

DOI:10.19651/j.cnki.emt.2212137

含光伏电源配电网故障的智能辨识方法研究

罗天禄¹ 王雪娜² 赵榕² 杨柳林²

(1. 广西电网有限责任公司 南宁 530023; 2. 广西大学电气工程学院 南宁 530004)

摘要: 在光伏电源接入配电网后,由于光伏发电的不确定性、间歇性、波动性增加了配电网故障的辨识难度。针对此问题,提出一种熵-变分模态分量与神经网络改进 ResNet 模型相结合的方法。首先搭建含光伏电源配电网 PSCAD 仿真模型,获取不同复杂故障情景下的批量数据。其次,利用熵-变分模态(E-VMD)方法重构样本的特征矩阵,再采用改进残差网络进一步挖掘故障样本的隐含特征,然后通过模型的训练与测试。与其他文献模型的分类效果对比,改进 ResNet 模型故障类型识别的准确率平均达到 99.95%,故障馈线识别的准确率达到 99.75%,且具有良好的鲁棒性,可以有效地实现含光伏电源配电网故障的快速辨识。

关键词: 配电网; 故障辨识; 熵-变分模态分解; 残差网络

中图分类号: TM726 文献标识码: A 国家标准学科分类代码: 470.4054

Research on intelligent fault identification method of distribution network including photovoltaic power supply

Luo Tianlu¹ Wang Xuena² Zhao Rong² Yang Liulin²

(1. Guangxi Power Grid Corporation, Nanning 530023, China;

2. School of Electrical Engineering, Guangxi University, Nanning 530004, China)

Abstract: After the PV power supply is connected to the distribution network, the uncertainty, intermittency and fluctuation of PV power generation increase the difficulty of identifying faults in the distribution network. To address this problem, this paper proposes a method combining the entropy-variance modal component with a neural network to improve the ResNet model. Firstly, a PSCAD simulation model of the distribution network containing PV power is built to obtain batch data under different complex fault scenarios. Secondly, the entropy-variance modal (E-VMD) method is used to reconstruct the feature matrix of the samples, and then the improved residual network is used to further explore the implied features of the fault samples, and then the model is trained and tested. In comparison with the classification results of other models in the literature, the improved ResNet model achieves an average accuracy of 99.95% for fault type identification and 99.75% for fault feeder identification, and has good robustness, which can effectively achieve fast fault identification in distribution networks containing PV power supplies.

Keywords: power distribution network; fault identification; variational mode decomposition residual; network

0 引言

传统配电网大多按照单一潮流方向进行故障判别及整定保护,而光伏的接入会造成配电网拓扑结构的改变。以往通过分析线路电压、电流方向的数值变动进行故障诊断的方法可能会造成误判、错判,从而引起保护装置误动、拒动及灵敏性降低等问题,不利于配电网的安全可靠运行^[1-3]。因此,对含光伏电源配电网故障辨识的研究具有重要的意义。

故障的辨识过程主要是故障数据特征的挖掘及故障分

类。常见的信号处理方法有小波包分析、希尔伯特黄变换、经验模态分解(empirical modal decomposition, EMD)及变分模态分解(variation mode decomposition, VMD)等。通过对信号的特征提取,再利用神经网络算法如 CNN(convolutional neural network, CNN), 残差网络(residual network, resNet), 孪生网络(siamese neural networks, SNN)等进行故障分类与识别。文献[4]提出一种时频域分析与随机森林结合的串联型低压故障电弧识别方法。根据多种负载频谱与纯阻性负载频谱的相关系数,将负载分为开关电源型负载和非开关电源型负载,分别训练两个随机

森林模型对其进行故障识别。文献[5]通过对暂态接地电容电流进行小波包分解,比较各条线路提取得到最大能量频带,再利用信号奇异性理论进行故障选线。文献[6]在配电网发生单相接地故障时故障特征微弱且易受外界噪声干扰时,提出基于参数优化变分模态分解 VMD 与能量相对熵相结合,确定熵值最大的区段即为故障区段。文献[7]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。文献[8]基于电流小波能量熵特征的检测直流串联微弱故障电弧的方法。通过计算电流信号脉冲因子,利用阈值比较法来检测故障电弧。文献[9]提出一种基于小波时频图和深度学习卷积神经网络的低压交流故障电弧诊断方法。利用 AlexNet 网络提取小波时频图特征,通过全连接层拟合数据实现故障电弧的智能诊断,但在不同负载类型的故障电弧图像存在一定数量的漏判或误判现象。文献[10]依据工频电流序分量分析故障距离相关性特征,构建特征匹配函数建立等效模型进行故障区段判别。文献[11]利用 ResNet 搭建基于迁移学习的 CNN 深度卷积神经网络模型,能在小样本情况下能迅速完成对故障区域的准确定位。一些传统方法基于数值整定与先验知识判别的方法在光伏电源接入系统后难以准确识别;而一些主流网络集中在加深网络层数与增加神经元个数,使得模型易陷入过拟合,影响最终故障辨识效果。

针对以上问题,本文基于信息熵理论与变分模态分解原理提出熵-变分模态分量(entropy-variational mode decomposition, E-VMD)方法进行故障数据的特征挖掘,

在保留原始数据时空特性的基础上进行时频域故障特征矩阵构造,利用 t-SNE 算法分析故障样本类别的聚集程度,验证了经 E-VMD 处理后样本区分度的增强。将所得故障样本作为神经网络的训练输入,利用改进 ResNet 模型强大的特征学习能力,实现故障类型与故障馈线的识别。

1 仿真模型与样本生成

通过 PSCAD 软件搭建含光伏发电的配电网仿真模型^[12]。模型由主电源、变压器、负载、光伏发电系统、架空线及电缆线路组成,如图 1 所示。

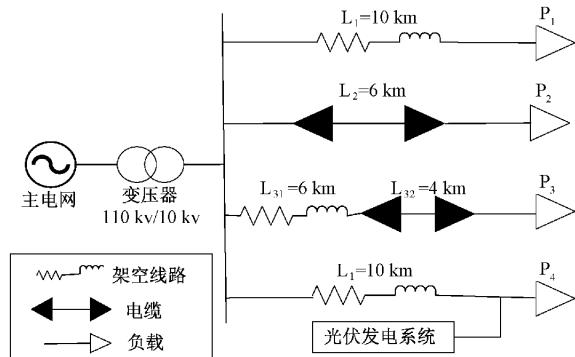


图 1 配电网仿真模型

仿真模型频率设置为 50 Hz, 主变压器采用 Y-Y 接线方式。监测装置在母线出口与馈线连接处进行电气信息采集,配网模型包括 $L_1 \sim L_4$ 4 条馈线, 各馈线负载分别为 $P_1 \sim P_4$, 具体参数如表 1 所示。

表 1 架空线路和电缆线路参数

类型	$R_t/(\Omega/\text{km})$	$L_t/(\text{mH}/\text{km})$	$C_t/(\mu\text{F}/\text{km})$	$R_o/(\Omega/\text{km})$	$L_o/(\text{mH}/\text{km})$	$C_o/(\mu\text{F}/\text{km})$
架空线	0.170	1.210	0.010	0.230	5.478	0.008
电缆线	0.270	0.225	0.339	2.700	1.019	0.280

利用 Python 语言编写故障仿真自动化程序,连接 PSCAD 软件接口实现故障仿真实验的自动化运行,进行不同情景下的故障实验以获得丰富的数据样本。具体参数设置如表 2 所示。采样频率设为 10 kHz, 提取故障前一

个周波起至故障发生后 4 个周波共 5 个周波长度作为采集区间。采集变压器低压侧 10 kV 母线处的三相电压、零序电流及各馈线的零序电流信号,每个采集样本大小为 8 × 1 000。

表 2 配网模型参数遍历值

故障类型	初始相角	过渡电阻/Ω	光伏接入位置	光伏照度 W/m ²	故障线路	故障位置
单相接地	60,120,180	10,50,90,2 000,3 000		700,900,1 100		
两相接地	60,120,180	[10~90]步长为 40		[500~1 300] 步长为 200		距各线路馈线
两相短路	60,120,180	[10~90]步长为 40	L4 馈线首端、 中端、末端	[500~1 300] 步长为 200	L1,L2, L3,L4	首端 20%、 40%、60%、 80% 处
三相短路	[60~360]步长为 60	[10~90]步长为 40		[500~1 300] 步长为 200		

2 故障样本特征提取

2.1 熵-变分模态原理

信息熵通常用于标定信号不确定性的程度,信号不确定程度越大,熵值越大^[13]。通过信号状态的概率分布来量化某个系统时间序列的不规则程度,故障信号的不确定性用熵值进行表示,计算公式如下:

$$H(x) = - \sum_{k=1}^N p_k \log_2(p_k) \quad (1)$$

式中: p_k 为事件对应发生的概率; N 为类别数目,且 $\sum_{k=1}^N p_k = 1$ 。

VMD 以其强大的数据自适应分解能力在故障信号处理方面得到越来越多的应用,对于非平稳、非线性信号具有良好的处理效果^[14-16]。VMD 结合实际情况确定序列的分解个数,采用完全非递归迭代搜寻模型的最佳中心频率和有限宽带,将信号序列分解成为相对稳定的 K 个不同频率下 IMF 分量,从而实现信号的有效分解。

假设配电网监测设备采集到的电气信号为 $f(t)$,通过预设尺度数 K 将该信号分解为 K 个 IMF 分量,第 k 个 IMF 分量记作 $u_k(t)$ 满足 3 个约束条件: K 个 IMF 分量之和等于 $f(t)$; K 个 IMF 分量带宽之和最小; 每个模态分量 $u_k(t)$ 都具有各自的中心频率和有限带宽。

将各个模态分量对应带宽之和的最小值作为式(1)优化的目标函数,其中 ∂_t 为函数对 t 的偏导数; $\delta(t)$ 为脉冲函数。则有:

$$\sum_{k=1}^K u_k = f(t) \quad (2)$$

$$\min_{\{u_k\}, \{w_k\}} \left\{ \sum_k \left\| \partial_t \left\{ \left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \right\} e^{-j w_k t} \right\|_2^2 \right\} \quad (3)$$

将约束变分问题转变为非约束变分问题得到增广 Lagrange 表达式,其中 α 为惩罚因子; $\lambda(t)$ 为约束项。如式(4)所示。

$$L(\{u_k\}, \{w_k\}, \lambda(t)) = \alpha \sum_k \left\| \partial_t \left\{ \left[\delta(t) + \frac{J}{\pi t} \right] u_k(t) \right\} e^{-j w_k t} \right\|_2^2 + \| f(t) - \sum_k u_k(t) \|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (4)$$

初始化参数 u_1, w_1, λ_1 和 n , 其中 $n = 0$, 按照式(5)~(7)迭代更新优化:

$$u_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i=1, i < k}^N u_i^n(\omega) - \sum_{i=1, i < k}^K u_i^n(\omega) + \frac{\lambda^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (5)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |u_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty \omega |u_k^n(\omega)|^2 d\omega} \quad (6)$$

$$\lambda^{n+1} = \lambda^n(\omega) + \tau (f(t) - \sum_k u_k^n(\omega)) \quad (7)$$

停止迭代的条件为:

$$K_u = \frac{E(x - \mu)^4}{\sigma^4} \quad (8)$$

当满足式(8)时,即可认为迭代收敛满足精度,将 K 个 IMF 分量输出,完成变分模态的分解。

2.2 特征提取分析

根据前面的理论与仿真实验,选取馈线和母线的零序电流及三相电压作为原始采集信息量,结合熵理论与 VMD 提出 E-VMD 方法进行包含空间位置信息、时频带信息的故障特征提取。

1) 提取时频域特征

每个故障仿真实验采集 M 个电气量,时间序列长度为 N 的信息作为一个故障样本,每个故障样本数据记为:

$$X_{N \times M} = [x_{1, N_0}; \dots; x_{m, N_0}; \dots; x_{M, N_0}] (N_0 \in 1, 2, \dots, N) \quad (9)$$

若该电气量分解得到 K 条 IMF 分量,分量的序列长度仍为 N ,信号被分解重构为 $K \times N$ 大小的时频矩阵,则第 m 个电气量的第 k 个 IMF 分量可分为:

$$x_{m, k} = [imf_{k, 1}(n); \dots; imf_{k, p}(n); \dots; imf_{k, P}(n)] (1 \leqslant p \leqslant P), (1 \leqslant n \leqslant N_T) \quad (10)$$

式中: $P = N/N_T$, 为每个 IMF 分量划分的总段数; $imf_{k, p}(n)$ 表示第 k 个 IMF 分量在第 p 段上第 n 个采样点对应的数值; N_T 为每周期的采样点数。

最后得到 IMF 分量时频域特征,如式(11)所示。

$$M_{s_{k, p}} = \frac{1}{N_T} \sum_{n=1}^{N_T} imf_{k, p}(n) \quad (11)$$

2) 计算能量熵

将上述分解得到的各分量 P 段瞬时能量值表示为:

$$E_{k, p} = \sum_{n=1}^{N_T} imf_{k, p}^2(n) \quad (12)$$

该电气信号的总能量:

$$E = \sum_{k=1}^K \left(\sum_{p=1}^P E_{k, p} \right) \quad (13)$$

式中: $\sum_{p=1}^P E_{k, p}$ 表示第 k 个分量的能量。

结合 IMF 与熵理论可用能量熵^[17]来描述某个信号分量对该信号的重要性特征,公式如下:

$$H_{E_{k, p}} = - \sum_{p=1}^P \frac{E_{k, p}}{E} \log_2 \left(\frac{E_{k, p}}{E} \right) \quad (14)$$

当能量分布发生改变时,其概率值会减少,计算得到的能量熵增大,表示各分量能量越混乱,越不稳定。

3) 获取特征矩阵

将电气量 k 个 IMF 分量 p 段内的特征表示为:

$$v_{imf_{k, p}}^y = [M_{s_{k, p}}, V_{a_{k, p}}, K_{q_{k, p}}, P_{sd_{k, p}}, M_{sf_{k, p}}, F_{c_{k, p}}, V_{f_{k, p}}, H_{E_{k, p}}] \quad (15)$$

则电气量 M 的故障特征表示为:

$$V_{imf_{k, p}}^y = [v_{imf_{1, p}}^y, v_{imf_{2, p}}^y, \dots, v_{imf_{k, p}}^y, \dots, v_{imf_{M, p}}^y] \quad (16)$$

通过式(17)将其转化为一个无量纲的相对数值以保证分析的可靠性, $v_{imf_{k,p}}^y$ 、 $v_{imf_{k,p}}^y$ 分别表示归一化处理前后的一维向量 $\max(v_{imf_{k,p}}^y)$ 、 $\min(v_{imf_{k,p}}^y)$ 分别表示归一化处理前一维向量的最大值与最小值。

$$v_{imf_{k,p}}^y = \frac{v_{imf_{k,p}}^y - \min(v_{imf_{k,p}}^y)}{\max(v_{imf_{k,p}}^y) - \min(v_{imf_{k,p}}^y)} \quad (17)$$

对矩阵进行归一化操作之后可得:

$$V_{imf_{k,p}} = [v_{imf_{1,p}}, v_{imf_{2,p}}, \dots, v_{imf_{k,p}}, \dots, v_{imf_{K,p}}] \quad (18)$$

然后对采集的其余时序信号进行重复操作, 依据样本信号的空间特性进行位置排列得到该样本的特征量, $V_{imf_{k,d}}^m$ 表示第 m 个电气量经 VMD 分解得到的第 k 条 IMF 分量中第 d 个特征量。将其依次展开可得:

$$V_{K,D}^m = \begin{bmatrix} v_{imf_1,1}^1 & \cdots & v_{imf_1,d}^1 & v_{imf_1,D}^1 \\ \vdots & \ddots & \vdots & \vdots \\ v_{imf_k,1}^m & \cdots & v_{imf_k,d}^m & v_{imf_k,D}^m \\ \vdots & \ddots & \vdots & \vdots \\ v_{imf_K,1}^M & \cdots & v_{imf_K,d}^M & v_{imf_K,D}^M \end{bmatrix} \quad (19)$$

2.3 降维与可视化

t-随机邻近嵌入算法(t-distributed stochastic neighbor embedding, t-SNE)是一种基于概率的非线性降维算法, 经过特征提取之后的数据样本维度缩减, 可将高维数据降维至二维或三维空间中, 并保留数据集的局部特性, 在许多领域展现出了良好的可视化展示性能^[18-19]。将高维空间中的样本采用高斯核心函数定义保留数据的局部和全局结构, 高维数据点 x_i 与 x_j 之间的条件概率 $p_{j|i}$ 由式(20)得出:

$$p_{j|i} = \frac{\exp(-\|x_i - x_j\|^2 / 2\sigma_i^2)}{\sum_{k \neq i} \exp(-\|x_i - x_k\|^2 / 2\sigma_i^2)} \quad (20)$$

式中: σ_i 是以数据点 x_i 为中心的高斯方差。

为使得相似度更大的点在低维空间中的分布更加接近, 采用更注重长尾分布的 t 分布对低维数据对应点 y_i 与 y_j 的条件概率进行表示:

$$q_{j|i} = \frac{\exp(-\|y_i - y_j\|^2)}{\sum_{k \neq i} \exp(-\|y_i - y_k\|^2)} \quad (21)$$

关于 2 个样本分布之间的嵌入点位置(kullback-leibler, KL)散度实现低维空间至高维空间的样本相似分布, 可通过寻求 KL 的最小值将样本降维, 公式如下:

$$KL(p \parallel q) = \sum_i \sum_j p_{ij} \log \frac{p_{ij}}{q_{ij}} \quad (22)$$

3 改进残差网络

随着网络层数的加深, 网络模型对非线性结构的拟合能力有所增强, 但在网络性能提升的研究中发现当网络层数增加到一定数值后, 网络性能会达到饱和甚至出现退化及过拟合^[20]。ResNet 以特有的“短路链接”方式避免了随

着神经网络层数加深可能导致某些特征缺失和信息丢失, 从而影响最终训练结果。ResNet 模块如图 2 所示, 其核心部分就是输入 x 通过添加一个快捷路径——恒等映射分支与主路径结果相加得到 $F(x) + x$, 最后再经非线性 ReLU 激活函数输出。由于快捷路径的存在既保证了模型的性能又降低了过拟合风险。

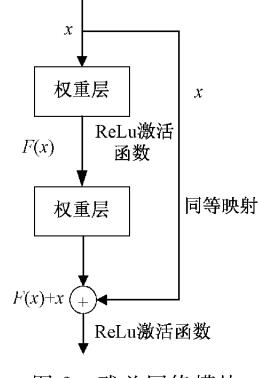


图 2 残差网络模块

ResNet 的核心是残差模块。在残差模块结构的基础上得到改进后的 ResNet 模型结构如图 3 所示, 其中 k, n, s, p 分别代表卷积核、数量、步长及填充方式。改进 ResNet 主要由 3×3 尺寸的卷积核堆叠模块组成, 池化层采用 2×2 尺寸核按最大池化方式保留更多纹理信息进行特征整合, 步长设置为 2, 全 0 填充方式。每层卷积网络都由 BN 算法, ReLU 激活函数, 卷积层 3 部分操作完成特征提取, 网络隐藏层后接全连接层经由 Softmax 函数激活输出节点进行网络输出。

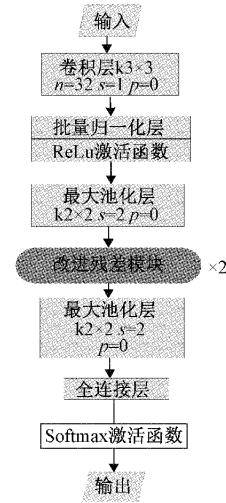


图 3 改进残差网络模型结构

假设卷积层的输入为 i , 该层的卷积核个数为 j , 卷积核大小为 $n \times m$, 则需要训练的参数个数为:

$$N = (n \times m \times i + 1) \times j \quad (23)$$

在输入特征维度相同、卷积核个数一样时, 卷积核大小由 3×3 分解为 3×1 , 则改进后卷积层需要训练的参数

数量约为之前的 1/3 左右,网络模型体积减小从而提高了模型训练效率。网络的横纵卷积核尺寸大小不一,丰富了感受野尺寸,进一步提升网络故障特征区分度。

4 实验与分析

4.1 样本优化处理

本次仿真实验搭建含光伏发电配电网模型作为故障辨识电路,通过改进 ResNet 模型对经 E-VMD 优化处理的故障样本进行训练学习与分类,来验证文中所提方法的有效性。根据前面熵变分模态原理分析可知对数据进行 VMD

分解过程中,模型优劣程度主要由惩罚系数 α 与模态分解个数 K 决定。惩罚系数可根据经验进行设置,采用有较强适应性的默认值 $\alpha=2\,000$ 。VMD 需要进行人为设置分解尺度 K ,结合 100 组零序电流信号和故障相电压信号特征矩阵尺寸问题,选取 $K=5$,能最大程度上地保留故障特征信息和信号分解的有效性,结果如图 4 所示。对采集到的故障信号进行 VMD 分解得到其对应的模式分量,其中主变压器低压侧的 A 相电压与零序电流信号 4 种故障类型下的 VMD 分解结果如图 5~8 所示,各种故障类型的不同模式分量蕴含着丰富的高频、低频特征,有利于进行故障识别。

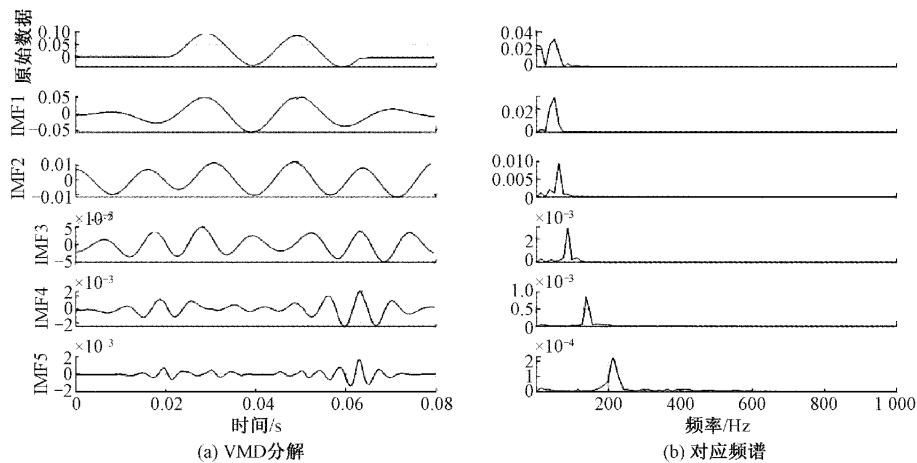


图 4 $K=5$ 时,VMD 分解与各分量频谱对照图

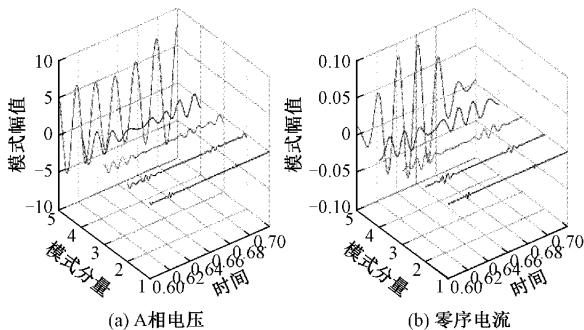


图 5 单相接地故障时的模式分量

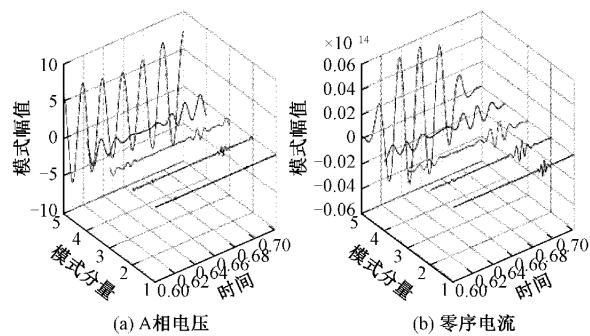


图 7 两相接地故障时的模式分量

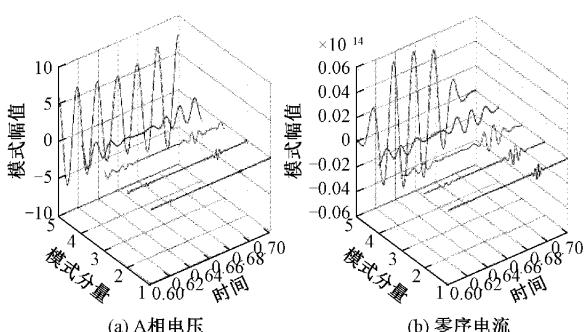


图 6 两相短路故障时的模式分量

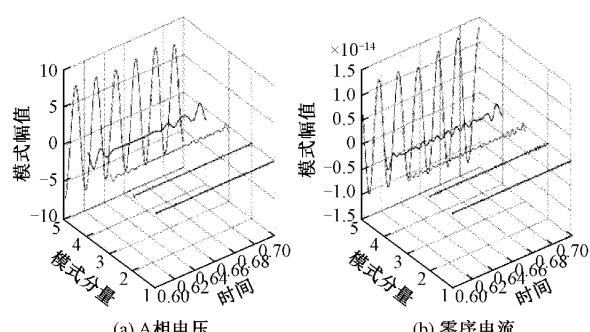


图 8 三相短路故障时的模式分量

将分解得到的模式分量从 0.60~0.70 s 以仿真周期

时长划分为 5 段,分别对各段进行特征提取一个长度为 8

的横向量，并将各段横向量依次横向排列得到 1×40 的特征量，各模式分量再按自上至下拼接得到 5×40 的特征量，再根据式(17)进行归一化计算以避免覆盖较小数值的特征值，最后重复上述操作得到其特征量。

按照空间位置规则排列得到故障样本特征矩阵，4 种故障类型的特征样本矩阵如三维曲面图 9 所示。经 E-VMD 处理后故障样本由 8×1000 变为 40×40 的故障特征矩阵，降低了故障数据维度，减轻后续神经网络的训练负担。同样对故障信号模式分量及相应时间段进行特征提取增加了不同样本间的区分度，有利于提高样本的数据质量。

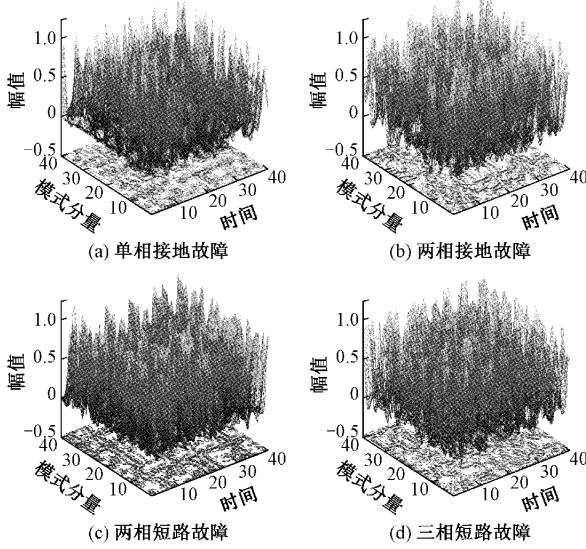


图 9 4 种故障类型特征样本三维曲面图

利用 t-SNE 算法将未经处理的原始数据与经过 E-VMD 处理后的不同故障馈线及故障类型样本计算空间距离绘制二维平面散点图如图 10、11 所示。

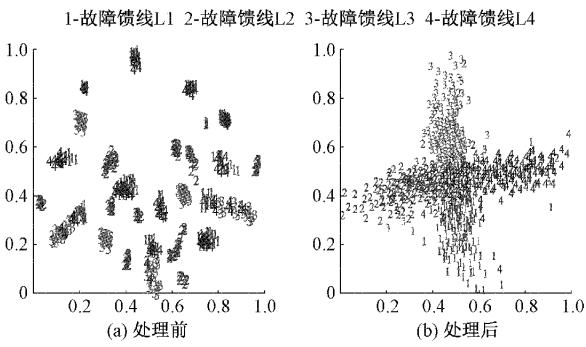


图 10 E-VMD 处理前后故障馈线样本距离散点图

由以上散点图可知，处理前的各故障整体聚集效果较差，经 E-VMD 处理后样本集具有更加明显的区分度，使得故障样本同类聚集程度有所提高，有利于后续神经网络模型的学习训练。

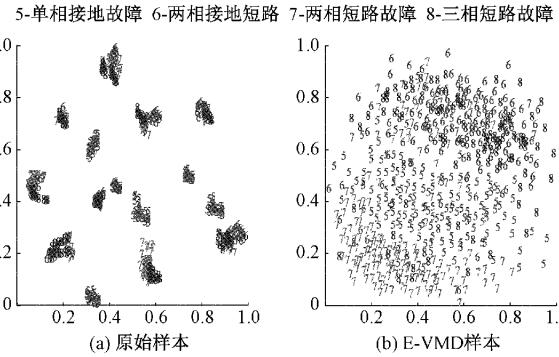


图 11 E-VMD 处理前后故障类型样本距离散点图

4.2 网络训练

网络训练测试在 Anaconda 集成开发环境下采用 TensorFlow 作为深度学习框架，使用 Python 编程语言进行网络搭建。根据获得的仿真数据结果进行网络训练，其中具体样本分布如表 3 所示。

表 3 故障馈线与故障类型仿真样本分布

	单相 接地 故障	两相 接地 故障	两相 短路 故障	三相 短路 故障	总计
故障馈线 L1	540	540	540	360	1 980
故障馈线 L2	540	540	540	360	1 980
故障馈线 L3	540	540	540	360	1 980
故障馈线 L4	1 080	1 080	1 080	360	3 600
总计	2 700	2 700	2 700	1 440	9 540

故障样本总数为 9 540 个，将训练集、验证集以及测试集划分为 8 : 1 : 1。对网络进行训练，其中批处理大小设置为 64，进行 10 个迭代 epoch，以 Adam 算法进行参数优化。网络训练集和验证集训练损失曲线如图 12 所示，在训练到第 7 个 epoch 时训练集，模型训练效果基本达到收敛且保持稳定。

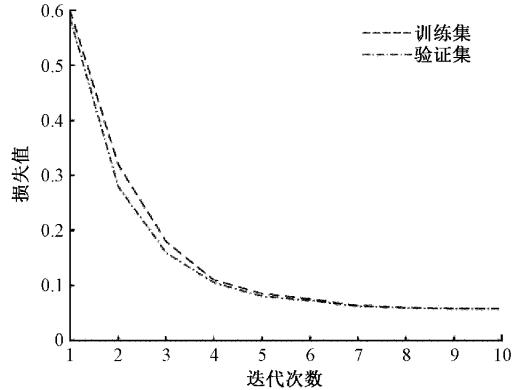


图 12 网络训练集损失值与验证集损失值

将未处理的原始数据集与经 E-VMD 处理的数据集送

入网络模型进行测试,随着迭代次数增加数据集的准确率上升,结果如图13所示。但在原始数据集的准确率曲线训练过程中产生抖动,反映了模型在训练过程中具有不稳定性,易出现过拟合现象。对比其他几类模型的准确率,改进后的网络模型具有更高的准确率和稳定性。

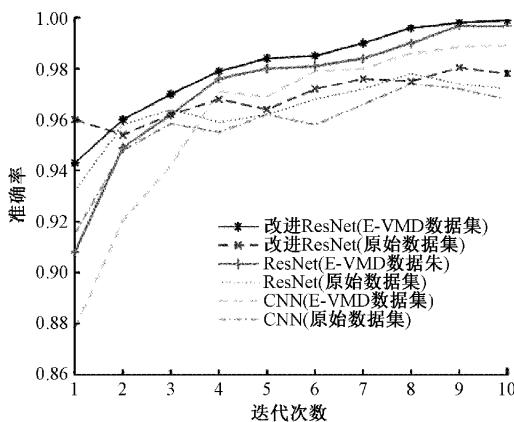


图13 数据集处理前后准确率

4.3 结果分析与对比

将测试集送入改进 ResNet 模型进行测试,对故障类型、故障馈线进行测试分类,改进 ResNet 模型的分类评估结果如表 4 所示。

表 4 测试集分类评估结果 %

	准确率	精确率	召回率	调节均值
单相接地故障	100	100	100	100
两相接地故障	99.83	100	99.26	99.63
两相短路故障	100	100	100	100
三相短路故障	100	100	100	100
馈线 L1	100	100	100	100
馈线 L2	100	100	100	100
馈线 L3	100	100	100	100
馈线 L4	99.90	100	99.72	99.86

故障类型与故障馈线的辨识效果做分类混淆矩阵如图 14 所示。分类混淆矩阵大小为 16×16 ,坐标轴上的 1、2、3、4 分别表示单相接地故障、两相接地故障、两相短路故障、三相短路故障;5、6、7、8 分别表示故障馈线 L1 至故障馈线 L4。对角线上数值表示预测值与实际值的重合度情况,非对角线的元素表示模型错分情况,元素值越少表明模型的分类效果越好。结合表 4 与图 14 分析可得,模型在单相接地故障、两相短路故障与三相短路故障测试集中均可进行准确识别。分类效果在两相接地故障类型有所下降,但其精准率可达到 100%。在测试集辨识效果中,故障馈线辨识效果整体优于故障类型辨识效果,仅馈线 L4 处存在一例漏报。

将本文模型测试集的故障类型与故障馈线分类效果

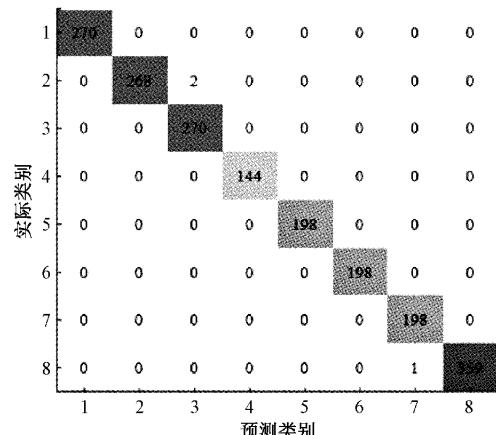


图 14 故障识别分类混淆矩阵

与以下文献所提方法进行对比如表 5 所示。由表 5 可知改进 ResNet 的故障分类准确率接近 100%。文献[10]利用 WEE 算法提高故障暂态特征区分度,通过 KELM 在单相接地故障分类准确率达到 100%。文献[21]两相接地故障辨识准确率虽高出改进 ResNet,但其余故障辨识率均低于改进 ResNet。文献[22]长短期记忆网络融合深度 Q 网络虽在记忆力分析上有所改进,但对三相接地故障类型的辨识准确率较低,相比其他故障类型辨识准确率低 30% 左右。文献[11]、[23]分别采用 AlexNet、ResNet 识别故障线路取得较好的分类效果。但本文提出的改进 ResNet 整体辨识效果表现更佳,进一步提升了故障辨识的准确度和分类性能。

表 5 故障分类效果对比 %

	故障类型准确率				故障 馈线 准确率	
	单相接地 故障		两相接地 故障			
	两相短路 故障	三相短路 故障	两相短路 故障	三相短路 故障		
文献[10]	100	99.83	99.3	99.2	—	
文献[21]	100	99.87	100	99.62	—	
文献[22]	96.84	93.42	90.67	69.04	—	
文献[11]	—	—	—	—	91.88	
文献[23]	—	—	—	—	99.68	
本文	100	99.83	100	100	99.75	

5 结 论

文中在残差模块的基础上提出改进残差网络,将 E-VMD 处理后的故障样本通过网络模型训练与测试,进行含光伏电源配电网故障辨识任务。训练过程中的损失曲线下降验证了该网络模型的稳定性,仿真实验结果表明:处理后的数据集更易进行故障的分类判别,说明故障特征提取的有效性,验证了改进 ResNet 模型的表征能力。通过对其他几类模型,改进 ResNet 模型具有更好的抗干扰性和辨识效果。

然而,改进 ResNet 在处理不同光伏出力情景下的故障分类表现有限,需要不同出力情况下的大量故障数据进行训练与学习。因此,未来可将光伏出力的情况作为故障辨识的一个特征属性,便于模型直观地根据光伏出力特性学习相应的有效特征,以降低故障数据量需求与网络计算负担。

参考文献

- [1] 晁晨栩,郑晓冬,高飘,等.含高比例光伏配电网的高频阻抗差动保护[J].中国电机工程学报,2021,41(20):6968-6979.
- [2] 程丽,李鑫,项兴尧,等.基于潮流计算的分布式光伏接入对配电网电压影响研究[J].科技通报,2021,37(5):31-36.
- [3] 黄瑶玲,杨楠,刘浔,等.分布式光伏电源接入对配电网影响[J].电工材料,2022,50(1):78-80.
- [4] 王毅,陈进,李松浓,等.基于时频域分析和随机森林的故障电弧检测[J].电子测量与仪器学报,2021,35(5):62-68.
- [5] 叶宝柱,薛超宇,张惠娟,等.基于特征频带小波包分析的配电网故障选线的研究[J].电气工程学报,2018,13(2):24-28.
- [6] 杜政奇,王敬华,张新慧.基于参数优化 VMD 和能量相似度的配电网故障区段定位方法[J].电子测量技术,2022,45(8):95-101.
- [7] 付华,金岑.VMD-PE 协同 SNN 的输电线路故障辨识方法[J].电子测量与仪器学报,2020,34(6):86-92.
- [8] 唐圣学,刁旭东,陈丽,等.光伏发电系统直流串联微弱故障电弧检测方法研究[J].仪器仪表学报,2021,42(3):150-160.
- [9] 向小民,汪杰,卢云.基于小波时频图和 AlexNet 网络的电弧故障诊断方法[J].国外电子测量技术,2022,41(10):170-177.
- [10] 李浩茹,丁保迪,季宇,等.考虑光伏出力间歇性的微电网故障辨识方法[J].电力建设,2020,41(9):76-85.
- [11] 孟子超,杜文娟,王海风.基于迁移学习深度卷积神经网络的配电网故障区域定位[J].南方电网技术,2019,13(7):25-33.
- [12] 邓丰,李欣然,曾祥君,等.基于多端故障行波时差的含分布式电源配电网故障定位新方法[J].中国电机工程学报,2018,38(15):4399-4409.
- [13] 党建,罗燚,田录林,等.基于优化的 VMD 融合信息熵和 FA_PNN 的风电机组齿轮箱故障诊断[J].太阳能学报,2021,42(1):198-204.
- [14] 肖启明,郭谋发.基于变分模态分解与图信号指标的配电网高阻接地故障识别算法[J].电气技术,2021,22(5):50-55.
- [15] 郑小霞,周国旺,任浩翰,等.基于变分模态分解的风机滚动轴承早期故障诊断[J].轴承,2016,440(7):48-53.
- [16] 江星星,宋秋昱,杜贵府,等.变分模式分解方法研究与应用综述[J].仪器仪表学报,2023,44(1):55-73.
- [17] 张小菊,张歆,孙进才.基于 IMF 能量熵的目标特征提取与分类方法[J].计算机工程与应用,2008(4):68-69.
- [18] PAN M, JIANG J, KONG Q, et al. Radar HRRP target recognition based on t-SNE segmentation and discriminant deep belief network[J]. IEEE Geoscience and Remote Sensing Letters, 2017,14(9): 1609-1613.
- [19] DA S L M A, DORIA N A D, DE M M A. Parallel t-SNE applied to data visualization in smart cities[J]. IEEE Access, 2020,8: 11482-11490.
- [20] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [J]. ArXiv Preprint ArXiv:1512.03385.
- [21] MOHAN N, SOMAN K P, VINAYAKUMAR R. Deep power: Deep learning architectures for power quality disturbances classification [C]. 2017 IEEE International Conference on Technological Advancements in Power and Energy(TAP Energy), IEEE,2017:1-4.
- [22] 姚欣,邢砾云,辛平.基于小波特征提取与深度学习的微电网故障诊断与分类方法[J].智慧电力,2021,49(12):17-24.
- [23] 侯思祖,郭威,王子奇,等.基于小波 AlexNet 网络的配电网故障区段定位方法[J].电测与仪表,2022,59(3):46-57.

作者简介

罗天禄,工程师,主要研究方向为新型电力系统规划与故障自愈。

E-mail:117532261@qq.com

王雪娜,硕士研究生,主要研究方向为风能和太阳能发电。

E-mail:1944889584@qq.com

赵榕,硕士研究生,主要研究方向为电力系统分析与计算。

E-mail:2252532710@qq.com

杨柳林(通信作者),博士,副教授,主要研究方向为电力系统分析与计算、大数据及其应用等。

E-mail:yangll@gxu.edu.cn