

基于VMD-MTF-CNN的故障电弧检测方法

董志文^{1,2,3}, 苏晶晶^{2,3}

(1. 福建理工大学 电子电气与物理学院, 福建 福州 350118;

2. 闽江学院 计算机与大数据学院, 福建 福州 350108;

3. 浙江省机电设计研究院有限公司, 浙江 杭州 310051)

摘要: 低压配电线路可能产生故障电弧引发电路故障, 为了区分正常电流和有故障电弧的电流, 提出一种基于电流二维图像与卷积神经网络的故障电弧检测方法。首先利用变分模态分解重构电流信号, 解决非线性型负载正常和故障电流难以辨识的问题; 再使用马尔可夫转移场算法对重构电流信号进行二维图像编码, 生成特征图像数据集。为了提高故障电弧检测的准确率和效率, 构建了基于卷积神经网络的故障诊断模型, 将所提特征图像数据集与未经信号重构的特征图像数据集分别输入到所构建的诊断模型进行对比验证, 结果表明, 所提方法能有效改善非线性负载状态混淆, 故障检测的平均准确率达到99%。

关键词: 故障诊断; 马尔可夫转移场; 变分模态分解; 卷积神经网络

中图分类号: TP183; TM501.2 **文献标志码:** A **文章编号:** 2097-3853(2024)04-0371-08

Arc fault detection method based on VMD-MTF-CNN

DONG Zhiwen^{1,2}, SU Jingjing^{2,3}

(1. School of Electronic, Electrical Engineering and Physics, Fujian University of Technology, Fuzhou 350118, China;

2. School of Computer and Data Science, Minjiang University, Fuzhou 350108, China;

3. Zhejiang Institute of Mechanical & Electrical Engineering Co., Ltd., Hangzhou 310051, China)

Abstract: Low-voltage distribution lines may produce arc faults, which may cause circuit faults. To distinguish between normal and fault currents, a fault arc detection method based on two-dimensional current images and convolutional neural networks is proposed. Firstly, the current signals are reconstructed using variational mode decomposition to address the challenge of distinguishing between normal and fault currents in nonlinear loads. Then, the Markov transition field algorithm is utilized to encode the reconstructed current signals into two-dimensional images, generating a dataset of feature images. To enhance the accuracy and efficiency of fault arc detection, a CNN-based fault diagnosis model is constructed. The proposed feature image dataset and the dataset of feature images without signal reconstruction are respectively fed into the constructed diagnostic model for comparison and validation. Results indicate that the proposed method effectively mitigates the confusion caused by nonlinear load states, achieving an average detection accuracy of 99%.

Keywords: fault diagnosis; Markov transition field; variational mode decomposition; convolutional neural networks

在低压配电系统中, 因设备绝缘老化、接线端子松动或线路表皮破损等原因可能会产生故障电弧, 引发电气火灾^[1]。故障电弧可分为串联电弧、并联电弧和接地电弧。通常情况下, 并联故障

电弧和接地故障电弧会导致回路电流迅速增加, 故障线路可使用漏电保护器、剩余电流断路器、浪涌保护器等保护电器切除。串联故障电弧就像线路中突然增加的非线性负载, 其线路电流将比运

收稿日期: 2024-01-23

基金项目: 福建省自然科学基金(2020J05170); 闽江学院科研项目(MYK21014)

第一作者简介: 董志文(1997—), 男, 福建南平人, 硕士研究生, 研究方向: 故障电弧检测。

通信作者: 苏晶晶(1986—), 女, 福建漳平人, 讲师, 博士, 研究方向: 电器及其智能化技术等。

行时低,波形特征也将发生变化^[2]。一些干扰性负载正常运行时的波形与故障电弧发生时的波形非常相似,故障电弧电流的识别难度大^[3-4]。

国内外学者往往通过大量故障电弧波形分析来获取串联故障电弧特征,研究其检测技术^[5]。当前针对故障电弧的检测研究主要分为传统机器学习算法和深度学习算法。文献[6]提取故障电流信号的样本熵作为特征值输入极限学习机(extreme learning machine, ELM)中进行识别。文献[7]通过提取时域和频域特征构成特征数据集,使用 CatBoost 模型对故障电弧实现识别。文献[8][9]采用自适应噪声的完全集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)算法对信号进行分解,提取本征模态分量(intrinsic mode functions, IMFs)的能量特征和熵特征,统计特征指标构成特征矩阵,输入到支持向量机(support vector machine, SVM)中进行故障识别。然而,这些传统的机器学习算法只对串联故障电弧的故障进行识别,并未区分其负载类型,特征提取的过程也相对繁琐^[10]。深度学习算法因其能够自动提取特征大大提高了特征提取的效率和准确率,深受研究者青睐。深度学习算法将预处理信号作为数据输入自动进行特征提取,并将提取的特征输送给最后的全连接层,实现分类目的^[11]。文献[12]基于 AlexNet 网络结构对故障电弧检测做了初步的尝试,将采集到的信号输入到改进的 AlexNet 网络中预测,正确率为 85%左右。文献[13][14]通过对采集信号进行小波变换和短时傅里叶变换将一维电流信号转为二维图像,再将生成的图像输入改进 AlexNet 模型中进行识别,提高了识别的正确率。然而,实验发现直接处理一维波形数据获取的特征容易受到负载性质的影响,尤其是非线性的负载正常运行时的波形与故障电弧发生时的波形相似容易混淆。

综上,本研究提出一种基于电流二维图像与卷积神经网络的故障电弧检测方法。利用变分模态分解(variational modal decomposition, VMD)对电流信号进行时频分解,重构电流信号;随后采用马尔可夫转移场(markov transition field, MTF)算法对重构的电流信号进行二维编码,生成特征图像作为神经网络的输入,通过构建的卷积神经网络模型,实现对电气线路正常状态和故障状态

的辨识。

1 基本原理

1.1 变分模态分解

变分模态分解是一种自适应、完全非递归的模态变分和信号处理方法^[15]。算法通过所给信号的模态分解个数,自适应地匹配每种模态的最佳中心频率和带宽数,从而有效地分离固有模态分量,划分信号的频域,获得给定信号的有效分解成分,最终达到变分问题的最优解。

VMD 变分模型构造如公式(1)所示。

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_{k=1}^K u_k(t) = f(t) \end{cases} \quad (1)$$

式中, $f(t)$ 为原始信号; k 为模态数量; ∂_t 为求梯度运算; u_k 为第 k 个 IMF 分量; ω_k 为 u_k 的中心频率; $\delta(t)$ 为脉冲函数。

引入二次惩罚因子 α 和拉格朗日乘法算子 λ ,将约束性变分问题变为非约束性变分问题,如式(2)所示。

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \quad (2)$$

通过交替更新计算,求扩展拉格朗日表达式的鞍点及最优解:

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

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

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left(\hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k^{n+1}(\omega) \right) \quad (5)$$

式中, $\hat{u}_k^{n+1}(\omega)$ 、 $\hat{f}(\omega)$ 、 $\hat{\lambda}(\omega)$ 分别为 $u_k^{n+1}(t)$ 、 $f(t)$ 、 $\lambda(t)$ 的傅里叶变换; τ 为噪声容忍度。

迭代约束条件如式(6)所示。

$$\sum_{k=1}^K \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (\varepsilon > 0) \quad (6)$$

式中, ε 为设定阈值。

1.2 二维图像编码

马尔可夫转移场^[16]利用马尔可夫过程的性质,将时间序列的状态转移抽象为马尔可夫转移矩阵,并将其扩展为马尔可夫转移场来进行图像编码。在MTF中,时间序列的演变基于马尔可夫链。马尔可夫链的未来状态只取决于当前状态,不会受过去状态的影响。因此,马尔可夫转移场克服了因摆脱时间依赖性导致转移矩阵中过多的信息丢失的问题。

对于时间序列 $X = \{x_1, x_2, x_3, \dots, x_n\}$, 其图像编码过程包括4个步骤。

第1步,将时间序列 X 分成 Q 分位箱。

第2步,将时间序列中每一个数据更改为对应分位箱的序号。

第3步,构造转移矩阵 W :

$$W = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1Q} \\ w_{21} & w_{22} & \dots & w_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ w_{Q1} & w_{Q2} & \dots & w_{QQ} \end{bmatrix} \quad (7)$$

式中, w_{ij} 表示分位箱 i 转移到分位箱 j 的概率。

第4步,构造马尔可夫转移场 M :

$$M = \begin{bmatrix} m_{11} & m_{12} & \dots & m_{1Q} \\ m_{21} & m_{22} & \dots & m_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ m_{Q1} & m_{Q2} & \dots & m_{QQ} \end{bmatrix} \quad (8)$$

$$m_{ij} = p\{w_{ij} | x_i \in q_i, x_j \in q_j\} \quad (9)$$

式中, m_{ij} 表示分位箱 i 转移到分位箱 j 的概率。

以阻性负载电流波形为例介绍 MTF 二维编码的过程,如图1。选取的分位箱 $Q=4$,生成 4×4 的转移矩阵 W ,再与电流波形构建填充生成马尔可夫转移场 M ,经过降采样处理,生成可视化的二维编码图。不同的颜色反映了分位数之间的转移概率大小,灰色代表大概率,黑色代表小概率。

1.3 基于CNN故障电弧识别模型

在模式分类领域,卷积神经网络可以避免复杂的特征量前期预处理,直接输入原始数据即可得到输出结果,因此得到了广泛的应用^[17]。本研究构建的卷积神经网络模型主要在 AlexNet 网络的基础上进行改进,替换了其中两层卷积层为 Inception 模块,并调整了卷积核大小,以减少模型的参数量。具体的 CNN 网络结构详见表1。

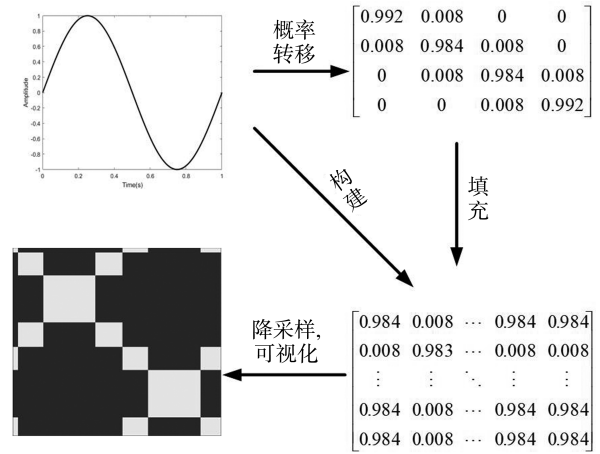


图1 MTF 二维编码图过程

Fig.1 MTF 2D encoding graph process

表1 卷积神经网络参数

Tab.1 Parameters of convolutional neural networks

序号	层类型	激活函数	输出
1	卷积层	ReLU	[36,218,218]
2	InceptionA	ReLU	[88,218,218]
3	最大池化		[88,108,108]
4	卷积层	ReLU	[256,54,54]
5	InceptionB	ReLU	[384,54,54]
6	最大池化		[384,26,26]
7	卷积层	ReLU	[256,12,12]
8	最大池化	ReLU	[256,6,6]
9	全连接	ReLU	[256,1]
10	全连接		[12,1]

Inception 模块通过在不同尺寸上并行进行卷积操作提取特征,并将所有输出结果拼接为一个深层特征图,利用不同大小的卷积核并行提取特征,丰富了特征的表达方式,增加了网络的宽度和对尺度的适应性。模块的基本结构如图2所示。

模型将通过 VMD-MTF 变换的电流信号图作为输入,首先由第一层卷积层提取输入图像的浅层空间局部特征;再经过池化层对特征图进行下采样,去除部分冗余信息,完成第一阶段的特征学习;然后借助 Inception 模块从特征图中学习到更深层次的空间故障特征;最后将学习到的特征图展平为一维向量并送入 Softmax 中,输出诊断结果。

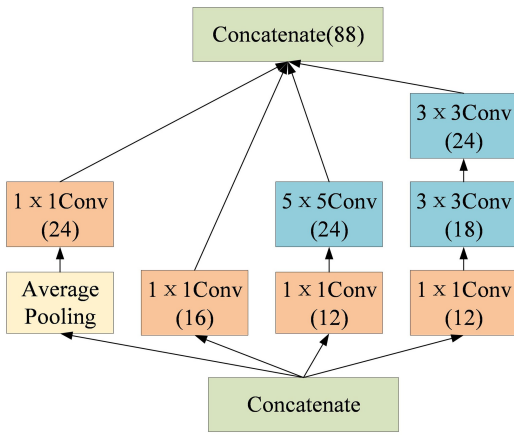


图 2 Inception 模块
Fig.2 Inception module

2 数据处理和分析

2.1 变分模态参数设定

VMD 分解的效果主要受分解模态数取值的影响。选择的分解层数过大可能导致过度分解, 过小可能导致欠分解。为了找到适合多种负载的最佳分解层数, 本研究采用中心频率法, 以开关电源和烧水壶变分模态分解的中心频率为例, 如表 2 所示。当分解层数过多时, 开关电源中 $K=5$ 和 $K=6$ 的中心频率相近, 存在过分解; 而当分解层数不足时, 烧水壶在 $K=4$ 时无法将高频分量解析出来, 存在欠分解的情况。综上, 根据中心频率法, 选取分解层数 $K=5$ 。

2.2 特征信号重构

利用自行研制的电弧故障实验平台进行实验采样频率为 100 kHz, 实验负载分别为纯电阻、调光灯、荧光灯、开关电源、卤素灯带阻性负载、吸尘器, 如图 3 所示。




图 3 故障电弧实验电路示意图

Fig.3 Schematic diagram of faulty arc experimental circuit

表 2 负载的变分模态分解中心频率表
Tab.2 Variational mode decomposition center frequency table of loads

负载	分量	中心频率/Hz			
		分解 4 层	分解 5 层	分解 6 层	分解 7 层
开关电源	IMF1	6 682	6 775	6 681	7 762
	IMF2	3 487	3 598	3 700	4 780
	IMF3	1 428	1 554	1 836	3 372
	IMF4	137	387	1 289	1 755
	IMF5	—	97	360	1 206
	IMF6	—	—	94	352
	IMF7	—	—	—	93
烧水壶	IMF1	12 041	23 533	28 975	29 047
	IMF2	3 773	8 212	11 522	11 990
	IMF3	674	3 003	5 545	6 953
	IMF4	57	440	2 184	3 292
	IMF5	—	55	440	1 265
	IMF6	—	—	55	357
	IMF7	—	—	—	54

以开关电源负载故障电流样本为例, 线路电流波形进行 VMD 分解, 分别计算各 IMF 的相关系数和能量比, 结果如表 3 所示。

表 3 各 IMF 分量相关系数—能量比

Tab.3 Correlation coefficient of each IMF component-energy ratio

IMF 序号	相关系数	能量比/%
IMF1	0.045 0	0.000 8
IMF2	0.089 8	0.003 6
IMF3	0.164 2	0.010 2
IMF4	0.505 1	0.071 0
IMF5	0.960 3	0.914 5

由表 3 可见, IMF4、IMF5 符合本研究提出的波形重构标准, 即相关系数大于 0.5 和能量比大于 5%, 因此, 选择这两个分量进行信号重构, 重构前后的波形如图 4 所示。由图 4 可见, 剔除一些中高频分量后, 重构的信号中故障信号的特征更加突出, 表明对信号进行重构能够减少干扰。

采用相同的方法对不同负载实验线路的负载电流波形进行重构,结果如图 5 所示。




图 4 信号重构前后的时域波形图

Fig.4 Time domain waveform plots before and after signal reconstruction

由图 5 可见,纯电阻负载的正常电流呈现为正弦波形,故障时具有明显的零区。荧光灯负载和卤素灯带阻性负载的正常电流波形表现出周期性的平肩现象,伴随着噪声;当发生故障时,平肩现象加剧,零休期延长,并伴随大量瞬态突变,噪声含量增加。调光灯负载的正常电流波形具有明显的平肩,而故障时在过零点处和峰值时有明显的尖波。上述负载在正常和故障电弧的波形呈现明显差异,但一些非线性负载的正常和故障电弧时的波形比较相似,容易混淆。经过 VMD 处理重构后的信号,开关电源保留了峰值时的畸变并放大了平肩处的冲击分量;而真空吸尘器则平滑了正常波形在平肩处的噪声毛刺,保留了故障时平肩处的噪声毛刺,使得这两种负载在正常和故障状态之间产生了明显的区别。

2.3 MTF 二维图像编码

将重构后的信号归一化处理,再用 MTF 变换生成二维图像。原始电流信号的二维编码图如图 6 所示。可见当发生电弧故障时,电流发生畸变并产生大量噪声,相应的二维编码图上出现不同密集程度的竖纹。纯电阻正常运行电流为正弦波,发生故障时电流产生零区和噪声,反映在图像上就是灰色方块变小并带有少量竖纹。荧光灯和卤素灯带阻性负载正常运行电流类似正弦波,但

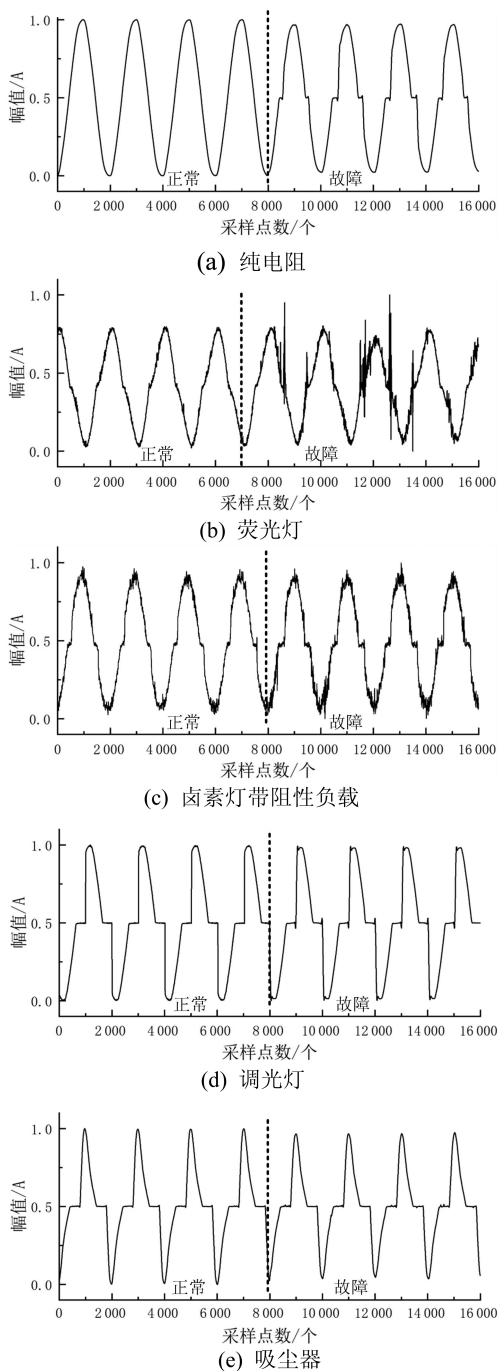


图 5 不同负载电流波形图

Fig.5 Waveforms of different load currents

是伴有噪声,显示在图像上就是密集的竖纹,当发生故障时电流发生严重的畸变和大量的噪声,使得故障图像产生大量密集的竖纹。调光灯正常波形图像为四周方格带竖纹,发生故障时呈现大量密集条纹。以上 4 种负载在电流正常和故障时都有明显的区别。但是,开关电源和吸尘器这类非线性负载正常运行时的波形与故障电弧发生时的波形非常相似,经过 MTF 编码后的图像也比较相

似。开关电源和吸尘器电流正常和故障时都有大量密集不规则的竖纹,导致卷积神经网络在识别

这类负载时故障识别率较低。

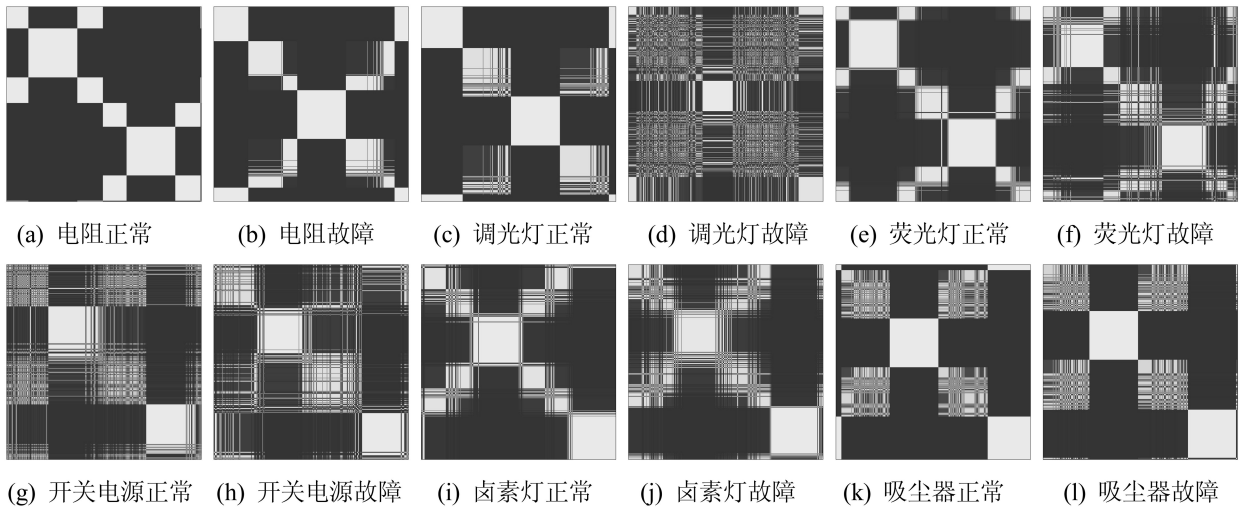


图 6 MTF 二维图像编码

Fig.6 2D image coding of MTF

为了改善上述情况,本研究提出联合 VMD-MTF 的故障特征提取方法,图 7 为经由波形重构后再进行二维编码图。经过 VMD 重构后的信号更加突显了故障时波形的奇异特性,与正常电流的二维图像有了明显的区别。开关电源电流正常

状态最明显的是边缘围绕不规则的矩形,故障状态为带横纹的方形块;吸尘器电流正常状态边缘方块的竖纹比较稀疏,而故障状态边缘方块的竖纹比较密集。

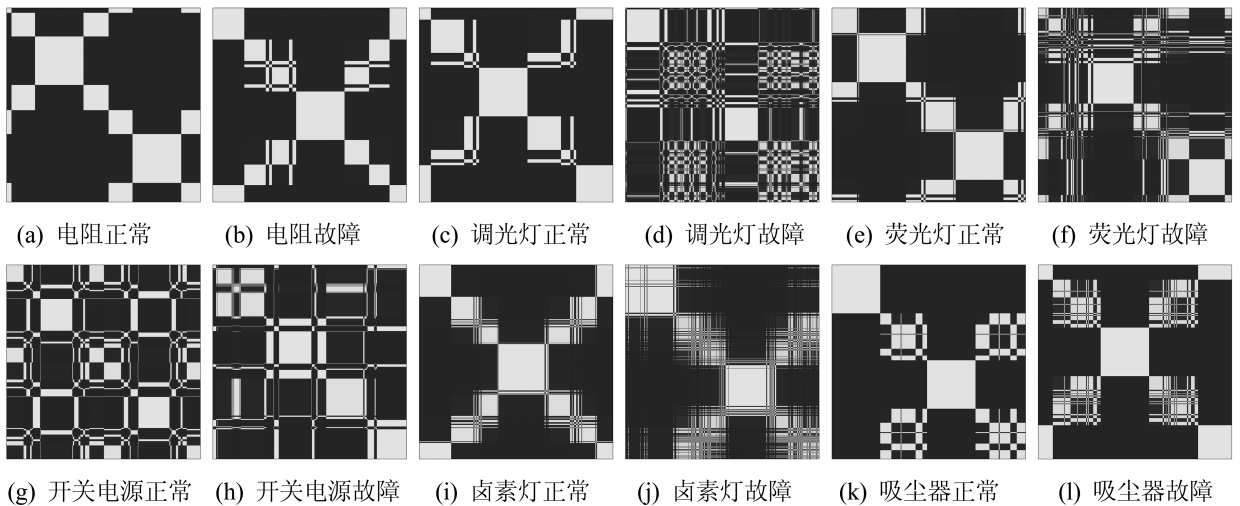


图 7 VMD-MTF 二维图像编码

Fig.7 2D image coding of VMD-MTF

3 结果和分析

3.1 数据集和实验验证

以一个周期为样本,对不同运行状态的负载电流信号进行截取,每份样本包含 2 000 个采样点,使用 VMD-MTF 将电流信号进行二维编码生

成数据集。数据集共有 7 200 个样本,训练集有 4 800 个样本,测试集有 1 200 个样本,验证集有 1 200 个样本。

为了验证 VMD-MTF-CNN 的性能,采用 MTF 对电流信号进行二维图像编码,生成相同的数据集,输到所搭建的 CNN 模型中测试,记录训练过

程中验证集的准确率和损失变化,实验结果如图 8 所示。由 VMD-MTF 处理故障电弧的数据集训练的正确率约为 99%,而由 MTF 处理的数据集的正确率约为 95%。该结果表明,相较于 MTF 方法,VMD-MTF 方法准确率更高。

为了进一步评价模型的性能,绘制了测试集的混淆矩阵以便可视化地评估模型的性能,各负载标签如表 4 所示,测试集混淆矩阵如图 9 所示。

由图 9 可见,MTF-CNN 方法对非线性负载的识别准确率比较低,在开关电源的预测中,容易将正常样本错误地预测为故障状态;而在吸尘器负载的预测中,则容易将故障样本错误地预测为正常状态。而 VMD-MTF 在处理数据时很好地改进

了该问题,提高了故障识别的准确率,在负载分类的识别率上达到了 99.33%。




图 8 不同数据集训练对比图

Fig.8 Training comparison chart of different datasets

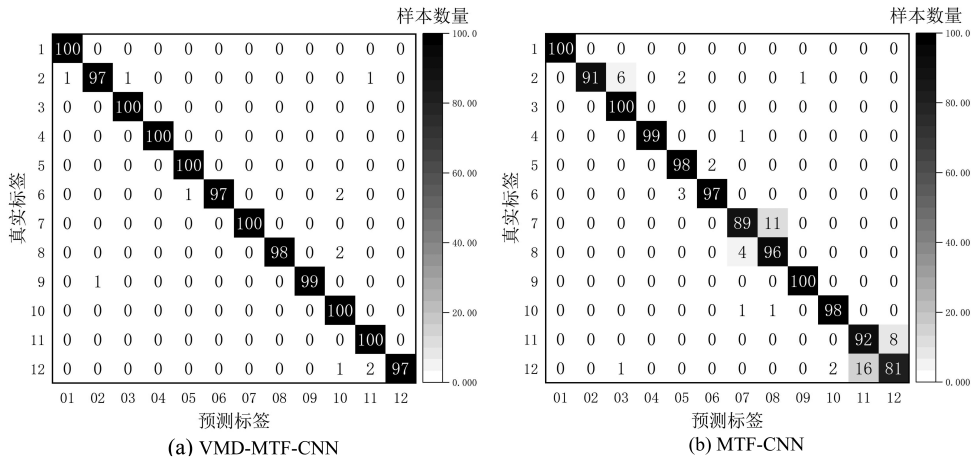


图 9 测试集混淆矩阵

Fig.9 Confusion matrix of test set

表 4 各负载标签

Tab.4 Labels for each load

负载状态	纯电阻 标签	调光灯 标签	荧光灯 标签	开关电 源标签	卤素灯 标签	吸尘器 标签
正常	01	03	05	07	09	11
故障	02	04	06	08	10	12

和 AlexNet 高,各项指标中的表现也是最佳的。

表 5 不同方法的故障电弧诊断结果

Tab.5 Fault arc diagnosis results of different methods

方法	模型名称	准确率/%	精确率/%	召回率/%	F1 值	模型大小/MB
VMD-MTF	CNN	99.00	99.03	99.00	0.99	15.5
	AlexNet	98.25	98.26	98.25	0.98	55.7
	LeNet	98.25	98.29	98.25	0.98	20.6
	ZFNet	97.42	97.51	97.42	0.97	15.2
MTF	CNN	95.08	95.20	95.08	0.95	15.5
	AlexNet	92.33	93.12	92.33	0.92	55.7
	LeNet	92.25	92.54	92.55	0.92	20.6
	ZFNet	90.33	90.82	90.33	0.90	15.2

3.2 模型对比

利用相同数据集进行训练和测试,得到了不同神经网络模型在 VMD-MTF 数据集上的测试结果如表 5 所示,VMD-MTF 数据集上的 4 种网络模型训练效果更好。

另外,与其他模型在参数数量相近的情况下对比,所设计的模型准确率优于 ZFNet;而在参数数量较少的情况下,所设计的模型准确率也比 LeNet

最后,将经过训练的模型部署到本地电脑上,并通过可进行网页访问的移动通讯设备如手机等,使用 Web 服务调用模型进行故障识别,识别时间在 0.06~0.24 s。

4 结论

针对故障电弧信号微弱、故障特征不明显导致故障而难以被检测等问题,本研究提出了一种基于 VMD-MTF-CNN 的电弧故障诊断方

法,将一维数据波形进行分解重构凸显故障奇异特征,再进行二维编码,从而构建故障特征库,并最终构建了基于 CNN 的故障诊断模型。研究表明,该方法能够有效地改善非线性负载电流波形正常与故障时波形相似时成识别率低的问题。故障诊断模型在不同负载情况下的故障诊断准确率平均在 99% 以上,能够有效地识别负载类型和工作状态。

参考文献:

- [1] YANG J H, FANG H Y, ZHANG R C, et al. An arc fault diagnosis algorithm using multiinformation fusion and support vector machines[J]. Royal Society Open Science, 2018, 5(9): 180160.
- [2] 余琼芳, 路文浩, 杨艺. 基于深度长短时记忆网络的多支路串联故障电弧检测方法[J]. 计算机应用, 2021, 41(S1): 321-326.
- [3] 张士文, 张峰, 王子骏, 等. 一种基于小波变换能量与神经网络结合的串联型故障电弧辨识方法[J]. 电工技术学报, 2014, 29(6): 290-295, 302.
- [4] 余琼芳, 胡亚倩, 杨艺. 低压交流串联故障电弧检测概述[J]. 电器与能效管理技术, 2020(1): 24-30.
- [5] DANG H L, KIM J, KWAK S, et al. Series DC arc fault detection using machine learning algorithms[J]. IEEE Access, 2021, 9: 133346-133364.
- [6] 刘树鑫, 刘学识, 李静, 等. 基于 SSA-ELM 的直流串联故障电弧检测方法研究[J]. 电器与能效管理技术, 2022(10): 65-73.
- [7] 金翠, 刘洋, 李琦, 等. 基于 CatBoost 的常用电器负载电弧故障识别方法[J]. 电测与仪表, 2023, 60(7): 193-200.
- [8] 宿磊, 沈煜, 杨帆, 等. 融合 CEEMDAN 分解与敏感 IMF 精选的串联电弧故障检测[J]. 电子测量与仪器学报, 2022, 36(10): 173-180.
- [9] 杨帆, 宿磊, 杨志淳, 等. 基于改进 CEEMDAN 分解与时空特征的低压供电线路串联故障电弧检测[J]. 电力系统保护与控制, 2022, 50(12): 72-81.
- [10] TIAN J H, HAN D Y, LI M D, et al. A multi-source information transfer learning method with subdomain adaptation for cross-domain fault diagnosis[J]. Knowledge-Based Systems, 2022, 243: 108466.
- [11] 王同, 许昕, 潘宏侠. 基于多域信息融合与深度分离卷积的轴承故障诊断网络模型[J]. 机电工程, 2024, 41(1): 22-32.
- [12] 余琼芳, 黄高路, 杨艺, 等. 基于 AlexNet 深度学习网络的串联故障电弧检测方法[J]. 电子测量与仪器学报, 2019, 33(3): 145-152.
- [13] 余琼芳, 胡亚倩, 杨艺. 基于小波特征及深度学习的故障电弧检测[J]. 电子测量与仪器学报, 2020, 34(3): 100-108.
- [14] 李斌, 杨亦航. 基于改进的 AlexNet 模型的家用负载电弧检测[J]. 传感技术学报, 2023, 36(12): 1928-1934
- [15] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [16] WANG Z, Oates T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks[C]//Twenty-Ninth AAAI Conference on Artificial Intelligence. Austin: AIII, 2015: 1-7.
- [17] 黄新波, 胡潇文, 朱永灿, 等. 基于卷积神经网络算法的高压断路器故障诊断[J]. 电力自动化设备, 2018, 38(5): 136-140, 147.

(责任编辑: 方素华)