

DOI: 10.13382/j.jemi.B1902870

VMD-PE 协同 SNN 的输电线路故障辨识方法*

付 华 金 岑

(辽宁工程技术大学 电气与控制工程学院 葫芦岛 125105)

摘 要:针对输电线路短路故障危害大、故障辨识率较低等问题,提出一种结合变分模态分解排列熵(VMD-PE)与孪生神经网络(SNN)的故障辨识方法,利用瞬时频率均值对VMD进行参数优化,确定分解层数 K ,通过VMD分解故障时的三相电压,计算分解后每个分量的排列熵,将其作为故障特征量;将故障特征输入到训练好的SNN中进行相似性度量,比较两个输入样本之间的相似程度,判别出输电线路短路故障类型。通过仿真实验验证了该方法的可行性,并与其他分类方法相对比,证明了该方法的准确性和优越性。

关键词:输电线路;故障辨识;变分模态分解(VMD);孪生神经网络(SNN);排列熵(PE)

中图分类号: TM726; TN98 **文献标识码:** A **国家标准学科分类代码:** 470.40

Fault identification method of transmission lines based on VMD-PE and SNN

Fu Hua Jin Cen

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: Aiming at the problems of damage caused by short-circuit faults and low fault identification rate of transmission lines, a fault identification method combining VMD-PE and siamese neural networks (SNN) is proposed. For determining the number of decomposition layers K , use the instantaneous frequency mean to optimize VMD parameters, decompose the three-phase voltage at fault by VMD, calculate the permutation entropy of each component after decomposition, and use them as the fault features; input the fault features into the trained SNN for similarity measurement, compare the similarity between the two input samples to determine the type of short-circuit fault on the transmission line. The feasibility of the method is verified by simulation experiments, and compared with other classification methods, the accuracy and superiority of the method are proved.

Keywords: transmission lines; fault identification; variational modal decomposition (VMD); siamese neural networks (SNN); permutation entropy (PE)

0 引 言

输电线路是电力系统的重要组成部分之一,但由于经常暴露在外,容易受到恶劣环境和天气的影响而发生故障^[1]。其中短路故障是最为频繁和严重的,会导致系统振荡,甚至破坏整个系统^[2]。因此能够快速准确的辨识输电线路短路故障,可以加快故障线路的检修速度,减小故障带来的经济损失和社会影响,是确保电力系统能够稳定运行的基础^[3]。

近年来,随着人工智能的快速发展,一些专家学者已经研究出很多输电线路故障的辨识方法,其主要可以分为故障特征提取和故障分类两个过程,常用的特征提取的方法有小波变换^[4]、傅里叶变换^[5]、经验模态分解(EMD)^[6],智能分类方法主要有支持向量机(SVM)^[7]、人工神经网络(ANN)^[8]。然而上述方法都存在着一定的弊端,小波变换需要人为设定小波基函数,容易造成故障信号的遗失^[9];傅里叶变换面对非线性信号时,无法准确的给出局部特征信息;经验模态分解虽然可以对信号进行自适应分解,但不足之处是易发生模态混叠现

收稿日期: 2019-12-27 Received Date: 2019-12-27

* 基金项目: 国家自然科学基金(51974151, 71771111)资助项目

象^[10];而支持向量机和人工神经网络等多数智能分类算法都需要大量样本数据进行训练,当故障样本数据较小时,它们都难以达到令人满意的效果^[11]。

针对上述方法的不足,提出了一种变分模态分解排列熵(VMD-PE)协同孪生神经网络(SNN)的短路故障辨识方法。VMD 是 Dragomiretskiy 等^[12] 2004 年提出的一种新型完全非递归的模态变分方法,与 EMD 所使用的循环筛分离方法不同,VMD 通过构建变分模型迭代的搜索最佳中心频率和带宽,避免发生模态混叠现象,现已成功应用在变压器故障诊断^[13]、电能质量检测^[14]、电力系统雷击故障定位^[15]等领域。排列熵最早是由 Bandt 等提出的,主要是为了度量时间序列复杂性,相对于其他熵,具有优秀的抗噪能力和计算效率^[16]。SNN 现已被应用到很多领域,最早的 SNN 用来验证手写签名的真伪,后来又与卷积神经网络(CNN)相结合,进行人脸跟踪^[17]和指静脉的识别^[18],SNN 在训练样本较少时可以达到较高的准确性。利用 VMD 对故障信号进行分解,计算每个模态分量的排列熵作为故障特征量,将特征量输入到 SNN 中,实现了输电线路的短路故障辨识。

1 故障信号分解及特征提取

1.1 故障信号分解

对于输电线路故障后产生的三相电压信号,应用 VMD 算法可以有效的分解故障信息。对输入的三相电压信号进行变分模型的构造,通过搜索确定该模型的最优解,便可以将输入的三相电压信号自适应的分解成预设的 K 个尺度数下不同频段的本征模态函数(intrinsic mode function, IMF)分量^[19]。变分模型如下:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\} \\ \text{s. t. } \sum_k u_k = f \end{cases} \quad (1)$$

式中: f 为输电线路发生短路故障时的三相电压信号; $\{u_k\} = \{u_1, \dots, u_k\}$ 为信号分解后的 IMF 分量; $\{\omega_k\} = \{\omega_1, \dots, \omega_k\}$ 为各个 IMF 分量的中心频率。

将二次惩罚因子 α 和拉格朗日乘法算子 λ 代入变分模型,模型变为:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = \\ \alpha \sum_k \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} \right] \cdot u_k(t) \right\|_2^2 + \\ \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (2)$$

采用交替方向算法来更新 u_k^{n+1} 、 ω_k^{n+1} 、 λ^{n+1} ,可以得到:

$$\hat{u}_k^k(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} u_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (4)$$

$$\hat{\lambda}(\omega) = \hat{\lambda}(\omega) + \tau \left[\hat{f}(\omega) - \sum_k \hat{u}_k(\omega) \right] \quad (5)$$

将上述得到的拉格朗日表达式的“鞍点”作为变分模型最优解,实现了将原始的三相电压信号 f 分解成 K 个 IMF 分量的目的。

1.2 故障信号特征提取

特征提取对于故障辨识具有关键性的作用,利用 VMD 排列熵作为短路故障特征。

将经 VMD 分解后的 IMF 分量设为 $X = \{x(1), x(2), \dots, x(N)\}$, 对其进行相空间重构,则矩阵 Y 为:

$$Y = \begin{bmatrix} x(1) & x(1 + \tau) & \cdots & x(1 + (m-1)\tau) \\ x(2) & x(2 + \tau) & \cdots & x(2 + (m-1)\tau) \\ \vdots & \vdots & \cdots & \vdots \\ x(i) & x(i + \tau) & \cdots & x(i + (m-1)\tau) \\ \vdots & \vdots & \cdots & \vdots \\ x(k) & x(k + \tau) & \cdots & x(k + (m-1)\tau) \end{bmatrix} \quad (6)$$

式中: m 为嵌入维数; τ 为延迟时间 $i = 1, 2, \dots, k$ 。

然后根据矩阵 Y 第 i 行元素的数值大小,进行升序方式重新排列,即:

$$Y(i) = x[i + (j_1 - 1)\tau] \leq x[i + (j_2 - 1)\tau] \leq \cdots \leq x[i + (j_m - 1)\tau] \quad (7)$$

式中: j_1, j_2, \dots, j_m 表示在重构向量中各元素所在列的索引号。

则对于矩阵 Y 中的每一行均可以得到一组排列序列:

$$s(l) = \{j_1, j_2, \dots, j_m\} \quad (8)$$

式中: $l = 1, 2, \dots, k$, 且 $k \leq m!$ 。

计算每组序列出现的概率,即可得到 IMF 分量的排列熵:

$$H_p(m) = - \sum_{i=1}^k P_i \ln P_i \quad (9)$$

当 $P_i = 1/m!$ 时, $H_p(m)$ 取最大值 $\ln(m!)$ 。将 $H_p(m)$ 归一化得到:

$$H_p(m) = H_p(m) / \ln(m!) \quad (10)$$

式中: $0 \leq H_p(m) \leq 1$, 其反应的是时间序列的随机程度,随机程度随着熵值的增大而变强。嵌入维数 m 一般取 $3 \sim 7$, 延迟时间 τ 取 1, 这里选取的参数分别为 $m = 6$, $\tau = 1$ 。

即可构建故障特征量:

$$S = [H_1, H_2, \dots, H_K] \quad (11)$$

2 建立 SNN 故障辨识模型

2.1 SNN 故障辨识模型结构

SNN 故障辨识模型的结构^[20]如图 1 所示,具备两个输入分支,隐藏层由两个平行的子网络组成,这两个子网络之间共享权值和偏置等参数。

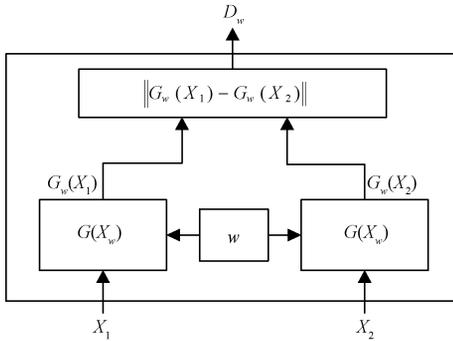


图 1 SNN 故障辨识模型结构

Fig. 1 Structure diagram of SNN fault identification model

将经 VMD 分解提取后的故障特征作为 SNN 的输入 X_1 和 X_2 , 假设该神经网络共有 l 层, 则第 l 层有 $p^{(l)}$ 个神经元, $X_1 = (x_1, x_2, \dots, x_d)$, 则顶层输出为:

$$G_w(X_1) = z^{(l)} = s(w^{(l)} z^{(l-1)} + b^{(l)}) \quad (12)$$

式中: s 是非线性激活函数; $w^{(l)}$ 是一个 $p^{(l)} \times d$ 的共享参数矩阵; $b^{(l)}$ 是一个偏置向量; 长度为 $p^{(l)}$ 。

选用含有 3 层隐含层的人工神经网络构建 SNN 故障辨识模型的子网络, Relu 函数作为激活函数, 相比于其他的激活函数, Relu 具有计算简单、可以有效抑制梯度消失问题等优点^[21]。

2.2 故障辨识模型参数优化

对得到的新的向量 $G_w(X_i)$ 进行相似性度量, 即可得出相似度的具体情况, 度量函数选用二范数:

$$D_w = \|G_w(X_1) - G_w(X_2)\|_2 \quad (13)$$

SNN 故障辨识模型训练和优化的过程实际上就是使损失函数最小化的过程, 损失函数的值越小, 表明预测值与真实值之间的越相似。利用反向传播算法来调节网络权值 w , 在训练过程中, 如果输入属于同一类别, 则应使 D_w 减小; 如果属于不同类别, 则使 D_w 增大。

损失函数的公式如下:

$$L = \frac{1}{2N} \sum_{n=1}^N (1 - Y) \frac{1}{2} (D_w)^2 + (Y) \frac{1}{2} \{ \max(0, m - D_w) \}^2 \quad (14)$$

式中: N 为样本个数; m 为设定的阈值; Y 为样本特征标

签: 当 X_1 和 X_2 为同一类别时, $Y = 0$; 当 X_1 和 X_2 为不同类别时, $Y = 1$ 。

为了使损失函数尽可能得到最小值, 采用随机梯度下降算法 (SGD) 沿负梯度方向更新优化模型参数 w 、 b 。

当输入数据为同一类别时, 则:

$$L = \frac{1}{2N} \sum_{n=1}^N D_w^2 \quad (15)$$

此时:

$$w^{(l)} = w^{(l)} - \frac{\partial L}{\partial w^{(l)}} = w^{(l)} - \alpha D_w \frac{\partial D_w}{\partial w^{(l)}} \quad (16)$$

$$b^{(l)} = b^{(l)} - \frac{\partial L}{\partial b^{(l)}} = b^{(l)} - \alpha D_w \frac{\partial D_w}{\partial b^{(l)}} \quad (17)$$

式中: α 为学习率。

当输入数据为不同类别时且 $D_w < m$ 时, 则:

$$L = \frac{1}{2N} \sum_{n=1}^N \{ \max(0, m - D_w) \}^2 \quad (18)$$

此时:

$$w^{(l)} = w^{(l)} - \frac{\partial L}{\partial w^{(l)}} = w^{(l)} + \alpha (m - D_w) \frac{\partial D_w}{\partial w^{(l)}} \quad (19)$$

$$b^{(l)} = b^{(l)} - \frac{\partial L}{\partial b^{(l)}} = b^{(l)} + \alpha (m - D_w) \frac{\partial D_w}{\partial b^{(l)}} \quad (20)$$

3 仿真验证

3.1 故障仿真模型

利用 MATLAB 仿真软件搭建了 220 kV 的双端输电线路模型, 对故障时的三相电压进行仿真分析, 系统简化的仿真示意图如图 2 所示, 设基波频率为 50 Hz, 短路故障开始时间为 0.2 s。

该模型仿真了高压输电线路发生的 4 种短路故障 (Ag、AB、ABg、ABC), 对于每种故障类型选取 30 组样本数据, 共 120 组数据, 选取其中的 40 组作为训练集, 其余为测试集。将待测试样本 a_i 与全部训练集样本 $\{a_1, a_2, \dots, a_{40}\}$ 分别做为 X_1 和 X_2 输入到训练好的 SNN 中, 得到相似度 $D_w = \{D_{wi1}, D_{wi2}, \dots, D_{wi40}\}$, 其中 $\min D_w$ 所对应的训练样本故障类型就是待测样本的故障类型。

通过取模态分量瞬时频率均值得到 VMD 算法中的 K 值, 绘制图 3 所示的模态分量为 1~9 时的标准化瞬时频率均值曲线。当曲线发生明显弯曲时的临界模态数就是 K 的最加取值。由于图 3(e) 曲线弯曲现象明显, 即 $K=4$ 为合理的模态数取值。

在仿真过程中, 当发生单相接地短路故障 (Ag) 时, A 相电压减小, B 相和 C 相电压略有升高; 当发生两相短路故障 (AB) 时, A 相、B 相电压减小, C 相电压明显升高; 当发生两相接地短路故障 (ABg) 时, A 相、B 相电压减

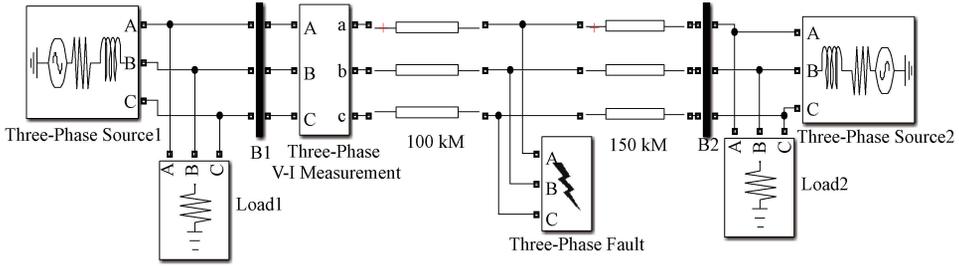


图2 高压输电线路简化仿真示意图

Fig. 2 Simplified simulation of high-voltage transmission lines

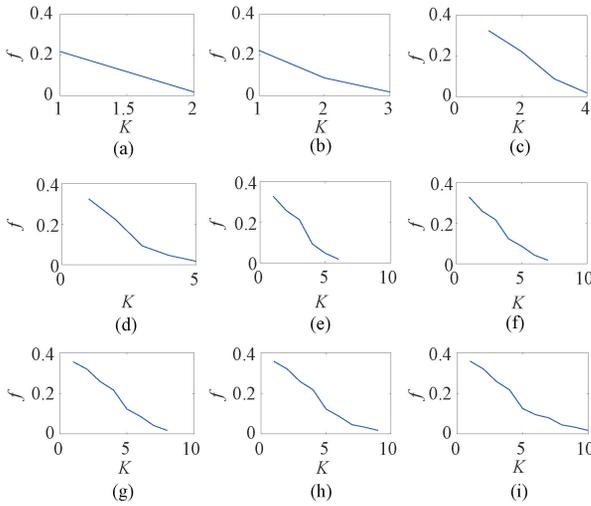


图3 VMD分量瞬时频率的均值

Fig. 3 Mean value of the instantaneous frequency of the VMD component

小,C相电压略有升高;当发生三相短路故障(ABC)时,A相、B相和C相电压都减小。由此说明可以利用故障时的三相电压作为故障特征,从而判别出短路故障类型。

3.2 仿真结果

以A相发生单相接地短路故障为例,对其三相电压进行VMD分解,结果分别如图4~6。

计算每个分量的排列熵,共得到12个排列熵值,将其作为SNN的输入,部分故障特征数据如表1所示。

图7所示为经过SNN测试后获得的故障辨识结果。其中标签1代表Ag,标签2代表AB,标签3代表ABg,标签4代表ABC。

3.3 对比分析

将EMD-SVM、DWT-ANN、VMD-ANN与VMD-SNN在不同训练样本的情况下进行故障辨识,其平均准确率的对比如图8所示。

由图8可以看出,在训练样本较小的情况下,VMD-SNN较其他分类方法相比具有更高的准确率。

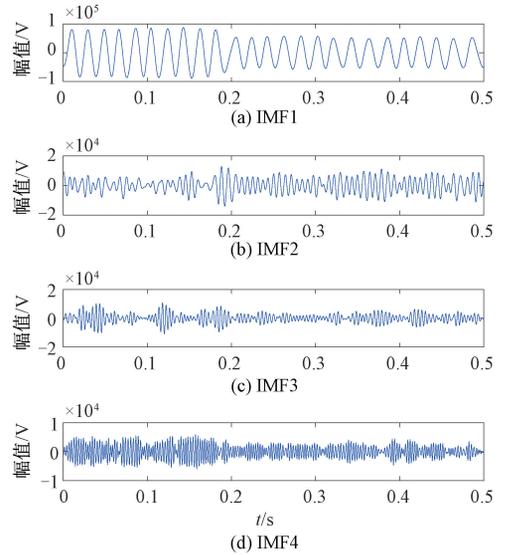


图4 A相接地短路时A相电压VMD分解

Fig. 4 A-phase VMD decomposition diagram for A-phase grounding short circuit

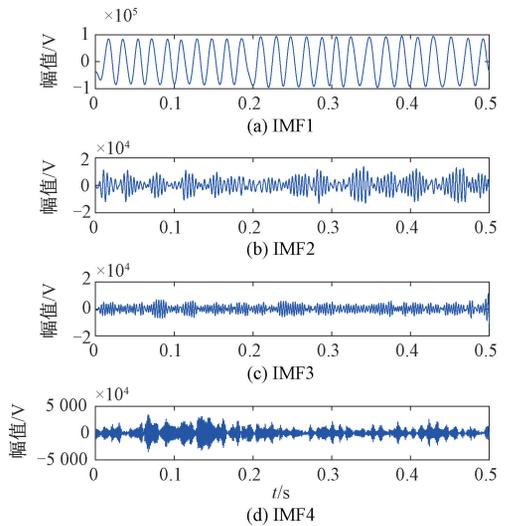


图5 A相接地短路时B相电压VMD分解

Fig. 5 B-phase VMD decomposition diagram for A-phase grounding short circuit

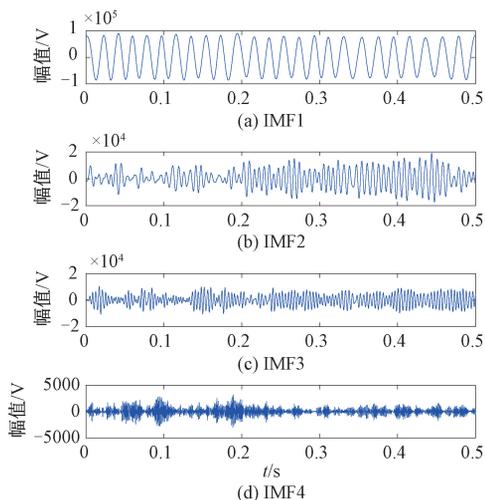


图 6 A 相接地短路时 C 相 VMD 分解

Fig. 6 C-phase VMD decomposition diagram for A-phase grounding short circuit

表 1 部分故障特征数据

Table 1 Some fault characteristics data

故障类型		特征向量			
单相接地短路	A	0.207 6	0.327 9	0.691 0	0.739 8
	B	0.204 7	0.222 8	0.445 7	0.696 2
	C	0.205 2	0.350 6	0.445 2	0.690 0
两相短路	A	0.203 0	0.233 1	0.338 5	0.456 8
	B	0.206 9	0.211 7	0.443 1	0.437 4
	C	0.203 8	0.324 8	0.418 3	0.499 1
两相接地短路	A	0.210 2	0.435 2	0.675 0	0.723 6
	B	0.208 2	0.446 1	0.677 0	0.731 9
	C	0.205 0	0.341 3	0.445 2	0.720 4
三相短路	A	0.205 4	0.212 1	0.282 0	0.464 1
	B	0.213 1	0.224 5	0.333 6	0.464 4
	C	0.212 5	0.256 5	0.365 2	0.485 3

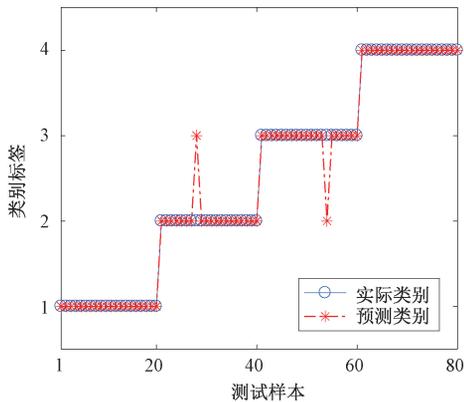


图 7 故障辨识结果

Fig. 7 Fault identification results

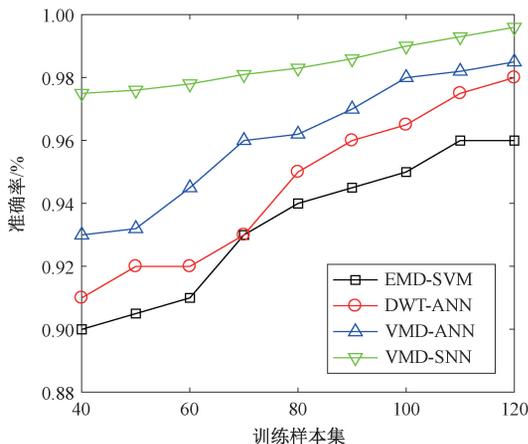


图 8 不同方法故障辨识准确率对比

Fig. 8 Comparison of the accuracy of fault identification by different methods

4 结 论

利用高压输电线路发生短路故障时三相电压具有较多故障信息的特点,提出一种 VMD-PE 与 SNN 相结合的故障辨识方法。通过大量仿真实验验证,得到以下结论: 1) VMD 可以有效的对故障时的三相电压信号进行自适应分解,防止发生模式混叠;2) VMD-PE 协同 SNN 对于输电线路的短路故障辨识具有良好的适用性;3) 与其他分类方法相比较,孪生神经网络可以对样本进行充分训练,深度挖掘样本之间的关系,在训练样本数据较小时具有更高的准确性,避免了因样本量不足而发生欠拟合的现象。

参考文献

[1] SAMANTARAY S R. A systematic fuzzy rule based approach for fault classification in transmission lines[J]. Applied Soft Computing, 2013, 13(2):928-938.

[2] 童晓阳,余森林,温豪.基于正序电流故障分量的输电线路故障检测[J].电力系统自动化,2018,42(24):150-162.

TONG X Y, YU S L, WEN H. Fault detection of transmission line based on of fault component positive sequence current [J]. Automation of Electric Power Systems, 2018,42(24):150-162.

[3] 姚敏,赵敏,邢力.基于数据融合的高压输电线接地故障检测方法[J].仪器仪表学报,2013,34(5):1139-1145.

YAO M, ZHAO M, XING L. Grounding fault detection method for high voltage transmission lines based on data fusion [J]. Chinese Journal of Scientific Instrument, 2013,34(5):1139-1145.

[4] 瞿合祚,刘恒,李晓明,等.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(3):146-152.
- QU H Z, LIU H, LI X M, et al. Feature combination optimization for multi-disturbance classification of power quality [J]. *Electric Power Automation Equipment*, 2017,37 (3): 146-152.
- [5] 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 J M, QU H Z, LI X M. Classification for hybrid power quality disturbances based on STFT and its spectral kurtosis [J]. *Power System Technology*, 2016, 40 (10): 3184-3191.
- [6] 孙蓉,马寿虎,葛乐,等.基于小波能量和 EMD 小电流接地故障选线[J].*中国科技论文*,2017,12(11):1247-1251.
- SUN R, MA SH H, GE L, et al. Fault line selection based on wavelet energy and EMD in non-solid-earthed network [J]. *China Science Paper*, 2017, 12 (11): 1247-1251.
- [7] 梅飞,梅军,郑建勇,等.粒子群优化的 KFCM 及 SVM 诊断模型在断路器故障诊断中的应用[J].*中国电机工程学报*,2013,33(36):134-141,19.
- MEI F, MEI J, ZHENG J Y, et al. Application of particle swarm fused KFCM and classification model of SVM for fault diagnosis of circuit breaker [J]. *Proceedings of the CSEE*, 2013,33 (36): 134-141,19.
- [8] 袁圃,毛剑琳,向凤红,等.改进的基于遗传优化 BP 神经网络的电网故障诊断[J].*电力系统及其自动化学报*,2017,29(1):118-122.
- YUAN P, MAO J L, XIANG F H, et al. Grid fault diagnosis based on improved genetic optimization BP neural network [J]. *Proceedings of the CSU-EPSA*, 2017,29 (1): 118-122.
- [9] ALI M S, BAKAR A H A, TAN C K, et al. High impedance fault localization using discrete wavelet transform for single line to ground fault [J]. *Arabian Journal for Science & Engineering*, 2017, 42(12):1-14.
- [10] 朱宁辉,白晓民,董伟杰.基于 EEMD 的谐波检测方法[J].*中国电机工程学报*,2013,33(7):92-98,14.
- ZHU N H, BAI X M, DONG W J. Harmonic detection method based on EEMD [J]. *Proceedings of the CSEE*, 2013,33 (7): 92-98,14.
- [11] 宁琦,耿读艳,王晨旭,等.基于多尺度排列熵及 PSO-SVM 的输电线路故障判别[J].*电子测量与仪器学报*,2019,33(7):173-180.
- NING Q, GENG D Y, WANG C X, et al. Fault identification of EHV transmission lines based on multi-scale entropy and PSO-SVM [J]. *Journal of Electronic Measurement and Instrumentation*, 2019, 33 (7): 173-180.
- [12] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. *IEEE Transactions on Signal Processing*, 2014, 62(3):531-544.
- [13] 张宁,朱永利,高艳丰,等.基于变分模态分解和概率密度估计的变压器绕组变形在线检测方法[J].*电网技术*,2016,40(1):297-302.
- ZHANG N, ZHU Y L, GAO Y F, et al. An on-line detection method of transformer winding deformation based on variational mode decomposition and probability density estimation [J]. *Power System Technology*, 2016,40 (1): 297-302.
- [14] 黄传金,周铜.基于变分模态分解的电能质量扰动检测新方法[J].*电力自动化设备*,2018,38(3):116-123.
- HUANG C J, ZHOU T. A new detection method of power quality disturbance based on VMD [J]. *Electric Power Automation Equipment*, 2018,38 (3): 116-123.
- [15] 高艳丰,朱永利,闫红艳,等.基于 VMD 和 TEO 的高压输电线路雷击故障测距研究[J].*电工技术学报*,2016,31(1):24-33.
- GAO Y F, ZHU Y L, YAN H Y, et al. Study on lightning fault locating of high-voltage transmission lines based on VMD and TEO [J]. *Transactions of China Electrotechnical Society*, 2016,31 (1): 24-33.
- [16] 高佳程,田蕴卿,朱永利,等.基于完全集合经验模态分解和排列熵的局部放电信号的小波包去噪方法[J].*电力系统及其自动化学报*,2018,30(3):1-7.
- GAO J C, TIAN Y Q, ZHU Y L, et al. Wavelet package denoising method for partial discharge signals based on CEEMD and PE [J]. *Proceedings of the CSU-EPSA*, 2018,30 (3): 1-7.
- [17] 吴汉钊.基于孪生卷积神经网络的人脸追踪[J].*计算机工程与应用*,2018,54(14):175-179.
- WU H Z. Face tracking using Siamese convolutional neural networks [J]. *Computer Engineering and Applications*, 2018,54 (14): 175-179.
- [18] 戴庆华,陈光化,唐逍,等.基于 Siamese 卷积神经网络的指静脉识别[J].*电子测量技术*,2018,41(24):51-55.
- DAI Q H, CHEN G H, TANG X, et al. Finger vein recognition based on Siamese convolutional neural network [J]. *Electronic Measurement Technology*, 2018,41 (24): 51-55.
- [19] 徐耀松,张原.基于改进 VMD-MSE 方法的输电线路故障特征分析及分类[J].*电子测量与仪器学报*,2019,33(6):89-95.

XU Y S, ZHANG Y. Feature analysis and classification of transmission line fault based on improving VMD-MSE methods [J]. Journal of Electronic Measurement and Instrumentation, 2019,33 (6): 89-95.

- [20] YANG L, JIANG P, WANG F, et al. Robust real-time visual object tracking via multi-scale fully convolutional Siamese networks [J]. Multimedia Tools and Applications, 2018.
- [21] PHILIPP P, FELIX V. Optimal approximation of piecewise smooth functions using deep ReLU neural networks[J]. Neural Networks,2018.

作者简介



付华, 1984 年于阜新矿业学院获得学士学位, 1994 年于阜新矿业学院获得硕士学位, 2006 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学教授, 研究方向为电力系统故障辨识。

E-mail: fxfuhua@163.com

Fu Hua received her B. Sc. degree from Fuxin Mining Institute in 1984, M. Sc. degree from Fuxin Mining Institute in 1994, and Ph. D. degree from Liaoning Technical University in 2006. Now she is a professor at Liaoning Technical University. Her main research interest includes power system fault identification.



金岑, 2018 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 研究方向为电力系统故障辨识。

E-mail: 2605601046@qq.com

Jin Cen received her B. Sc. degree from Liaoning Technical University in 2018. Now she is a M. Sc. candidate at Liaoning Technical University. Her main research interest includes power system fault identification.