

# 基于时频谱图和自适应动态权重 PSO-CNN 的外破振动信号识别<sup>\*</sup>

崔岩 方春华 文中 方萌 游海鑫 郭俊康  
(三峡大学电气与新能源学院 宜昌 443000)

**摘要:**为避免地下电缆遭受破坏,提高振动监测系统对外力破坏的预警能力,提出一种基于时频谱图和自适应动态权重粒子群算法-卷积神经网络(PSO-CNN)的外破振动信号识别方法。首先,将振动传感系统获取的3 000组外破振动信号转化生成时频谱图数据集,在图像预处理阶段,采用直方图均衡化和二维主成分分析(2D-PCA)算法来增强灰度图像特征并实现图像数据的降维;然后,将图像数据集的70%作为CNN模型的训练集,并在网络训练过程中引入自适应动态惯性权重 PSO对CNN模型的卷积层、池化层相关参数进行迭代寻优,从而获得优化 PSO-CNN 分类模型;最后,利用测试集图像数据对优化 PSO-CNN 模型的识别性能进行验证,并与其他分类模型进行了对比。结果表明,所提方法对6种常见外破振动信号的识别准确率达到98.33%,平均每张图像的识别时间仅为0.24 s,与其他分类算法相比具有更高的分类精度和更快速的识别速度,为快速准确地识别外力破坏事件类型提供了一种可行方案。

**关键词:**时频谱图;2D-PCA降维;惯性权重;卷积神经网络;粒子群优化算法  
**中图分类号:** TM757 **文献标识码:** A **国家标准学科分类代码:** 510

## Vibration signal identification of external force failure based on time-frequency spectrum and adaptive dynamic weight PSO-CNN algorithm

Cui Yan Fang Chunhua Wen Zhong Fang Meng You Haixin Guo Junkang  
(College of Electricity and New Energy, China Three Gorges University, Yichang 443000, China)

**Abstract:** In order to avoid the damage of underground cables and improve the early warning ability of the vibration monitoring system against external force damage, an identification method of external damage vibration signal based on time-frequency spectrum and adaptive dynamic inertia weight PSO-CNN is proposed. Firstly, 3 000 groups of external vibration signals obtained by the vibration sensing system are converted into time-frequency spectrum data sets. In the image preprocessing stage, histogram equalization and 2D-PCA algorithm are used to enhance the characteristics of gray image and reduce the dimensions of image data; Then, 70% of the image dataset is taken as the training set of the CNN model, and the adaptive dynamic inertia weight PSO algorithm is introduced in the network training process to iteratively optimize the relevant parameters of the convolution layer and pooling layer of the CNN model, so as to obtain the optimized PSO-CNN classification model; Finally, the recognition performance of the optimized PSO-CNN model is verified by using test set image data, and which is compared with other classification models. The results show that the recognition accuracy of the proposed method for six common external damage vibration signals reaches 98.33%, and the average recognition time of each image is only 0.24 s. Compared with other classification algorithms, the proposed method has higher classification accuracy and faster recognition speed, which provides a feasible scheme for quickly and accurately identifying the types of external damage events.

**Keywords:** time-frequency spectrum; 2D-PCA dimension reduction; inertia weight; convolutional neural network; particle swarm optimization algorithm

收稿日期:2022-09-26

<sup>\*</sup> 基金项目:国家自然科学基金(51477090)项目资助

## 0 引言

地下电缆作为电力系统的重要组成部分,在城市输配电网络中得到了广泛运用<sup>[1]</sup>。但直埋敷设的电缆经常遭受地面无组织施工造成的损伤,导致电缆主绝缘性能劣化,严重时甚至造成电缆本体断裂,严重影响电力系统的正常运行<sup>[2]</sup>。因此,实时监测电缆周边振动情况,及时对电缆周边潜在威胁进行预警,对于保证地下电缆的安全运行具有重要意义。

国内外学者在振动信号识别领域做了大量研究,以深度学习和机器学习为代表的智能算法已在振动信号识别、图像理解等方面取得了突破性进展<sup>[3-5]</sup>。振动信号类型识别主要分为特征提取和分类器识别两部分。目前常用的特征提取方法主要有时域特征提取、频域特征提取和时频分析<sup>[6]</sup>。时域、频域特征提取方法原理简单、容易实现,但是需要针对不同类型的振动信号寻找代表特征值,依赖于先验知识,并且对噪声不具有鲁棒性<sup>[7]</sup>。而时频分析方法可以将振动信号从一维扩展到时间-频率域二维平面,能够展示时域和频域的联合分布信息,是目前应用最广泛、效果最好的特征提取方法。常用的时频分析方法包括短时傅里叶变换<sup>[8]</sup>、希尔伯特-黄变换<sup>[9]</sup>、经验模态分解<sup>[10]</sup>、小波变换<sup>[11]</sup>等。而时频谱图则是利用短时傅里叶变换将振动信号进行转化生成的一种可视化三维图像,可以完整描述信号在时域及频域上的能量分布,被广泛运用在信号识别领域<sup>[12]</sup>。

利用深度学习方法进行图像识别不需依赖人工特征工程,能够降低硬件成本,实现图像的快速、自动识别<sup>[13-14]</sup>。但是原始数据常常存在大量冗余或无用特征,导致训练时间过长,识别效率较低,出现所谓的“维数灾难”现象<sup>[15]</sup>。因此,一些学者针对特征降维问题开展了相关研究。Zhong等<sup>[16]</sup>提出一种基于主成分分析(principal component analysis, PCA)与自组织神经网络(self-organizing map, SOM)相结合的识别方法,通过在SOM前插入PCA层对手势图像进行特征降维,显著提高了识别速度,且识别准确率稳定在90%以上。谭敏生等<sup>[17]</sup>利用随机森林算法对图像独热编码后的数据进行特征度量,保留了主要特征信息,在不降低识别准确率的前提下实现了数据的最优压缩。此外,文献[18-19]提出了如基于二维主成分分析(two dimensional principal component analysis, 2D-PCA)和双向二维主成分分析等降维方法,相比于一维特征值降维方法,改进后的2D-PCA算法对图像的降维效果更好,提升速度的效果更加明显。

卷积神经网络(convolutional neural network, CNN)是深度学习中有代表性的算法模型,不需要特意设置分类器,具有很强的泛化能力<sup>[20-22]</sup>。但是,CNN网络结构及初始参数的不同选择在很大程度上影响模型的识别性能<sup>[23]</sup>。为此,文献[24-25]提出了利用粒子群算法(particle swarm optimization, PSO)优化CNN网络模型

的方法,通过设置PSO的种群数量、惯性权重和学习因子等参数,使卷积神经网络能够在非经验指导下自主选择最佳网络结构参数和初始权重,获得最优CNN分类模型。其中,惯性权重是影响粒子进化速度和寻优能力的重要参数之一。若PSO采用较小的惯性权重,可能导致粒子在迭代初期空间搜索能力不足,出现早熟收敛、陷入局部最优等情况;而较大的惯性权重则会减弱粒子的局部搜索性能,导致粒子进化停滞不前。针对上述缺点,Shi等<sup>[26]</sup>提出一种基于时变线性动态递减惯性权重调节策略以平衡粒子的局部搜索性能和收敛速度;全秋娟等<sup>[27]</sup>、马龙等<sup>[28]</sup>也分别提出了指数型惯性权重调节策略和余弦型惯性权重调节策略。以上方法虽然在一定程度上提高了普通PSO的寻优性能,但并未考虑到粒子进化过程中适应度函数值变化与惯性权重之间的联系。因此,本文提出一种自适应动态惯性权重调节策略,即随着迭代次数和适应度函数值的变化动态调节惯性权重大小,能够有效提高PSO算法的全局搜索能力和局部开发性能,从而获得最优CNN网络模型参数。

综上,本文提出基于振动信号时频谱图和自适应动态权重PSO-CNN的振动源识别方法。首先,将振动传感系统获取的异常振动信号转化生成时频谱图,并将所得灰度图像进行图像增强和2D-PCA降维处理;然后,利用自适应动态惯性权重PSO对浅层LeNet-5卷积神经网络模型进行优化,获得最优分类模型参数;最后,利用图像测试集数据对优化PSO-CNN模型的识别性能进行了检验,并与其他几种优化模型进行了对比。实验结果验证了本文所提算法的可行性和优越性,为快速准确地识别外力破坏事件类型提供了一种可行方案。

## 1 时频谱图及预处理

## 1.1 时频谱图

时频谱图是信号短时频谱的时间-能量表示,是振动信号的一种三维可视化表示。时频谱图的横轴为时间,纵轴为频率值,各坐标点对应时间频率成分的能量变化会呈现出不同的纹理特征。时频谱图的获取分为分帧、加窗和短时傅里叶变换3步。信号的分帧是利用可移动窗口进行加权的方式来实现,即利用窗函数 $\omega(n)$ 与振动信号 $s(n)$ 相乘,从而得到加窗信号 $x(n)$ 为:

$$x(n) = s(n)\omega(n) \quad (1)$$

常见的窗函数有矩形窗和汉明窗,矩形窗与汉明窗的参数对比如表1所示。

表1 矩形窗和汉明窗参数对比

窗类型	主瓣宽度	旁瓣峰值	最小阻带衰减
矩形窗	$4\pi/N$	-13	-21
汉明窗	$8\pi/N$	-41	-53

汉明窗的主瓣宽度较宽,旁瓣值也相对较小,其低通

特性更加平滑,可以较好地反映出短时信号的频率特性。汉明窗定义式如下:

$$\omega(n) = \begin{cases} 0.5 \left(1 - \cos \frac{2n\pi}{N-1}\right), & 0 \leq n \leq N-1 \\ 0, & n < 0 \text{ 或 } n > N \end{cases} \quad (2)$$

对信号进行分帧处理后,对第  $n$  帧信号  $x_n(m)$  进行短时离散傅里叶变换,计算表达式如下:

$$X_n(e^{j\omega}) = \sum_{m=-\infty}^{\infty} x_n(m) \cdot \omega(n-m) e^{-j\omega m} \quad (3)$$

令  $\omega = 2\pi k/N$ , ( $0 \leq k \leq N-1$ ), 则信号的短时傅里叶变换可表示为:

$$X_n\left(e^{j\frac{2\pi k}{N}}\right) = X_n(k) = \sum_{m=0}^{N-1} x_n(m) \omega(n-m) e^{-j\frac{2\pi k}{N} m} \quad (4)$$

式中:  $x_n(m)$  表示第  $n$  帧信号的第  $m$  个样本点;  $N$  表示帧长。

由能量密度谱函数定义可知,短时能量密度和短时傅里叶变换存在如下关系:

$$S_n(e^{j\omega}) = X_n(e^{j\omega}) \cdot X_n(e^{j\omega})^* = |X_n(e^{j\omega})|^2 \quad (5)$$

式(5)可进一步表示为:

$$S_n(e^{j\omega}) = \sum_{k=-\infty}^{\infty} R_n(k) e^{j\omega k} \quad (6)$$

其中,  $R_n(k) = \sum_{m=-\infty}^{\infty} x_n(m) \cdot \omega(n-m) \cdot x_n(m+k) \cdot \omega(n-m-k)$

将时间序列  $n$  作为横坐标,频率  $\omega$  作为纵坐标,  $S_n(e^{j\omega})$  的值作为点  $(x, \omega)$  的能量幅值,得到的二维图像(实际为三维图像)即时频谱图。

## 1.2 直方图均衡图像增强

在图像识别中,通常将 RGB 时频谱图进行灰度化处理以减少图像数据量,提高后续算法速度。然而,灰度图像难以体现 RGB 图像的色彩对比度,缺乏层次感。为此,引入直方图均衡化进行图像特征增强,该方法可将图像灰度直方图中像素点不均匀部分转化为像素点在全部灰度范围内的均匀分布,使图像的灰度动态范围进一步扩大,从而改善图像的亮度分布状态,增强图像的视觉效果。具体处理过程如下。

1) 根据时频谱图图像的灰度值计算灰度概率密度函数  $P(h_k)$  :

$$P(h_k) = N_k/N \quad k = 0, 1, \dots, L-1 \quad (7)$$

式中:  $N_k$  表示灰度图中第  $k$  个灰度级出现的次数;  $N$  为图像的像素总数;  $L$  表示灰度级总数。

2) 由  $P(h_k)$  计算累积分布函数  $S_k$ , 并将  $S_k$  归算到  $[0, 255]$ , 表达式为:

$$S_k = 255P(h_j) = 255 \sum_{j=0}^k P(h_j) \quad k = 0, 1, \dots, L-1 \quad (8)$$

图 1(a) 所示为振动信号的 RGB 时频谱图,图像尺寸

为  $256 \times 256 \times 3$ , 其灰度图像如图 1(b) 所示, 图像尺寸为  $256 \times 256 \times 1$ 。可以看到, 灰度图中振动能量最强与最弱部分均为暗色, 无法反映原 RGB 图像中的能量分布特征。为此, 利用直方图均衡化对灰度图进行特征增强, 增强后的图像如图 1(c) 所示。可以发现, 图像增强后的时频谱图能量强弱区分非常显著, 能够准确反映实际时频谱图的能量分布特征。

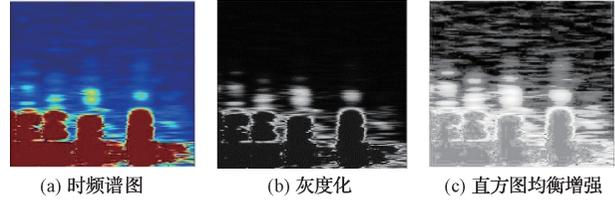


图 1 图像处理过程

## 1.3 2D-PCA 降维

若采用  $256 \times 256$  的时频谱图作为 CNN 的训练数据, 可能会由于特征信息冗余而导致训练时间较长, 识别效率下降。本文采用的 2D-PCA 降维算法可以根据原始图像数据直接构建协方差矩阵实现图像重构, 在保留图像纹理特征的同时有效降低计算复杂度。

对于二维图像矩阵  $\mathbf{A} \in \mathbf{R}^{m \times n}$ , 为获得其投影特征向量  $\mathbf{Y} \in \mathbf{R}^{m \times n}$ , 需要寻找最佳投影空间  $\mathbf{X}$ , 使得  $\mathbf{A}, \mathbf{Y}, \mathbf{X}$  满足式(9)。

$$\mathbf{Y} = \mathbf{A}\mathbf{X} \quad (9)$$

变换矩阵  $\mathbf{X}$  可利用投影样本的总体散布矩阵  $\mathbf{J}(\mathbf{X})$  求解:

$$\mathbf{J}(\mathbf{X}) = \text{tr}(\mathbf{S}_\mathbf{X}) \quad (10)$$

$$\mathbf{S}_\mathbf{X} = \mathbf{E}(\mathbf{Y} - \mathbf{E}\mathbf{Y})(\mathbf{Y} - \mathbf{E}\mathbf{Y})^T \quad (11)$$

$$\text{tr}(\mathbf{S}_\mathbf{X}) = \mathbf{X}^T \mathbf{E}[(\mathbf{A} - \mathbf{E}\mathbf{A})^T (\mathbf{A} - \mathbf{E}\mathbf{A})] \mathbf{X} \quad (12)$$

式中:  $\mathbf{S}_\mathbf{X}$  是  $\mathbf{Y}$  的协方差矩阵;  $\text{tr}(\mathbf{S}_\mathbf{X})$  是  $\mathbf{S}_\mathbf{X}$  的迹。

则图像的协方差矩阵  $\mathbf{G}_t$  可表示为:

$$\mathbf{G}_t = \mathbf{E}[(\mathbf{A} - \mathbf{E}\mathbf{A})^T (\mathbf{A} - \mathbf{E}\mathbf{A})] \quad (13)$$

根据  $\mathbf{S}_\mathbf{X}$  和  $\mathbf{G}_t$  可得总体散布函数  $J(\mathbf{X})$  :

$$J(\mathbf{X}) = \mathbf{X}^T \mathbf{E}\{(\mathbf{X} - \mathbf{E}(\mathbf{X}))^T (\mathbf{X} - \mathbf{E}(\mathbf{X}))\} \quad (14)$$

最佳投影空间  $\mathbf{X}$  即为  $J(\mathbf{X})$  最大化时对应的投影空间。

对于一个包含  $N$  个不同类型振动信号时频谱图的样本集合  $\{\mathbf{A}_i\}_1^N$ , 图像大小为  $m \times n$ , 首先求得  $\mathbf{G}_t$  的特征值, 将其中最大的  $d$  个特征值对应的正交特征向量组成投影矩阵  $\mathbf{X}$ , 则图像  $\mathbf{A}_i$  通过式(9)可得到, 一组投影特征向量  $\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_d$ , 也即图像  $\mathbf{A}_i$  的特征图像矩阵  $\mathbf{B}_i = \{\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_d\}$ 。通过 2D-PCA 降维得到的特征图像集  $\{\mathbf{B}_i\}_1^N$  即可作为 CNN 网络训练数据。

## 2 基于自适应权重 PSO-CNN 基本原理

### 2.1 CNN 神经网络基本理论

CNN 在图像处理方面具有强大优势, CNN 的稀疏交

互、参数共享等特性可有效降低训练参数量,易于网络结构的训练和优化,并且具有强鲁棒性和强容错能力。

CNN模型一般包括输入层、卷积层、池化层、全连接层和输出层;输入层用于接收图像并将图像数据进行规范化处理;卷积层C用于图像特征提取,通过设置卷积核的大小和移动步长,用卷积核中参数与二维数组对应位置元素进行卷积计算并在相应位置输出以实现特征提取;池化层V通常置于卷积层之后,用于对卷积层获得的特征值进行聚合,以降低特征映射的分辨率、减少数据处理量、加快网络训练速度;全连接层中每个节点都与上一层中所有节点相连,可将前一层提取的特征整合为一维向量,最后将生成的一维特征向量作为Softmax分类器的输入,得到的输出值即为最终的图像类型标签。

在振动信号识别任务中,所用数据规模较小,训练深层网络可能导致训练样本的过拟合,使得训练时间过长,实时性变差。因此,本文采用双卷积层LeNet-5卷积神经网络模型进行特征提取,全连接层后使用Softmax分类器进行图像识别。网络结构如图2所示。

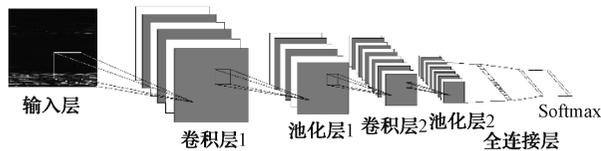


图2 CNN神经网络结构

## 2.2 基于自适应权重的PSO算法

PSO是Eberhart和Kennedy开发的一种优化算法,其主要思想为随机初始化大小为 $N$ 、维数为 $D$ 的粒子群,通过粒子之间的相互协作和信息共享来更新每个粒子的特征属性,最终获得全局最优解。PSO中第 $i$  ( $i=1,2,\dots,N$ )个粒子的位置为 $x_i=(x_{i,1},x_{i,2},\dots,x_{i,N})$ ,粒子速度为 $v_i=(v_{i,1},v_{i,2},\dots,v_{i,N})$ ,粒子通过其个体最优( $pbest$ )和全局最优( $gbest$ )两个过程进行位置更新,当达到迭代停止条件时输出全局最优解。粒子的更新过程如式(15)、(16)所示。

$$x_{i,d}^{k+1} = x_{i,d}^k + v_{i,d}^{k+1} \quad (15)$$

式中: $x_{i,d}^k$ 表示第 $i$ 个粒子在第 $k$ 代、第 $d$ 维度上的位置; $v_{i,d}^k$ 表示第 $i$ 个粒子在第 $k$ 代、第 $d$ 维度上的速度。

$$v_{i,d}^{k+1} = \omega v_{i,d}^k + c_1 r_1 (pbest_{i,d}^k - x_{i,d}^k) + c_2 r_2 (gbest_{i,d}^k - x_{i,d}^k) \quad (16)$$

式中: $\omega$ 为惯性权重; $c_1$ 和 $c_2$ 用于控制 $pbest$ 和 $gbest$ 之间的权衡; $r_1$ 和 $r_2$ 为 $0.1\sim 0.9$ 的随机数; $pbest_{i,d}^k$ 表示第 $i$ 个粒子在第 $k$ 代、第 $d$ 维度上的当前最优解; $gbest_{i,d}^k$ 表示第 $i$ 个粒子在第 $k$ 代、第 $d$ 维度上的全局最优解。

上述过程为普通粒子群算法,其中的惯性权重 $\omega$ 主要用来协调局部最优和全局最优之间的平衡, $\omega$ 较大时,粒子的移动步长和搜索范围较大,适合迭代初期快速寻找最优解;而当 $\omega$ 较小时,粒子的搜索范围变小,局部搜

索能力提高,适合迭代后期的精细局部搜索。普通粒子群算法中惯性权重 $\omega$ 为定值,容易出现早熟收敛、陷入局部最优等情况。因此,本文在PSO迭代过程中采用一种非线性自适应动态惯性权重选择方式,即随着当前粒子的适应度函数值对惯性权重 $\omega$ 进行动态更新,更新方式如下:

$$\omega = \begin{cases} \omega_{\max}, & f > f_{avg} \\ \omega_{\min} - (\omega_{\max} - \omega_{\min}) \frac{(f - f_{\min})}{f_{avg} - f_{\min}}, & f \leq f_{avg} \end{cases} \quad (17)$$

式中: $\omega_{\max}$ 、 $\omega_{\min}$ 为惯性权重的最大值和最小值,实际优化计算中常取 $\omega_{\max}=0.9$ 、 $\omega_{\min}=0.4$ ;  $f$ 为当前粒子的适应度函数值; $f_{avg}$ 为当前所有粒子的平均适应度值; $f_{\min}$ 为当前所有粒子的最小适应度值。

## 2.3 自适应动态惯性权重PSO优化的卷积神经网络

结合2.1节不同参数对CNN识别性能的影响分析,本文将卷积核数量、大小、步长,池化核大小、步长作为待优化参数,参数范围如表2所示,PSO种群数量为10,各粒子参数定义如表3所示。

表2 待优化参数及参数范围

层	待优化参数	取值范围
卷积层C	卷积核数量	10~50
	卷积核大小	2~6
	步长	2~6
池化层V	池化核大小	2~6
	池化核步长	1~4

表3 粒子参数定义

粒子参数	待优化参数
$a_1$	$C_1$ 中卷积核数目
$a_2$	$C_1$ 中卷积核大小
$a_3$	$C_1$ 中卷积核步长
$a_4$	$V_1$ 中池化核大小
$a_5$	$V_1$ 中池化核步长
$a_6$	$C_2$ 中卷积核数目
$a_7$	$C_2$ 中卷积核大小
$a_8$	$C_2$ 中卷积核步长
$a_9$	$V_2$ 中池化核大小
$a_{10}$	$V_2$ 中池化核步长

利用自适应动态惯性权重PSO对卷积神经网络进行优化的步骤如下:

步骤1)对图像数据集进行预处理,选取训练集作为CNN网络的输入;

步骤2)初始化粒子群速度和位置,令迭代次数 $q=0$ ;

步骤3)根据式(15)、(16)更新粒子的速度和位置 $v_{i,d}^k$ 、 $x_{i,d}^k$ ;

步骤4)将 CNN 网络训练数据得到的测试误差值作为适应度函数值  $f$ ;

步骤5)更新个体最优解  $pbest_{i,d}^k$  和全局最优解  $gbest_{i,d}^k$ ;

步骤6)令  $q=q+1$ ,重复步骤3)~6),并根据式(17)更新惯性权重  $w$ ;

步骤7)当达到最大迭代次数或误差达到标准时输出全局最优解,也即最优 CNN 模型参数。

综上,本文提出的基于时频谱图和自适应动态权重 PSO-CNN 的振动信号识别算法的具体流程如图3所示。

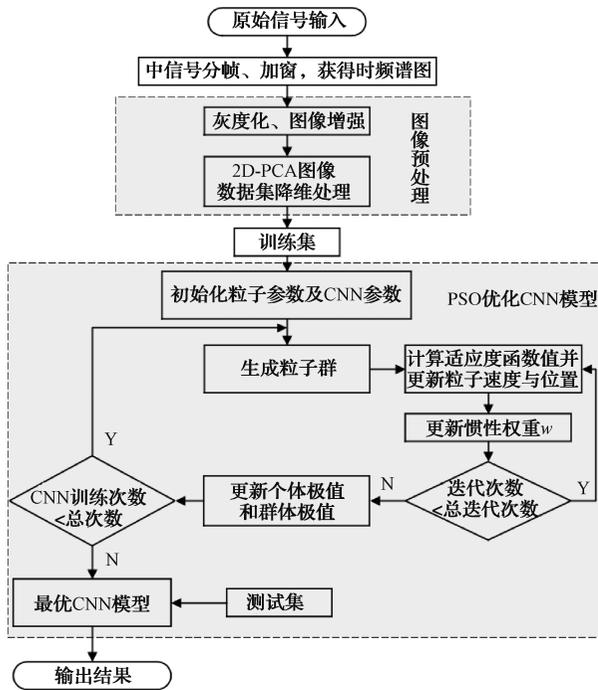


图3 算法流程

### 3 实验及结果分析

#### 3.1 实验数据采集及预处理

由于目前没有开源的施工振动信号数据集,为验证自适应动态权重 PSO-CNN 算法在外破振动信号识别上的有效性,本文实验利用振动传感系统实地采集施工振动信号进行验证,实验现场如图4所示。



图4 实验现场

信号采集装置采用工控机搭载 PCI-4474 数据采集卡,设置采样率为 5 kHz,样本数据时长为 1 s。传感器使用 IEPE 加速度传感器,数据采集装置及传感器参数如表4所示,设备实物图如图5所示。

表4 数据采集卡和传感器参数

型号	分辨率	采样率	信号输入	电压范围
PCI-4474	24 bits	102.4 kS/s	4	±10 V
型号	量程/g	频率范围/Hz	工作电流/mA	电压灵敏度/(mV·g <sup>-1</sup> )
YK-YD20	25	0.5~5 000	2~10	199.9



(a) 传感器 (b) 数据采集设备

图5 数据采集设备

本文设置了6种施工类型,分别为机械挖掘、打桩、破碎锤、钻孔机、车辆经过和人工挖掘。施工位置处于传感器周围 20 m×20 m,每种施工类型各采集 500 组振动信号数据,信号时间长度设置为 1 s。利用 MATLAB 将采集的振动信号转化为时频谱图,设置帧长  $L_f = 32$ ,帧移  $Linc = 25\%$ ,图像的频率范围为 0~1 500 Hz,强度色条值范围设置为 0~10。图6所示为6种振动信号的部分时频谱图像数据。

由图6可以看出,6种施工振动信号的主要频段集中在 0~1 000 Hz,6种施工振动信号的时频谱图在时域及频域上均存在各自明显特征,但仍有大量频段存在重叠区域,很难通过人工对其进行准确的类型识别。

原始 RGB 时频谱图如图7(a)所示,图像尺寸为 256×256×3。首先对 RGB 图像进行灰度化和图像增强处理,突出图像特征的同时将图像尺寸缩减为 256×256×1;然后利用 2D-PCA 算法对图像进行数据压缩,设置  $d = 64$ ,降维后的图像尺寸变为 256×64×1。原始图像、增强后的灰度图与降维图像对比如图7所示。可以看出,经降维后的图像仍然保留了时频谱图中的纹理特征,并且大大减少了图像数据量。

#### 3.2 实验设置及结果分析

本文实验使用 Windows10 系统,编程语言为 MATLAB,处理器为 Inter i7-10700 处理器,显卡为 NVIDIA GTX3060。使用双卷积层 LeNet-5 卷积神经网络进行数据训练与识别实验,模型参数如表5所示。

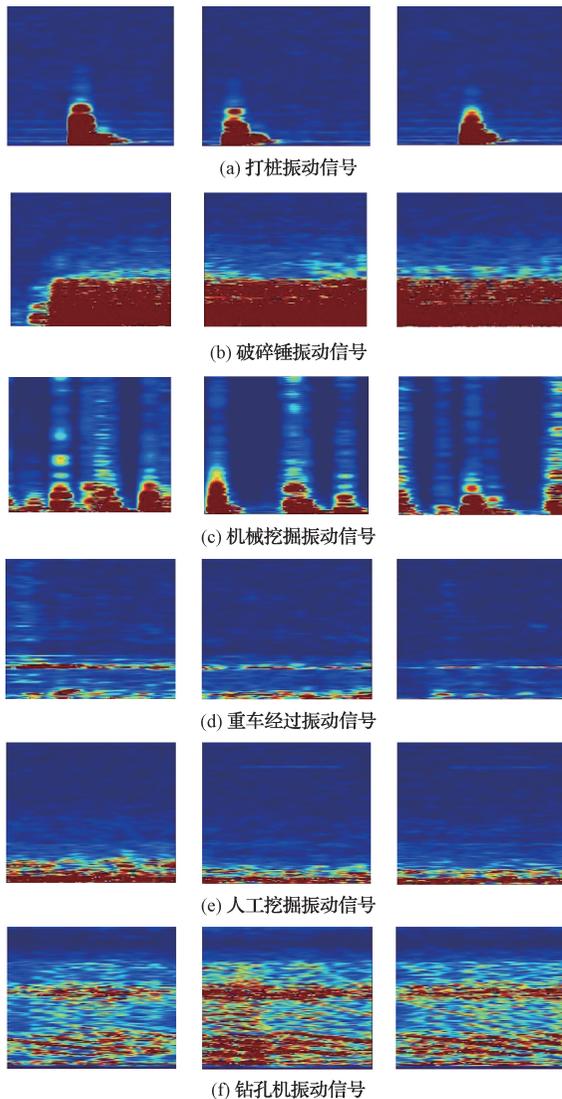


图6 6种振动信号部分时频谱图数据

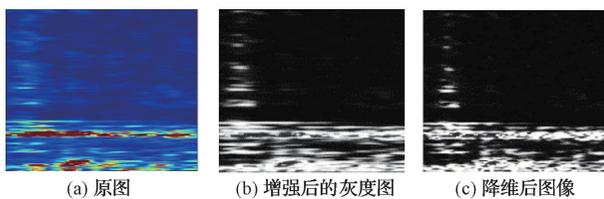


图7 图像显示效果对比

表5 双卷积层 LeNet-5 卷积神经网络结构参数

参数	取值范围
$C_1$ 中卷积核个数	20~50
$C_1$ 中卷积核大小	3~6
$C_2$ 中卷积核个数	5~20
$C_2$ 中卷积核大小	3~6
池化核大小	$2 \times 2$
激活函数类型	Sigmoid, ReLU
池化层采样方式	Max-pooling
学习率	$10^{-4}$

首先,将3 000张RGB图像数据仅进行灰度化处理作为数据集,人工选取4种参数配置的CNN模型进行数据训练及识别实验。4种CNN模型识别结果如表6所示,其中,20@3×3表示卷积核数量为20,卷积核大小为3×3, $C_1$ 代表卷积层1, $C_2$ 代表卷积层2。

表6 4种CNN模型参数设置及识别结果

CNN模型	$C_1$	$C_2$	传递函数类型	学习率	识别准确率/%
CNN <sub>1</sub>	20@5×5	5@2×2	ReLU	0.000 1	72.33
CNN <sub>2</sub>	30@5×5	10@2×2	ReLU	0.000 1	84.67
CNN <sub>3</sub>	20@3×3	5@2×2	ReLU	0.000 1	76.11
CNN <sub>4</sub>	30@5×5	10@2×2	Sigmoid	0.000 1	83.22

CNN<sub>1</sub>和CNN<sub>2</sub>只有卷积核个数不同,在传递函数及学习率相同的前提下,CNN<sub>2</sub>的准确率相较CNN<sub>1</sub>提升了12.34%;CNN<sub>1</sub>与CNN<sub>3</sub>相比只有 $C_1$ 的卷积核大小不同,但识别准确率相差3.78%;由CNN<sub>2</sub>与CNN<sub>4</sub>识别结果可知,其他参数相同的前提下,使用ReLU作为激活函数相比使用Sigmoid函数识别准确率提升了1.45%。可见,卷积核大小、数量以及不同传递函数的选取在很大程度上影响最终的识别准确率。因此,通过人工选择CNN参数难以获得最优分类模型。

其次,为了证明本文所提方法中图像增强和2D-PCA降维算法对于图像识别的积极作用,利用上述识别率最高的CNN<sub>2</sub>模型进行如下两种方法的识别实验。

1)方法1

3 000张RGB图像经灰度化处理后直接作为CNN<sub>2</sub>数据集,按照7:3分为训练集和测试集。

2)方法2

3 000张RGB图像经灰度化、图像增强及2D-PCA降维后作为CNN<sub>2</sub>数据集,按照7:3分为训练集和测试集。

分别记录两种方式下的图像预处理时间、训练时间、测试集识别时间及识别准确率,实验结果记录如表7所示,识别结果混淆矩阵图如图8所示。

表7 两种方法识别实验结果

	图像预处理 时间/min	训练时间 /min	测试时间 /min	识别准确 率/%
方法1	0.8	27.4	7.5	84.67
方法2	2.6	12.8	4.3	85.33

由表7可知,方法2在图像预处理阶段所用时间相比方法1增加了1.8 min,但是方法2中CNN模型的训练时间缩短了14.6 min,测试集识别时间由7.5 min缩减到4.3 min,平均每张图像的识别时间仅为0.29 s,并且识别准确率也有所提升。上述结果说明图像数据经图像增强和2D-PCA降维处理后,图像特征更加明显,并且大大降

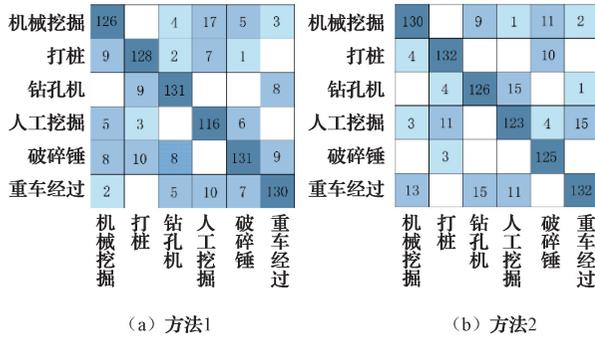


图8 两种方法识别结果混淆矩阵图

低了运算数据量,减少了算法总体运行时间,对于图像识别具有积极作用。

最后,将图像增强和 2D-PCA 降维后的图像数据作为 CNN 数据集,使用基于自适应动态惯性权重 PSO 优化的 CNN 模型对图像数据进行识别实验。将 2.3 节列出的 10 个待优化参数作为 PSO 的输入变量,将模型的准确率误差作为输出,在训练过程中进行参数寻优迭代。PSO 相关参数设置如表 8 所示。

表 8 PSO 相关参数设置

参数	数值
种群数量	10
惯性参数	0.4~0.9 动态更新
加速度常数 $c_1$	1.2
加速度常数 $c_2$	1.2
最大迭代次数	50

为了防止偶然性,使用改进的 PSO 按照表 8 参数进行 5 次 CNN 网络训练,记录每次训练输出的最优粒子参数,并获得该模型对测试集的识别准确率和测试时间,结果如表 9 所示。

表 9 5 次 PSO-CNN 模型测试结果

实验次数	1	2	3	4	5	均值
识别时间/s	213	220	216	213	210	214.4
准确率/%	96.89	97.67	97.22	98.33	97.56	97.53

由表 9 可知,5 次训练输出的最优模型对测试集的识别准确率均大于 96%,平均识别准确率达到 97.53%。第 4 次训练得到的粒子参数模型识别准确最高,达到了 98.33%,平均每张图像的识别时间仅为 0.24 s,与使用相同数据集的 CNN<sub>2</sub> 识别结果相比,识别速率提升了 17.44%,识别准确率提升了 13.00%。将第 4 次训练得到模型记为 PSO-CNN-4,其粒子参数如表 10 所示。

### 3.3 算法对比

#### 1) PSO-CNN-4 与普通 PSO-CNN 对比分析

为验证基于自适应动态惯性权重 PSO 相对与普通

表 10 PSO-CNN-4 模型参数

参数项	值
$C_1$ 卷积核数量	36
$C_1$ 卷积核大小	$4 \times 4$
$C_1$ 卷积核步长	2
$C_2$ 卷积核数量	29
$C_2$ 卷积核大小	$3 \times 3$
$C_2$ 卷积核步长	2
$V_1$ 池化核大小	$2 \times 2$
$V_1$ 池化核步长	1
$V_2$ 池化核大小	$2 \times 2$
$V_2$ 池化核步长	1

PSO 的优越性,采用普通 PSO 同样对 LeNet-5 网络模型进行参数寻优,设置惯性权重  $\omega = 0.6$ ,其余参数均一致。迭代过程中两种算法的适应度函数值变化如图 9 所示,两种模型对于测试集的识别准确度及识别时长如表 11 所示。

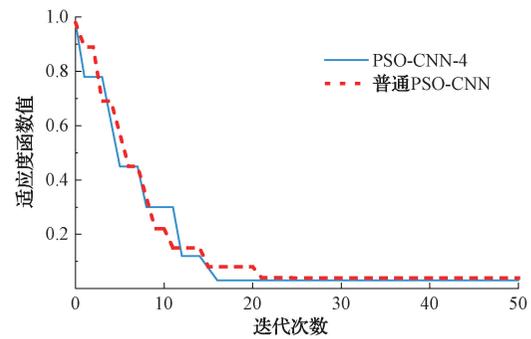


图 9 PSO 迭代过程中适应度函数值变化情况

表 11 优化模型与普通模型识别性能对比

	识别准确率/%	识别时长/s
PSO-CNN-4	98.33	213
普通 PSO-CNN	96.11	216

由结果可知,优化后的 PSO-CNN-4 模型识别准确率相比普通 PSO-CNN 提高了 2.22%,每张图片的识别速率差距较小。但是,普通 PSO 在迭代 26 次后,适应度函数值才达到最小值,而自适应动态权重 PSO 在迭代 16 次时即达到了最小值并保持稳定,其寻优速度明显优于普通 PSO 算法。因此,采用自适应动态惯性权重的 PSO-CNN-4 模型与普通 PSO-CNN 模型相比,其具有更好的参数优化性能和更高的识别准确率。

#### 2) PSO-CNN-4 与其他分类模型对比分析

将 PSO-CNN-4 与 CNN<sub>2</sub> 以及 3 种经典 CNN 结构 (ZFNet、VGG 和浅层 ALexNet) 进行对比,选用相同的训练集进行网络训练,使用同一测试集进行检验,记录每种模型的识别准确率及识别时间,测试结果如图 10 所示。

由对比结果可知,4 种分类模型中,PSO-CNN-4 模型

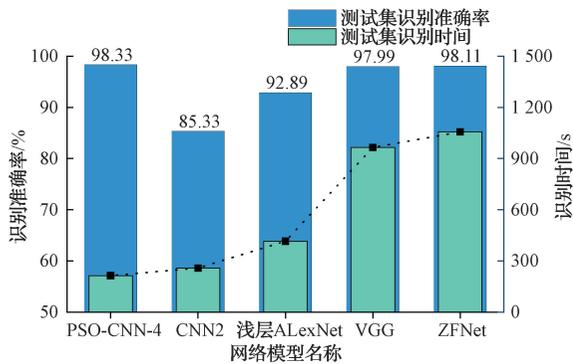


图 10 5 种网络模型分类效果对比

的识别准确率最高且识别速率最快,与固定网络参数的 CNN<sub>2</sub> 模型和浅层 AlexNet 模型相比,其识别精度分别高出了 13.00% 和 5.44%。ZFNet、VGG 模型虽然同样具有较高的识别准确率,但由于其均为深层网络,计算参数量过大,导致其训练时间和测试时间过长,难以满足振动监测的实时性要求。因此,本文提出的基于自适应动态惯性权重 PSO-CNN 模型具有更加优越的识别性能,并且其相对简洁的结构保证了模型的轻量化,对于振动信号时频谱图的识别表现出了更好的适用性。

综上,本文提出的基于时频谱图和自适应动态权重 PSO-CNN 的振动信号识别方法能够有效提取信号时频谱图特征,相比传统信号识别方法具有更快的检测速率以及更高的检测精度,保证了信号监测的实时性和可靠性,适用于电缆线性区域外破振动信号的实时监测。

#### 4 结 论

为实现电缆周界外力破坏事件的识别,提出基于时频谱图特征和自适应动态权重 PSO-CNN 的振动信号识别算法。以振动传感系统获取的异常振动信号时频谱图作为基础数据集,在图像预处理阶段,首先对时频谱图进行灰度化处理 and 图像增强,然后利用 2D-PCA 对图像数据进行降维处理,保留原图重要特征的同时大大减小了图片尺寸。在此基础上,利用自适应动态惯性权重 PSO 对 CNN 的卷积层、池化层相关参数进行迭代寻优,从而获得最优的 CNN 分类模型。在对实地采集的 6 种振动信号识别实验中,本文所提方法在识别准确率、执行时间等方面相较于未优化的 CNN 模型有了明显提升和改进,并在与其他分类模型的对比试验中进一步验证了该算法的有效性和优越性,为快速、准确识别外力破坏事件类型提供了一种可行方案。

#### 参 考 文 献

[1] 刘骥,张明泽,张振鹏,等. 外部振动对 500 kV 交联聚乙烯电缆敷设条件的影响[J]. 高电压技术, 2017, 43(2):673-681.  
[2] 杨世迎,祝贺,何文,等. 外部冲击下电力电缆护套

结构性损伤研究[J]. 振动与冲击, 2020, 39(24): 122-127.

[3] ZHAO Z Q, ZHENG P, XU S, et al. Object detection with deep learning: A review[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(11): 3212-3232.  
[4] 陈伟根, 范海炉, 王有元, 等. 基于小波能量与神经网络的断路器振动信号识别方法[J]. 电力自动化设备, 2008(2):29-32.  
[5] 张训杰, 张敏, 李贤均. 基于二维图像和 CNN-BiGRU 网络的滚动轴承故障模式识别[J]. 振动与冲击, 2021, 40(23):194-201, 207.  
[6] WANG S, ZENG X. Robust underwater noise targets classification using auditory inspired time-frequency analysis[J]. Applied Acoustics, 2014, 78: 68-76.  
[7] 刘元, 苏盛, 刘正道, 等. 基于时、频域自相似性的配电网变压器环境噪声识别方法[J]. 电力自动化设备, 2022, 42(3):203-209.  
[8] 李舜酩, 郭海东, 李殿荣. 振动信号处理方法综述[J]. 仪器仪表学报, 2013, 32(8):1907-1915.  
[9] 柳絮, 王坚, 李文. 集成变分模态分解和希尔伯特-黄变换的结构振动时频提取模型[J]. 武汉大学学报(信息科学版), 2021, 46(11):1686-1692.  
[10] 闫鹏程, 孙华刚, 毛向东, 等. 基于 EMD 与 SVD 的齿轮箱分形诊断方法研究[J]. 电子测量与仪器学报, 2012, 26(5):404-412.  
[11] 胡业林, 代斌, 宋晓. 基于小波包和 AFSA-SVM 的电机故障诊断[J]. 电子测量技术, 2021, 44(2):48-55.  
[12] 刘云鹏, 罗世豪, 王博闻, 等. 基于 Mel 时频谱-卷积神经网络的变压器铁芯夹件松动故障声纹模式识别[J]. 华北电力大学学报(自然科学版), 2020(6):52-60, 67.  
[13] 马瑶, 智敏, 殷雁君, 等. CNN 和 Transformer 在细粒度图像识别中的应用综述[J]. 计算机工程与应用, 2022, 58(19):53-63.  
[14] 王青. 计算机视觉技术及其在电力系统自动化中的应用[J]. 通信电源技术, 2019, 36(1):213-214.  
[15] 詹长杰, 周步祥. 基于 PCA-SVM 模型的中长期电力负荷预测[J]. 电测与仪表, 2015, 52(9):6-10, 40.  
[16] ZHONG J, HE W Y, TAN H S. Research on human-computer interaction gesture recognition based on PCA dimensionality reduction and machine learning algorithm [J]. Machine Tool & Hydraulics, 2020(6): 181-186.  
[17] 谭敏生, 杨帅创, 丁琳, 等. 结合随机森林的 PSO-CNN 入侵检测研究[J]. 计算机应用与软件, 2021, 38(12):326-331.  
[18] YANG J, ZHANG D D, FRANGI A F, et al. Two-dimensional PCA: A new approach to appearance-

- based face representation and recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131-137.
- [19] HU N, MA H, ZHAN T. Finger vein recognition method combining LBP texture feature and B2DPCA technology [J]. CAAI Transactions on Intelligent Systems, 2019, 14(3): 533-540.
- [20] 刘昉, 李奇临, 蒋涌, 等. 基于CNN的天气雷达异常回波图像识别算法研究[J]. 电子设计工程, 2021, 29(6): 74-78, 87.
- [21] 郑一珍, 牛藹楷, 熊晓燕, 等. 基于EMD-SDP特征融合的CNN轴承保持架故障诊断研究[J]. 机电工程, 2021, 38(1): 81-87.
- [22] 叶壮, 余建波. 基于多通道加权卷积神经网络的齿轮箱振动信号特征提取[J]. 机械工程学报, 2021, 57(1): 110-120.
- [23] 刁宁昆, 马怀祥, 刘锋. 一种改进LeNet5结合LightGBM的滚动轴承故障诊断方法[J]. 国外电子测量技术, 2022, 41(1): 140-145.
- [24] 赵安军, 赵啸, 荆竞, 等. 优化CNN超参数的非侵入式电力负荷识别算法[J/OL]. 激光与光电子学进展: 1-14[2023-01-05]. <http://kns.cnki.net/kcms/detail/31.1690.TN.20220713.1225.050.html>.
- [25] 赵帅, 刘松涛, 汪慧阳. 基于PSO-CNN的LPI雷达波形识别算法[J]. 系统工程与电子技术, 2021, 43(12): 3552-3563.
- [26] SHI Y, EBERHART R C. A modified particle swarm optimizer [C]. Proceedings of IEEE International Conference on Evolutionary Computation. Piscataway: IEEE Press, 1998: 69-73.
- [27] 全秋娟, 赵岂, 李萌. 基于自适应动态改变的粒子群优化算法[J]. 微电子学与计算机, 2019, 36(2): 6-10, 15.
- [28] 马龙, 卢才武, 顾清华, 等. 引入改进鸽群搜索算子的粒子群优化算法[J]. 模式识别与人工智能, 2018, 31(10): 43-54.

#### 作者简介

崔岩, 硕士研究生, 主要研究方向为高压与绝缘技术、信号处理等。

E-mail: cuiyan011@163.com

方春华(通信作者), 博士, 副教授, 主要研究方向为高压与绝缘技术、电缆故障诊断技术。信号处理等。

E-mail: sxdx105@163.com

文中, 硕士, 副教授, 主要研究方向为电缆故障诊断技术、信号处理等。

E-mail: 1006854504@qq.com