合主成分分析法和 PSO 优化支持向量机实现了对触电故障类型的识别。文献[8]基于小波包变换分析触电剩余电流低频分量能量谱并提取触电特征向量,结合量子神经网络对触电事故类型进行识别,取得了较好的效果。文献[9]基于统计量提取了 6 个参数作为特征向量,并以人工神经网络为分类器,获得超过 85% 的放电类型识别率。以上方法的计算过程较为复杂,同时大部分文献只进行理论推导与仿真分析,没有进行具体实验的验证。

神经网络具有收敛速度快、网络结构简单、自学习与自适应性强,以及可利用线性学习能力求解非线性问题等优点^[10-12],被广泛设计并应用于特征识别和模式分类。因此,本文首先对实验得到的触电信号数据进行预处理,并提取了信号波形的时频域

特征参数以及波形的二次谐波幅值数据。再利用主成分分析法对特征参数进行降维处理,并结合 GRU 神经网络建立触电诊断模型。本文方法对新一代剩余电流保护装置的研究与开发提供了新的思路,对提高配电系统供电可靠性也具有参考价值。

1 实验平台搭建与数据预处理

1.1 实验平台搭建

本文使用猪肉作为触电体,实际电路中的三相电阻使用滑动变阻器替代。通过调节三相电阻的电阻值获得三相平衡与三相不平衡触电信号两大类样本,实验原理图如图 1 所示。




图 1 实验原理图

Fig. 1 Experimental schematic diagram

图 1 中 R_A 为 A 相电阻, R_B 为 B 相电阻, R_C 为 C 相电阻。剩余电流互感器测量三相总剩余电流。触电体并联于 A、B、C 相可分别获得不同相的触电信号。

在实验中,取经过隔离开关的三相市电作为实验输入三相电,确保实验过程的安全。A、B 和 C 三相电路的每一相均用三个最大阻值为 $200\ \Omega$ 的滑动变阻器替代。 R_1 与剩余电流互感器组成回路,阻值为 $280\ \Omega$ 。本文根据实验原理图连接电路,并选择不同类型的猪肉作为触电体进行实验,从而获得更加

丰富的样本数据。每次做实验,都是先接通三相回路,再接通触电回路,即模拟触电。为了实验采集数据的可靠性,每次触电实验在相同条件下都进行多次触电并采集数据。

1.2 获取原始剩余电流信号

生物体接入电路中可以等效为1个复杂的阻抗网络,而且当发生触电时,等效的阻抗网络参数是时刻在变化的,并且在触电发生的较短时间内电流呈现出1个递增周期函数的趋势^[1]。触电信号样本数据均由实验室触电试验平台的示波器采集得到。采集的剩余电流波形频率为100 kHz,1个周期0.02 s的采样点数为2 000。触电原始剩余电流波形如图2所示。




图2 触电原始剩余电流信号波形

Fig. 2 The original residual current signal waveform of electrocution

1.3 降采样与降噪

由于示波器的采样频率较高,以及采集原始剩余电流时含有噪声,因此需要对原始剩余电流信号进行处理。首先是降采样处理,将电流波形的频率由100 kHz下降为10 kHz;其次采用了最大重叠离散小波变换(MODWT)对降采样后的数据进行降噪处理。降噪的结果为保存信号的低频分量。降采样和离散小波降噪后的剩余电流波形如图3所示。




图3 降采样降噪后的剩余电流波形

Fig. 3 Residual current waveform after downsampling and noise reduction

算法的特征向量,以提高分类器的准确性和鲁棒性。

本文采用了滑动窗口法提取触电电流波形的11个时域特征参数,具体的表达式如表1所示。

表1中,触电信号的时域特征与波形特征参数,反映了波形的集中与离散程度、能量以及波形的分布情况。特征参数包含了平均值 a_1 、绝对平均值 a_2 、方差 a_3 、标准差 a_4 、最大值 a_5 、最小值 a_6 、峰值 a_7 、均方根 a_8 、偏度 a_9 、波形因数 a_{10} 、能量 a_{11} 。

除了提取时域特征数据,还通过傅里叶变换将触电电流波形变换到频域后,发现二次谐波在触电发生前一周幅值较低,在触电发生的1个周期内幅值明显增大,故提取了二次谐波数据也作为特征数据。同时计算了10个频域特征参数。频域特征参数反映了频谱的集中与离散程度、频域振动能量以及主频带位置的变化^[13]。频域特征参数的表达式如表2所示。

2.2 主成分分析法降维

主成分分析法(PCA)是多元统计分析中比较常用的线性降维方法^[14-15]。PCA通过线性投影将原始高维的数据空间映射到低维的空间中,而且使降维后的数据保留住较多的原始特征数据的特性^[16]。现已被广泛应用于数据分析、机器学习等诸多领域。

上一节,从触电的剩余电流中提取了时域特征数据、频域特征数据以及二次谐波数据。这些特征数据都能够从不同方面反映出生物体的触电。但由其组成的特征向量维数较高,且部分特征数据之间又存在一定的关联性,故会存在冗余特征数据。为

2 理论方法

2.1 特征参数的提取

由于所采集的触电剩余电流信号包含大量的冗余信息和噪声,难以直接进行识别。因此,需要进行特征提取,从原始的剩余电流信号中提取出对触电类型鉴别有帮助的特征,并将其转化为可用于分类

表 1 时域特征参数

Tab. 1 Characteristic parameters in time-domain

序号	特征表达式	序号	特征表达式
1	$a_1 = \frac{1}{N} \sum_{i=1}^N x(i)$	7	$a_7 = a_5 - a_6$
2	$a_2 = \frac{1}{N} \sum_{i=1}^N x(i) $	8	$a_8 = \sqrt{\frac{1}{N} \sum_{i=1}^N x(i) ^2}$
3	$a_3 = \frac{1}{N} \sum_{i=1}^N x(i) - a_1 ^2$	9	$a_9 = \frac{\frac{1}{N} \sum_{i=1}^N x(i) - a_1 ^3}{a_4^3}$
4	$a_4 = \sqrt{a_3}$	10	$a_{10} = \frac{a_8}{a_2}$
5	$a_5 = \max(x(i))$	11	$a_{11} = \sum_{i=1}^N x(i)^2$
6	$a_6 = \min(x(i))$		

注: $i=1, 2, \dots, N$ 为样本采样点数; $x(i)$ 为时域信号序列。

表 2 频域特征参数

Tab. 2 Characteristic parameters in frequency-domain

序号	特征表达式	序号	特征表达式
1	$b_1 = \frac{1}{K} \sum_{n=1}^K s(n)$	6	$b_6 = \sqrt{\frac{1}{K} \sum_{n=1}^K (f_n - b_5)^2 s(n)}$
2	$b_2 = \frac{1}{K} \sum_{n=1}^K (s(n) - b_1)^2$	7	$b_7 = \frac{b_6}{b_5}$
3	$b_3 = \frac{\sum_{n=1}^K (s(n) - b_1)^3}{K \sqrt{b_2^3}}$	8	$b_8 = \frac{\sum_{n=1}^K (f_n - b_5)^3 s(n)}{K b_6^3}$
4	$b_4 = \frac{\sum_{n=1}^K (s(n) - b_1)^4}{K b_2^2}$	9	$b_9 = \frac{\sum_{n=1}^K (f_n - b_5)^4 s(n)}{K b_6^4}$
5	$b_5 = \frac{\sum_{n=1}^K f_n s(n)}{\sum_{n=1}^K s(n)}$	10	$b_{10} = \frac{\sum_{n=1}^K \sqrt{ f_n - b_5 s(n)}}{K \sqrt{b_6}}$

注: $n=1, 2, \dots, K$ 为谱线数; $s(n)$ 为第 n 条谱线的频率幅值; f_n 为第 n 条谱线的频率值。

避免维数灾难与提高模型的识别能力, 在触电故障诊断前需使用 PCA 将冗余特征数据去除。

首先, 由于不同的特征参数包含不同性质的物理量, 为消除不同特征参数之间的量纲差异, 采用式 (1) 对数据归一化至 $[0, 1]$ 区间内。

$$f' = \frac{f - f_{\min}}{f_{\max} - f_{\min}} \quad (1)$$

式中:

f ——同一组特征数据中的某一值;

$f_{\min}$ ——该组特征数据中的最小值;

$f_{\max}$ ——该组特征数据中的最大值;

f' ——对应 f 经归一化后的特征数据。

所有特征数据都经过标准归一化后, 可用 1 个 $n \times p$ 矩阵 F 表示, 其中 n 表示特征参数的个数, p 表

示数据样本。本次数据处理 $n=20, p=224$ 。通过式(2)计算矩阵 F 的协方差矩阵 G , 协方差矩阵 G 为 1 个 $n \times n$ 矩阵。

$$G = \frac{F^T F}{p-1} \quad (2)$$

式中:

F^T ——矩阵 F 的转置。

通过计算可得到协方差矩阵 G 的 n 个特征向量和 n 个特征值。特征向量表示协方差矩阵的主要方向, 特征值表示数据沿着该方向的方差大小。将特征向量按对应特征值的大小进行排序, 并选择前 a 个特征向量作为主成分。并将这 a 个特征向量按列组成 1 个投影矩阵 M 。

将矩阵 F 与投影矩阵 M 相乘, 即可将原 n 维的特征数据集降维至 a 维空间之中。实现了特征维度降维, 此时得到 1 个降维后的 $a \times p$ 特征矩阵。

图 4 为方差贡献率随主成分的变化图, 由图可得出, 方差贡献率的变化趋势随主成分逐渐减小, 并且在第 3 个成分之后的方差贡献率基本趋于平稳, 前 3 个的主成分累计贡献率为 94.5%。因此取前 3 个成分作为本次特征数据集的主成分, 即可反映大部分特征数据的信息。由 20 个特征参数转化为 3 个新特征参数, 达到了降维目的。




图 4 方差贡献率随主成分变化图

Fig. 4 Changes of variance contribution rate with the variations of principal components

根据投影矩阵 M , 可得出 3 个主成分的系数, 如表 3 所示。由表 3 可得出 3 个主成分为 20 个变量的线性组合。 A_1 、 A_2 、 A_3 表示 3 个主成分, 具体表达式如下:

表 3 主成分系数

Tab. 3 Coefficients of principal components

变量	主成分1	主成分2	主成分3
a_2	-0.303 66	-0.021 00	-0.064 65
a_3	-0.287 23	-0.062 74	-0.006 04
a_4	-0.309 25	-0.010 07	-0.097 82
a_5	-0.245 79	0.042 95	-0.223 35
a_6	0.265 81	0.018 19	0.013 50
a_7	-0.284 24	0.015 13	-0.136 42
a_8	-0.298 28	0.013 56	-0.147 29
a_9	-0.005 96	0.029 15	-0.182 84
a_{10}	0.149 48	0.289 35	-0.473 20
a_{11}	-0.275 42	-0.044 56	-0.039 60
b_1	-0.224 56	0.242 82	0.061 44
b_2	-0.278 29	-0.063 13	-0.035 61
b_3	-0.222 52	-0.279 34	0.218 72
b_4	-0.246 85	-0.296 02	0.243 44
b_6	-0.120 18	0.423 34	0.442 00
b_7	-0.194 64	0.004 51	-0.422 94
b_8	0.053 80	-0.282 51	-0.227 29
b_9	0.024 61	-0.121 74	-0.087 29
b_{10}	-0.178 97	0.344 54	0.259 75
c_1	-0.066 40	0.534 03	-0.154 24

注: c_1 为二次谐波。

$A_1 =$

$$-0.303\ 66\ a_2 - 0.287\ 23\ a_3 - 0.309\ 25\ a_4 - 0.245\ 79\ a_5 + 0.265\ 81\ a_6 - 0.284\ 24\ a_7 - 0.298\ 28\ a_8 - 0.005\ 96\ a_9 + 0.149\ 48\ a_{10} - 0.275\ 42\ a_{11} - 0.224\ 56\ b_1 - 0.278\ 29\ b_2 - 0.222\ 52\ b_3 - 0.246\ 85\ b_4 - 0.120\ 18\ b_6 - 0.194\ 64\ b_7 + 0.053\ 8\ b_8 + 0.024\ 61\ b_9 - 0.178\ 97\ b_{10} - 0.066\ 4\ c_1$$

$A_2 =$

$$-0.021\ a_2 - 0.062\ 74\ a_3 - 0.010\ 07\ a_4 + 0.042\ 95\ a_5 + 0.018\ 19\ a_6 + 0.015\ 13\ a_7 + 0.013\ 56\ a_8 + 0.029\ 15\ a_9 + 0.289\ 35\ a_{10} - 0.044\ 56\ a_{11} + 0.242\ 82\ b_1 - 0.063\ 13\ b_2 - 0.279\ 34\ b_3 - 0.296\ 02\ b_4 + 0.423\ 34\ b_6 + 0.004\ 51\ b_7 - 0.282\ 51\ b_8 - 0.121\ 74\ b_9 + 0.344\ 54\ b_{10} + 0.534\ 03\ c_1$$

$A_3 =$

$$-0.064\ 65\ a_2 - 0.006\ 04\ a_3 - 0.097\ 82\ a_4 - 0.223\ 35\ a_5 + 0.013\ 5\ a_6 - 0.136\ 42\ a_7 - 0.147\ 29\ a_8 - 0.182\ 84\ a_9 - 0.473\ 2\ a_{10} - 0.039\ 6\ a_{11} + 0.061\ 44\ b_1 - 0.035\ 61\ b_2 + 0.218\ 72\ b_3 + 0.243\ 44\ b_4 + 0.442\ b_6 - 0.422\ 94\ b_7 - 0.227\ 29\ b_8 - 0.087\ 29\ b_9 + 0.259\ 75\ b_{10} - 0.154\ 24\ c_1$$

2.3 GRU 神经网络

门控循环网络(Gate Recurrent Unit, GRU)是循

环神经网络(Recurrent Neural Network, RNN)的 1 种,是长短期记忆网络(Long Short Term Memory, LSTM)的变体,它通过门结构可以有效地解决循环神经网络梯度消失和梯度爆炸的问题,并且它比 LSTM 网络收敛速度更快^[17-18]。其细胞核结构图如图 5 所示。GRU 模型中有两个门,重置门和更新门。GRU 网络将重复的细胞核连接成链式结构, x_t 为输入数据, y_t 为输出数据。GRU 网络就是通过每 1 个细胞核中的重置门和更新门来进行运算和数据的传播。




图 5 GRU 细胞核结构图

Fig. 5 GRU cell nucleus structure diagram

重置门决定新的输入信息与历史的信息相结合,决定保留多少历史信息,重置门的值 g_r 越小,则保留上一时刻的历史信息越少^[19-20]。更新公式如式(3)所示。更新门控制上一时刻的状态 h_{t-1} 和新输入 x_t 对当前状态的影响程度,也就是决定了要将多少历史信息传递到未来^[21-22]。更新公式如式(4)所示。

$$g_r = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (3)$$

$$g_z = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (4)$$

$$\hat{h}_t = \tanh(W_h \cdot [g_r \times h_{t-1}, x_t] + b_h) \quad (5)$$

$$h_t = (1 - g_z) \times h_{t-1} + g_z \times \hat{h}_t \quad (6)$$

式中:

g_r 、 g_z 、 $\hat{h}_t$ 、 h_t ——重置门、更新门、候选隐藏状态及当前隐藏状态;

W ——权重;

b ——偏置;

$\sigma(\cdot)$ ——sigmoid 函数,使用此函数可以将数据限制在 $[0, 1]$ 范围内^[23],如式(7)所示;

$\tanh(\cdot)$ —— $\tanh$ 函数,使用此函数可以将数据限制在 $[-1, 1]$ 范围内,如式(8)所示。

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

$$\tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (8)$$

2.4 GRU 神经网络参数确定

GRU 神经网络模型由输入层、GRU 网络层、全连接层和输出层构成^[24],如图 6 所示。




图 6 GRU 神经网络结构图

Fig. 6 GRU neural network structure diagram

为了能获得性能较好的模型,需要对 GRU 网络层数和神经元数进行参数调优。理论上,增加网络层数能增强拟合能力,提升效果。但是实际上,过多的网络层数会导致过拟合和训练难度加大,使模型难以收敛。因此,设置迭代次数为 30 的实验测试,固定神经元个数为 64,改变不同的网络层数,通过式(9)计算对应网络层数的平均绝对误差值(MAE),实验结果如表 4 所示。

表 4 GRU 网络层数 MAE

Tab. 4 Number of GRU network layers and MAE

当前GRU网络层数	神经元个数/个	MAE
1	64	0.200 0
2	64	0.133 3
3	64	0.233 3
4	64	0.200 0

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (9)$$

式中:

$\hat{y}_i$ ——预测值;

y_i ——实际值。

误差越小,MAE 值也越小,说明该网络层数对应的模型具有更高的精确度。通过表 4 可知,GRU 网络层数为 2 时,MAE 值最小,因此确定 GRU 网络层数为 2。

同理,神经元个数不同也会对模型的性能造成影响。在 GRU 层中神经元个数少会造成欠拟合,而神经元个数过多会造成过拟合问题。因此,选择 1 个合适的神经数量是比较重要的。设置迭代次数为

30 的实验测试,固定 GRU 网络层数为 2,改变不同的神经元个数,通过式(9)计算对应神经元数的平均绝对误差值,实验结果如表 5 所示。

表 5 神经元数 MAE
Tab. 5 Number of neurons and MAE

当前GRU网络层数	神经元个数/个	MAE
2	8	0.433 3
2	16	0.400 0
2	32	0.266 6
2	64	0.200 0
2	128	0.300 0

通过表 5 可知,神经元数为 64 时,MAE 值最小,因此确定神经元数为 64。

学习率用于确定每次迭代的步长,属于优化算法的调谐参数。设置合适的学习率,可使损失函数收敛到最小值,也就是使预测值与真实值的差距达到最小。损失值越小,说明模型的预测效果越好。设置不同学习率的实验测试,可得到不同的损失值,实验结果如表 6 所示。

表 6 学习率和损失值
Tab. 6 Learning rate and loss value

学习率	0.000 8	0.000 9	0.001 0	0.002 0	0.003 0
损失值	0.265 5	0.241 2	0.240 3	0.273 9	0.248 3

通过表 6 可知,当学习率为 0.001 0 时,损失值最小,因此取学习率为 0.001 0。

因此,GRU 神经网络结构图中输入层为 3 个主成分的数据特征参数;两层 GRU 网络层中各有 64 个神经元;全连接层有 4 类,分别表示:三相平衡正常、三相平衡触电、三相不平衡正常以及三相不平衡触电;输出层为输出 4 类触电中的 1 种。训练迭代次数为 300,学习率取 0.001 0。

3 触电诊断

3.1 触电诊断流程

本次实验采集的 224 组样本数据中,三相平衡触电信号、三相平衡正常信号、三相不平衡触电信号以及三相不平衡正常信号 4 类样本数据各 56 组。再取四类样本数据各 35 组,共 140 组作为训练集;取四类样本数据各 15 组,共 60 组作为测试集;剩下

的 24 组样本数据作为验证集。触电诊断流程图如图 7 所示。第一步,通过以猪肉作为触电体的触电实验,获取触电剩余电流信号;第二步,对获取的数据降采样处理后,使用最大重叠离散小波变换进行降噪处理;第三步,对降噪后的剩余电流信号进行时域和频域分析,提取时域和频域特征数据,同时提取触电波形的二次谐波幅值特征数据;第四步,对提取的特征数据进行归一化处理,再进行 PCA 降维得到 3 个新的特征数据;第五步,搭建 GRU 触电诊断模型,并且把 3 个新的特征数据集划分为训练集、测试集以及验证集作为模型输入,进行训练与验证;最后,运用训练得到的模型,输入任意 1 组数据,进行触电诊断。




图 7 触电诊断流程图

Fig. 7 Electrocution diagnosis flow chart

3.2 触电诊断结果分析

在训练过程中,随着 GRU 模型迭代次数的增加,测试的损失函数率不断减少直至收敛。同时,测试准确率不断提升向 100% 趋近,说明了该模型能较好地学习输入的特征数据。虽然在训练过程中,损失值出现过几次突增,随后极速下降,但是总体呈现下降并且不断向 0 趋近。在损失值发生较大的震荡时,准确率也伴随着震荡,产生这一现象可能是参数训练过程中,模型陷入了局部最优。随着迭代次数的增加,训练参数得到不断更新到最佳,最后两条曲线趋于稳定,实验结果如图 8 所示。

3.3 不同模型对比分析

本次实验使用长短期记忆网络 LSTM、循环神




图 8 测试过程示意图

Fig. 8 Schematic diagram of the testing process

神经网络 RNN、人工神经网络 ANN(Artificial Neural Network) 以及支持向量机 SVM(Support Vector Machine) 4 种模型来做比较。SVM 属于机器学习, 其余模型都属于深度学习。图 9 显示了深度学习的 4 个模型的损失函数值随着迭代次数增加而变化的情况。结果表明, 4 个模型的损失函数值均随着迭代次数的增加而逐渐减小, 其中 GRU 收敛效果最好, LSTM 次之。RNN 的收敛结果有明显的波动, 同时 RNN 与 ANN 的收敛值都较大。因此, GRU 模型具有训练效果。




图 9 迭代次数与损失函数的关系

Fig. 9 Relationship between the number of iterations and the loss function

表 7 显示了 5 种模型在迭代次数为 300 时的触电识别准确率以及训练时间。结果表明, GRU 与 LSTM 具有较高的准确率 98.33%, RNN、ANN 与 SVM 的准确率较低, 仅 91.67%。同时, 在相同的准确率下, GRU 的训练时间较 LSTM 短, 这是因为 GRU 网络较 LSTM 网络更简单。

表 7 不同模型的性能比较

Tab. 7 Performance comparison of different models

神经网络	迭代次数/次	准确率/%	训练时间/s
GRU	300	98.33	6.559 0
LSTM	300	98.33	6.883 7
RNN	300	91.67	4.551 8
ANN	300	91.67	11.675 4
SVM	300	91.67	0.001 0

4 结论

1) 在三相平衡与三相不平衡的触电实验上, 本文对生物体触电剩余电流信号进行采集, 再对电流信号进行降采样和降噪处理, 提取出时频域统计参数和二次谐波幅值参数。各参数均能从不同方面表征生物体触电信号的特征。

2) 运用主成分分析法将原始提取的 20 个特征量降为 3 个新的特征量, 并将新的三维特征量参数作为触电诊断模型的输入向量, 进行触电故障类型诊断, 大大提高了诊断的准确率。

3) 通过 GRU、LSTM、RNN、ANN 和 SVM 5 种神经网络分别对降维后新的特征参数进行触电类型诊断, 对比实验结果得出, GRU 模型对触电信号故障类型诊断具有更好的效果。

参考文献:

- [1] 赵启承, 虞雁凌. 基于长短期记忆神经网络的生命体触电电流检测 [J]. 传感器与微系统, 2022, 41(1): 142-145. DOI: 10.13873/J.1000-9787(2022)01-0142-04.
- ZHAO Q C, YU Y L. Biological body electrocution current detection based on LSTM neural networks [J]. Transducer and microsystem technologies, 2022, 41(1): 142-145. DOI: 10.13873/J.1000-9787(2022)01-0142-04.
- [2] 劳永钊, 吴任博, 肖健, 等. 中压配电网线损实时同步监测系统设计方案研究 [J]. 南方能源建设, 2022, 9(增刊 1): 139-146. DOI: 10.16516/j.gedi.issn2095-8676.2022.S1.021.
- LAO Y Z, WU R B, XIAO J, et al. Research on design scheme of real-time synchronous monitoring system for line loss of medium voltage distribution network [J]. Southern energy construction, 2022, 9(Suppl.1): 139-146. DOI: 10.16516/j.gedi.issn2095-8676.2022.S1.021.
- [3] 蔡智萍, 郭谋发, 魏正峰. 基于 BP 神经网络的低压配电网生命体触电识别方法研究 [J]. 电网技术, 2022, 46(4): 1614-1623. DOI: 10.13335/j.1000-3673.pst.2021.0742.
- CAI Z P, GUO M F, WEI Z F. Research on recognition method of living body shock in low-voltage distribution network based on BP neural network [J]. Power system technology, 2022, 46(4):

- 1614-1623. DOI: [10.13335/j.1000-3673.pst.2021.0742](#).
- [4] 侯瑞. 基于粒子群算法的区域综合能源系统规划及运行优化[J]. *内蒙古电力技术*, 2019, 37(4): 43-48. DOI: [10.3969/j.issn.1008-6218.2019.04.003](#).
HOU R. Planning of regional integrated energy system based on particle swarm optimization and its operation optimization [J]. *Inner Mongolia electric power*, 2019, 37(4): 43-48. DOI: [10.3969/j.issn.1008-6218.2019.04.003](#).
- [5] 关海鸥, 杜松怀, 苏娟, 等. 一种触电信号的自动快速检测模型[J]. *电网技术*, 2013, 37(8): 2328-2335. DOI: [10.13335/j.1000-3673.pst.2013.08.008](#).
GUAN H O, DU S H, SU J, et al. An automatic and quick detection model of electric shock signals [J]. *Power system technology*, 2013, 37(8): 2328-2335. DOI: [10.13335/j.1000-3673.pst.2013.08.008](#).
- [6] 陈航宇, 李天友, 杨智奇. 低压配网剩余电流保护运行现状及相关措施分析[J]. *电气技术*, 2021, 22(1): 104-108. DOI: [10.3969/j.issn.1673-3800.2021.01.021](#).
CHEN H Y, LI T Y, YANG Z Q. Analysis of current operation status and relevant measures of low-voltage distribution network residual current protection [J]. *Electrical engineering*, 2021, 22(1): 104-108. DOI: [10.3969/j.issn.1673-3800.2021.01.021](#).
- [7] 韩晓慧, 杜松怀, 苏娟, 等. 触电信号暂态特征提取及故障类型识别方法[J]. *电网技术*, 2016, 40(11): 3591-3596. DOI: [10.13335/j.1000-3673.pst.2016.11.046](#).
HAN X H, DU S H, SU J, et al. Fault transient feature extraction and fault type identification for electrical shock signals [J]. *Power system technology*, 2016, 40(11): 3591-3596. DOI: [10.13335/j.1000-3673.pst.2016.11.046](#).
- [8] 关海鸥, 刘梦, 李春兰, 等. 基于小波包变换和量子神经网络的触电故障类型识别模型[J]. *农业工程学报*, 2018, 34(5): 183-190. DOI: [10.11975/j.issn.1002-6819.2018.05.024](#).
GUAN H O, LIU M, LI C L, et al. Classification recognition model of electric shock fault based on wavelet packet transformation and quantum neural network [J]. *Transactions of the Chinese society of agricultural engineering*, 2018, 34(5): 183-190. DOI: [10.11975/j.issn.1002-6819.2018.05.024](#).
- [9] 胡文堂, 高胜友, 余绍峰, 等. 统计参数在变压器局部放电模式识别中的应用[J]. *高电压技术*, 2009, 35(2): 277-281. DOI: [10.13336/j.1003-6520.hve.2009.02.007](#).
HU W T, GAO S Y, YU S F, et al. Application of statistic parameters in recognition of partial discharge in transformers [J]. *High voltage engineering*, 2009, 35(2): 277-281. DOI: [10.13336/j.1003-6520.hve.2009.02.007](#).
- [10] CHEN L, HAN W, HUANG Y H, et al. Online fault diagnosis for photovoltaic modules based on probabilistic neural network [J]. *European journal of electrical engineering*, 2019, 21(3): 317-325. DOI: [10.18280/ejee.210309](#).
- [11] WANG H H, WANG P, LIU T. Power quality disturbance classification using the S-transform and probabilistic neural network [J]. *Energies*, 2017, 10(1): 107. DOI: [10.3390/en10010107](#).
- [12] 李春兰, 罗杰, 石砦, 等. 基于小波分析和概率神经网络的触电事故识别方法[J]. *江苏大学学报(自然科学版)*, 2023, 44(1): 75-81, 88. DOI: [10.3969/j.issn.1671-7775.2023.01.011](#).
LI C L, LUO J, SHI Z, et al. Electric shock identification method based on probabilistic neural network and wavelet analysis [J]. *Journal of Jiangsu University (Natural Science Edition)*, 2023, 44(1): 75-81, 88. DOI: [10.3969/j.issn.1671-7775.2023.01.011](#).
- [13] 罗杰. 基于生物触电特征的触电事故识别方法研究[D]. 乌鲁木齐: 新疆农业大学, 2021. DOI: [10.27431/d.cnki.gxnyu.2021.000173](#).
LUO J. Research on recognition method of electric shock accident based on biological electric shock characteristics [D]. Urumqi: Xinjiang Agricultural University, 2021. DOI: [10.27431/d.cnki.gxnyu.2021.000173](#).
- [14] 周松林, 茆美琴, 苏建徽. 基于主成分分析与人工神经网络的风电功率预测[J]. *电网技术*, 2011, 35(9): 128-132. DOI: [10.13335/j.1000-3673.pst.2011.09.004](#).
ZHOU S L, MAO M Q, SU J H. Prediction of wind power based on principal component analysis and artificial neural network [J]. *Power system technology*, 2011, 35(9): 128-132. DOI: [10.13335/j.1000-3673.pst.2011.09.004](#).
- [15] 马瑞, 康仁, 罗斌, 等. 基于改进主成分分析法的水电机组能耗特征识别方法[J]. *电网技术*, 2013, 37(5): 1196-1201. DOI: [10.13335/j.1000-3673.pst.2013.05.012](#).
MA R, KANG R, LUO B, et al. An improved principal component analysis based recognition method for energy consumption characteristics of thermal generation unit [J]. *Power system technology*, 2013, 37(5): 1196-1201. DOI: [10.13335/j.1000-3673.pst.2013.05.012](#).
- [16] 肖颖涛, 王化全, 俞海峰, 等. 基于主成分分析法和模糊综合评价法的配电网评估[J]. *南方能源建设*, 2019, 6(3): 105-112. DOI: [10.16516/j.gedi.issn2095-8676.2019.03.018](#).
XIAO Y T, WANG H Q, YU H F, et al. Evaluation of distribution network status based on principal component analysis and correspondence analysis [J]. *Southern energy construction*, 2019, 6(3): 105-112. DOI: [10.16516/j.gedi.issn2095-8676.2019.03.018](#).
- [17] 黄子敬. 基于循环神经网络的内部威胁检测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2020. DOI: [10.27061/d.cnki.ghgdu.2020.000634](#).
HUANG Z J. Research on insider threat detection method based on recurrent neural network [D]. Harbin: Harbin Institute of Technology, 2020. DOI: [10.27061/d.cnki.ghgdu.2020.000634](#).
- [18] 王康, 龚文杰, 段晓燕, 等. 基于 PSO 算法优化 GRU 神经网络的短期负荷预测[J]. *广东电力*, 2020, 33(4): 90-96. DOI: [10.3969/j.issn.1007-290X.2020.004.012](#).
WANG K, GONG W J, DUAN X Y, et al. Short-term load forecasting model of power system based on PSO algorithm to

- optimize GRU neural network [J]. *Guangdong electric power*, 2020, 33(4): 90-96. DOI: [10.3969/j.issn.1007-290X.2020.004.012](https://doi.org/10.3969/j.issn.1007-290X.2020.004.012).
- [19] 周莽, 高瑾, 李晨光, 等. GRU 神经网络短期电力负荷预测研究 [J]. *科技创新与应用*, 2018, 8(33): 52-53, 57. DOI: [10.3969/j.issn.2095-2945.2018.33.021](https://doi.org/10.3969/j.issn.2095-2945.2018.33.021).
- ZHOU M, GAO T, LI C G, et al. Research on short-term power load forecasting based on GRU neural network [J]. *Technology innovation and application*, 2018, 8(33): 52-53, 57. DOI: [10.3969/j.issn.2095-2945.2018.33.021](https://doi.org/10.3969/j.issn.2095-2945.2018.33.021).
- [20] 张国豪, 刘波. 采用 CNN 和 Bidirectional GRU 的时间序列分类研究 [J]. *计算机科学与探索*, 2019, 13(6): 916-927. DOI: [10.3778/j.issn.1673-9418.1812059](https://doi.org/10.3778/j.issn.1673-9418.1812059).
- ZHANG G H, LIU B. Research on time series classification using CNN and Bidirectional GRU [J]. *Journal of frontiers of computer science and technology*, 2019, 13(6): 916-927. DOI: [10.3778/j.issn.1673-9418.1812059](https://doi.org/10.3778/j.issn.1673-9418.1812059).
- [21] 牛哲文, 余泽远, 李波, 等. 基于深度门控循环单元神经网络的短期风功率预测模型 [J]. *电力自动化设备*, 2018, 38(5): 36-42. DOI: [10.16081/j.issn.1006-6047.2018.05.005](https://doi.org/10.16081/j.issn.1006-6047.2018.05.005).
- NIU Z W, YU Z Y, LI B, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network [J]. *Electric power automation equipment*, 2018, 38(5): 36-42. DOI: [10.16081/j.issn.1006-6047.2018.05.005](https://doi.org/10.16081/j.issn.1006-6047.2018.05.005).
- [22] 陈立国, 张跃冬, 耿光刚, 等. 基于 GRU 型循环神经网络的随机域名检测 [J]. *计算机系统应用*, 2018, 27(8): 198-202. DOI: [10.15888/j.cnki.csa.006466](https://doi.org/10.15888/j.cnki.csa.006466).
- CHEN L G, ZHANG Y D, GENG G G, et al. Detection of random generated names using recurrent neural network with gated recurrent unit [J]. *Computer systems & applications*, 2018, 27(8): 198-202. DOI: [10.15888/j.cnki.csa.006466](https://doi.org/10.15888/j.cnki.csa.006466).
- [23] 王增平, 赵兵, 纪维佳, 等. 基于 GRU-NN 模型的短期负荷预测方法 [J]. *电力系统自动化*, 2019, 43(5): 53-58. DOI: [10.7500/AEPS20180620003](https://doi.org/10.7500/AEPS20180620003).
- WANG Z P, ZHAO B, JI W J, et al. Short-term load forecasting method based on GRU-NN model [J]. *Automation of electric power systems*, 2019, 43(5): 53-58. DOI: [10.7500/AEPS20180620003](https://doi.org/10.7500/AEPS20180620003).
- [24] 郭威, 张凯, 魏新杰, 等. 高渗透率分布式光伏接入的新型电力系统净功率预测 [J]. *电测与仪表*, 2022, 59(12): 48-55. DOI: [10.19753/j.issn1001-1390.2022.12.006](https://doi.org/10.19753/j.issn1001-1390.2022.12.006).
- GUO W, ZHANG K, WEI X J, et al. Net power prediction for a novel power system with high permeability distributed photovoltaic access [J]. *Electrical measurement & instrumentation*, 2022, 59(12): 48-55. DOI: [10.19753/j.issn1001-1390.2022.12.006](https://doi.org/10.19753/j.issn1001-1390.2022.12.006).

作者简介:



蔡高凤

蔡高凤(通信作者)

1981-, 男, 工程师, 学士, 主要从事配电运行管理工作(e-mail)41113900@qq.com。

(编辑 孙舒)