

DOI:10.19651/j.cnki.emt.2107997

# 基于双谱与双流卷积神经网络的断路器故障诊断<sup>\*</sup>

林 穿 徐启峰

(福州大学 电气工程与自动化学院 福州 350108)

**摘要:** 高压断路器操动机构的振动信号包含了断路器运行状态的重要信息,对操动机构工作状态的诊断辨识十分重要。针对振动信号随机、非平稳的复杂特性,提出了一种基于双谱分析和双通道流浅层卷积神经网络的断路器故障诊断方法。对振动信号进行双谱分析和小波分析,分别提取2D双谱矩阵以及1D小波频带能量作为双流卷积神经网络的双通道特征;对断路器模拟实验采集到的5种工况下的振动信号进行有监督训练。结果表明,双谱分析能够抑制高斯噪声、保留操动机构不同工况下主要峰值形态特征并融合小波频带能量特征,所提模型训练迭代5次即可达到98.33%的高识别精度,实现断路器操动机构的故障诊断辨识。

**关键词:** 振动信号;双谱分析;双流卷积神经网络;故障诊断;断路器

中图分类号: TM56 文献标识码: A 国家标准学科分类代码: 470.4

## Fault diagnosis of circuit breaker based on bispectrum and two-stream convolutional neural network

Lin Chuan Xu Qifeng

(School of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China)

**Abstract:** High-voltage circuit breaker operating mechanism vibration signal contains important information about the status of the circuit breaker, which is of great significance for the diagnosis and identification of the operating status of the operating mechanism. Aiming at the complex characteristics of random and non-smooth vibration signals, a circuit breaker fault diagnosis method based on bispectrum analysis and a two-stream flow shallow convolutional neural network is proposed. Bispectral analysis and wavelet analysis are performed on the vibration signal. The 2D bispectral matrix and 1D wavelet band energy are extracted as the dual-channel features of the two-stream convolutional neural network, respectively, supervised model training of vibration signals collected from circuit breaker simulation experiments for five operating conditions. The results show that the bispectral analysis can suppress Gaussian noise, retain the main peak morphological features of the operating mechanism under different operating conditions and fuse wavelet band energy features, and the proposed model can achieve a high recognition accuracy of 98.33% in 5 training iterations to achieve fault diagnosis and identification of the circuit breaker operating mechanism.

**Keywords:** vibration signal; bispectrum analysis; two-stream convolutional neural network; fault diagnosis; circuit breaker

## 0 引言

随着智能电网的兴起,对高压断路器的智能化和运行可靠性的要求也越来越高,科学地评估断路器运行状态<sup>[1]</sup>、实时识别缺陷十分重要<sup>[2]</sup>。据国内外数据统计,由操动机构内部异常引起高压断路器故障事故占60%以上。振动信号可以实时反映操动机构内部状态信息,且非侵入式测量可有效避免电磁干扰。因此,在高压断路器故障诊断领

域,采集振动信号进行分析的方式逐渐成为研究热点<sup>[3]</sup>。

常见的振动信号处理方法有幅值域分析法、傅里叶变换、小波分析、高阶统计量等方法<sup>[4]</sup>。文献[5]用小波包变换将振动信号分解为频带能量,映射断路器故障情况。文献[6]采用CEEMDAN分解法分解振动信号,获得固有模式函数作为故障诊断特征。文献[7]提出改进的时域能量熵与变分模式分解计算振动信号能量熵,提取故障特征。通过时域和频域分析振动信号特征已得到广泛应用,但振

收稿日期:2021-09-30

\*基金项目:国家自然科学基金(51977038)项目资助

动信号的提取易受噪声干扰,提取到的频谱、时频特征的质量将变得不可靠。

当获得振动信号特征后,通常采取智能算法建立故障分类模型。常见的分类模型有 3 类:基于定性经验知识、基于统计分析以及基于浅层人工智能。经典模型有朴素贝叶斯、反向神经网络、决策树、支持向量机、动态时间规整等。文献[8]基于小样本非精确狄里赫雷模型结合贝叶斯网络估计断路器机械故障概率。文献[9]提出灰狼优化支持向量机对振动信号熵权特征进行学习和训练。文献[10]以一组正常工况下的振动信号为基准,以短时能熵比作为动态时间规整算法的输入向量进行故障诊断。但是,基于定性经验知识需要专业经验积累来推测故障类型;基于统计分析对数据的准确性与完备性要求较高;浅层人工智能对复杂映射性能表达能力有限。随着深度学习地发展,深度网络逐步被应用于断路器故障诊断领域,能够挖掘振动信号与故障类型复杂的映射关系。文献[11]对振动信号应用随机森林二进制编码拓展特征宽度,使用堆叠自编码压缩特征训练断路器故障分类器。文献[12]将振动信号转变为小波时频图再通过 AlexNet 深层卷积神经网络构建故障分类模型。文献[13]提出卷积神经网络和长短时记忆网络的混合深度网络,从时空两方面提取振动信号特征建立故障诊断模型。深度网络诊断模型具有很高的识别精度,但计算运行开销大、训练迭代次数多。

综上所述,基于振动信号的高压断路器故障诊断仍需克服噪声对振动信号提取的干扰、增强振动信号特征表达以及建立强映射表达性能、高识别精度、少迭代次数、短运行时长的分类模型的需求。因此,本文提出一种将振动信号分别采用小波分析、双谱分析形成 1D 小波频带特征和 2D 双谱矩阵特征的融合信息特征的双通道浅层卷积神经网络高压断路器故障诊断分析的方法。通过对 10 kV 弹簧操动机构的断路器进行模拟实验,采集 5 种工况的振动信号建立所提方法的故障诊断模型,并与其它 3 种经典分类模型进行对比,验证所提方法的有效性和优越性。

## 1 断路器振动信号分析与特征提取

### 1.1 操动机构振动信号的产生

以 10 kV 弹簧操动机构的断路器为研究对象,操动机构包含分合闸弹簧、分合闸线圈、凸轮、拐臂、棘轮等机械零件。其工作过程包括分闸操作、合闸操作以及储能操作 3 个动作过程。

机械联动碰撞的动作过程伴随着规律性振动的产生。因此,振动信号蕴含着丰富的操动机构工况信息,对振动信号开展特征分析具有重要的应用价值。

### 1.2 基于振动信号的双谱分析法

双谱分析是一种二阶谱,通常用于监测非线性信号中的二次相位耦合<sup>[14]</sup>。通常采用直接定义法计算信号的双

谱,信号的离散傅里叶变换定义为:

$$\mathbf{X}(f) = \sum_{t=-\infty}^{\infty} \mathbf{x}(t) \exp(-j2\pi ft) \quad (1)$$

式中: $\mathbf{x}(t)$ 为信号; $\mathbf{X}(f)$ 为复数; $f$ 为频率。

幅值  $|\mathbf{X}(f)|$  和相位  $\varphi$  的表达式为:

$$\mathbf{X}(f) = |\mathbf{X}(f)| \exp(j\varphi) \quad (2)$$

通过傅里叶变化,双谱  $B(f_c, f_s)$  在频域内表示为:

$$\mathbf{B}(f_1, f_2) = E < \mathbf{X}(f_1) \mathbf{X}(f_2) \mathbf{X}^*(f_1 + f_2) > \quad (3)$$

式中: $\mathbf{X}^*$  为  $\mathbf{X}$  复共轭数; $f_1, f_2$  和  $f_1 + f_2$  是 3 个不同的频率; $E < >$  为数学期望表达式;双谱  $\mathbf{B}(f_1, f_2)$  在频域坐标系具备对称性,包含原始信号的幅值信息与相位信息。

### 1.3 基于振动信号的小波频带能量分析法

小波频带能量分析法利用小波分解将信号中不同分量无冗余、无疏漏、正交地分解到独立的频带内,根据各频带内能量变化来判断系统运行状况。离散小波分解振动信号  $\mathbf{x}(k)$  第  $j$  层的第  $k$  个采样点的高频和低频小波系数分别定义为:

$$\mathbf{D}_j(k) = \sum_{l=0}^{L-1} h(l) \cdot \mathbf{A}_{j-1}(k+l-L+1) \quad (4)$$

$$\mathbf{A}_j(k) = \sum_{l=0}^{L-1} g(l) \cdot \mathbf{A}_{j-1}(k+l-L+1) \quad (5)$$

式中: $\mathbf{D}_j(k)$  和  $\mathbf{A}_j(k)$  分别为高频和低频小波系数; $L$  为滤波器长度; $h(l)$  为高通滤波器; $g(l)$  为低通滤波器;当  $j$  为 1 时, $\mathbf{A}(k) = \mathbf{x}(k)$ 。

## 2 双流卷积神经网络

卷积神经网络(convolutional neural network,CNN)采用局部感知器与权重共享方式增强泛化能力的同时降低网络模型的复杂度和参数个数<sup>[15]</sup>。双流 CNN 的首次提出是应用于识别视频中的人体行为,其同时提取空间特征与时序特征<sup>[16]</sup>可以达到更好的识别效果。本文设计的双流浅层 CNN 模型构架如图 1 所示,相比深度 CNN 模型不同点在于同时拥有一维卷积通道和二维卷积通道的双通道输入,且每个通道仅有一层卷积层。所提模型构架重点在于合理设计双通道和汇聚层。

### 1) 卷积层

图 1 中双流 CNN 网络输入的 1 D 卷积以及 2 D 卷积计算分别如式(6)、(7)所示。

$$\mathbf{T}_1(i) = \mathbf{b}^i + \mathbf{w}_d^i \sum_{d=1}^m r_d, i = 1, 2, \dots \quad (6)$$

$$\mathbf{T}_2(i) = \mathbf{b}^i + \mathbf{w}_{d,y}^i \sum_{d=1}^m \sum_{y=1}^n r_{d,y}, i = 1, 2, \dots \quad (7)$$

式中: $\mathbf{T}_1(i)$  和  $\mathbf{T}_2(i)$  分别表示由第  $i$  个 1 D 或 2 D 卷积核提取的特征; $w$  和  $b$  分别表示权重和偏置; $r$  表示输入; $m, n$  分别表示两个不同维度的输入点数。

### 2) 汇聚层

融合一维和二维特征前,需要将二维数据展平到一维,展平操作  $flatten()$  如式(8)、(9)所示。

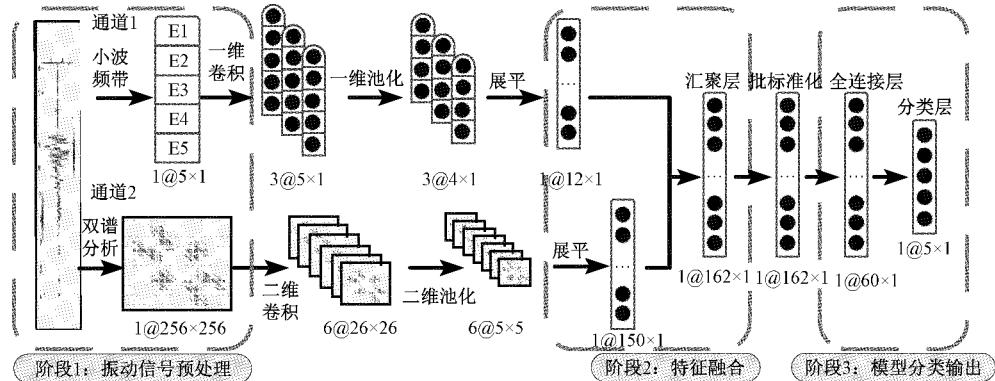


图1 双流卷积神经网络断路器故障诊断模型框架

$$\mathbf{Q}_i = \begin{bmatrix} s_{11} & \cdots & s_{1h} \\ \vdots & \ddots & \vdots \\ s_{h1} & \cdots & s_{hh} \end{bmatrix} \quad (8)$$

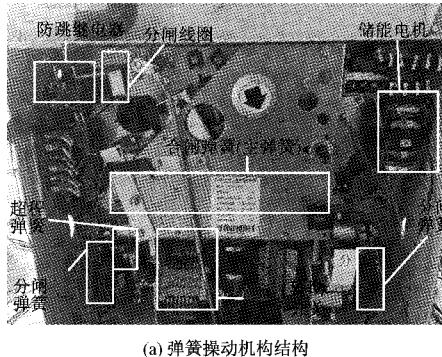
$$\mathbf{q}_i^T = flatten(\mathbf{Q}_i) = [s_{11}, \dots, s_{1h}, \dots, s_{h1}, \dots, s_{hh}] \quad (9)$$

式中: $\mathbf{Q}_i$ 为二维特征平面; $s_{ih}$ 为第 $h$ 行第 $h$ 列的特征平面元素值; $\mathbf{q}_i$ 为展平后向量。

继而与另一通道进行汇聚操作 $FF()$ :

$$\mathbf{d}_i^T = FF(\mathbf{q}_{i1}, \mathbf{q}_{i2}) = [s_{111}, \dots, s_{hh1}, s_{112}, \dots, s_{hh2}] \quad (10)$$

式中: $\mathbf{q}_{i1}$ 表示一维特征向量; $\mathbf{q}_{i2}$ 表示展平后的二维特征向量。



(a) 弹簧操动机构结构

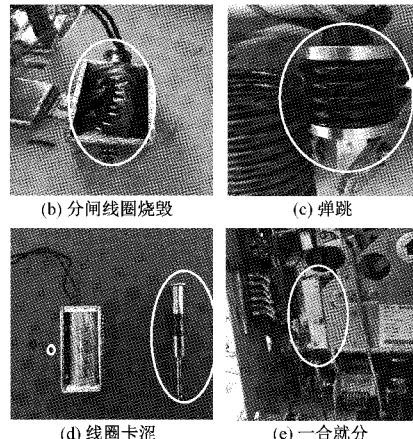


图2 操动机构与故障模拟图

- 1) 分闸线圈烧毁故障:拆除分闸线圈、闭合分闸按钮,使线圈长时间通电,直至线圈表面烧焦。
- 2) 弹跳故障:调节超程弹簧的压缩量。
- 3) 线圈卡涩故障:拆开线圈,在顶杠上缠绕一圈绝缘胶布,增加其运动摩擦力。
- 4) 一合就分故障:重新固定拐臂,顶开合闸脱扣器。

### 3.2 基于双谱分析的振动信号特征预处理与分析

#### 1) 振动信号双谱特征预处理

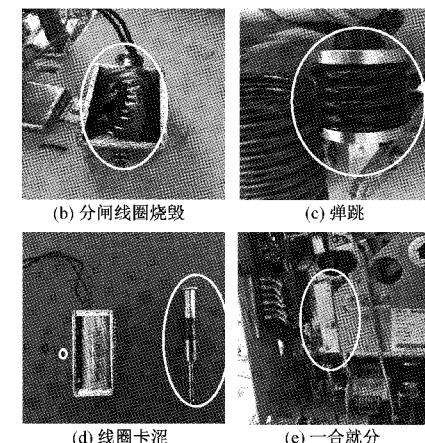
振动信号双谱特征预处理步骤具体如下。

- 步骤1:将振动信号运用式(1)~(3)求得双谱 $\mathbf{B}(f_1, f_2)$ 。5种工况的振动信号双谱 $\mathbf{B}(f_1, f_2)$ 可以由图3的二维双谱图显示。探究振动信号与运行状态的双谱映射关系,有

### 3 基于双谱与小波的特征提取分析

#### 3.1 振动信号数据来源

振动信号数据来源于对一台10 kV弹簧操动机构断路器的故障模拟实验,通过安装于操动机构基座上的加速度传感器采集振动信号。图2为操动机构结构和故障模拟实验图。模拟方案描述如下:



利于初步筛查出异常实验数据。

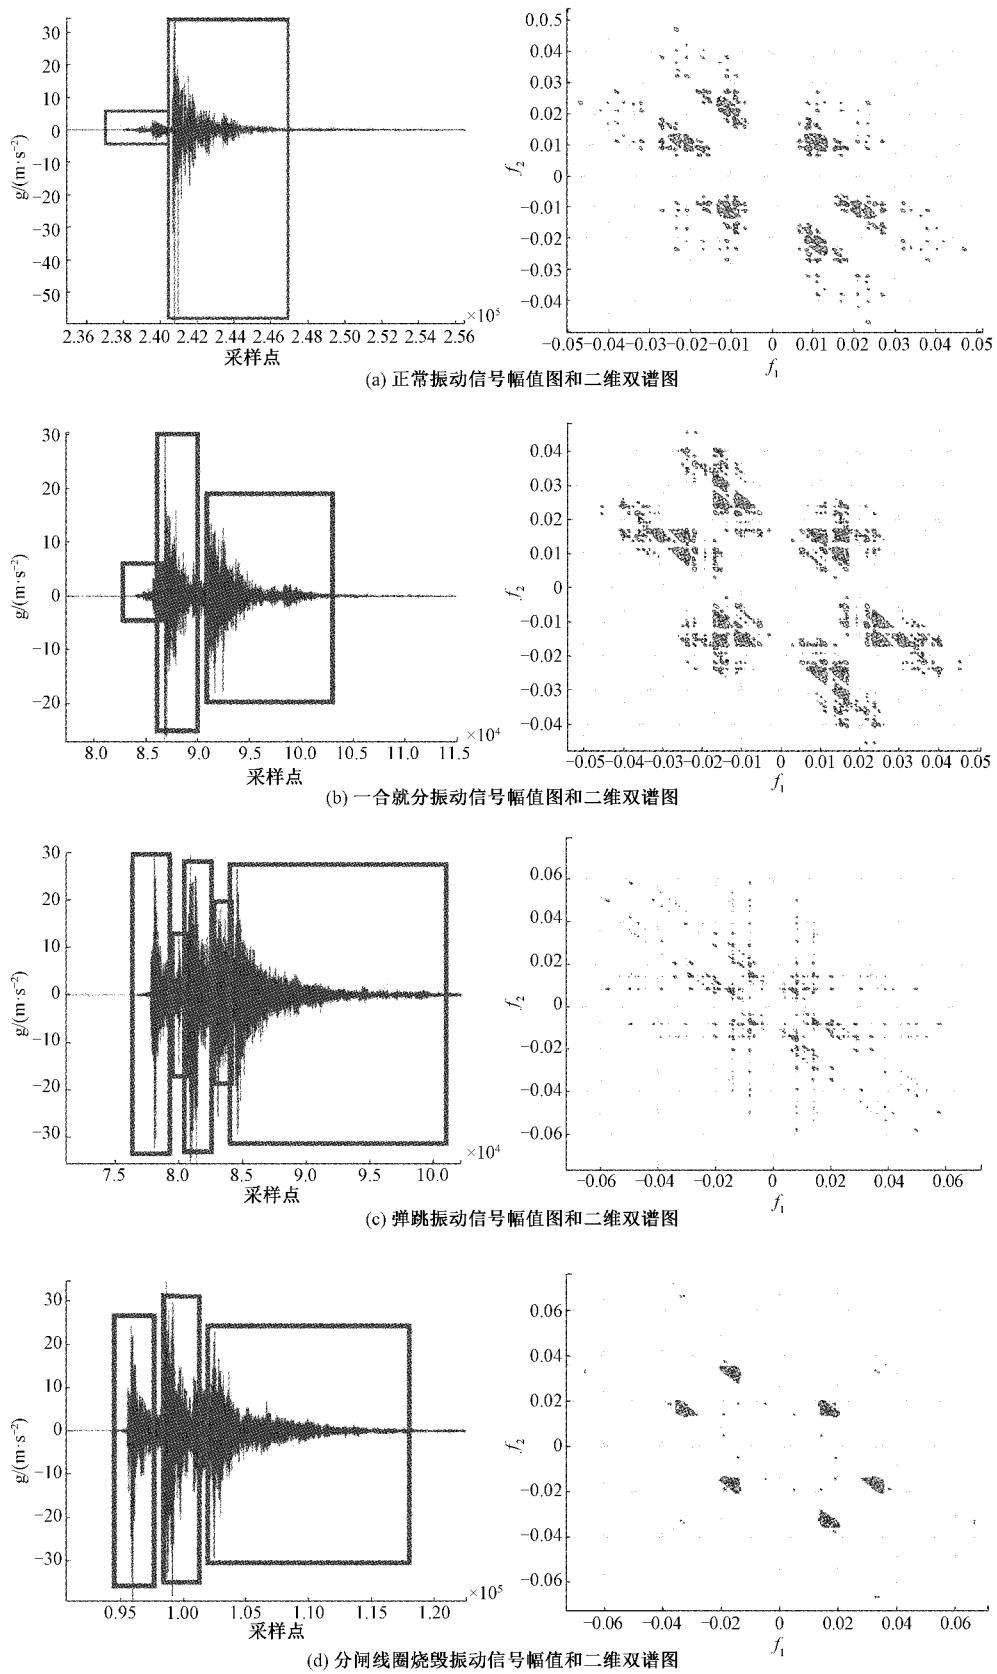
步骤2:所求 $\mathbf{B}(f_1, f_2)$ 为复数形式,对其取模值形成2D矩阵形式。

步骤3:双流CNN网络2D通道输入格式为 $256 \times 256$ ,对2D矩阵进行标准压缩。

#### 2) 振动信号双谱分析抑制噪声性能的验证

以分闸线圈烧毁工况下的振动信号为例进行验证。先后给振动信号添加高斯噪声与非高斯噪声(瑞利分布的随机噪声),验证双谱抑制振动信号噪声的性能。由于双谱具有对称性,因此双谱平面示意图仅显示第一象限,验证性能如图4所示。

图4(c)无噪声信号双谱图与图4(f)含高斯噪声信号



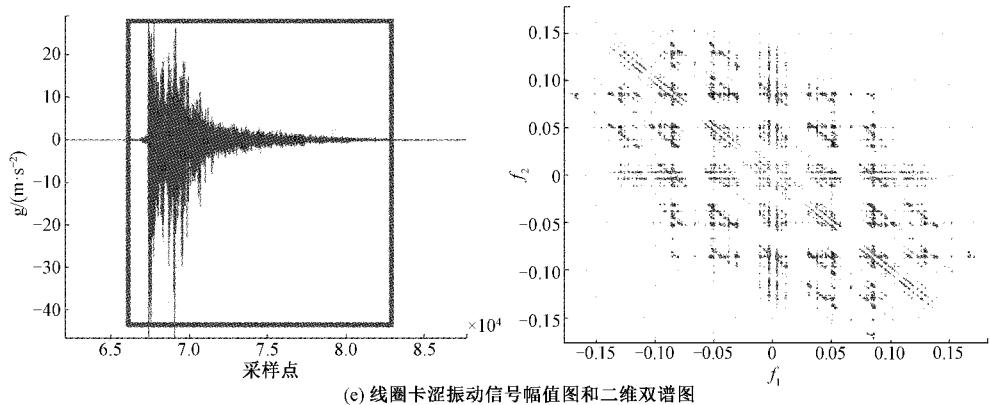


图3 不同工况下振动信号的双谱分析

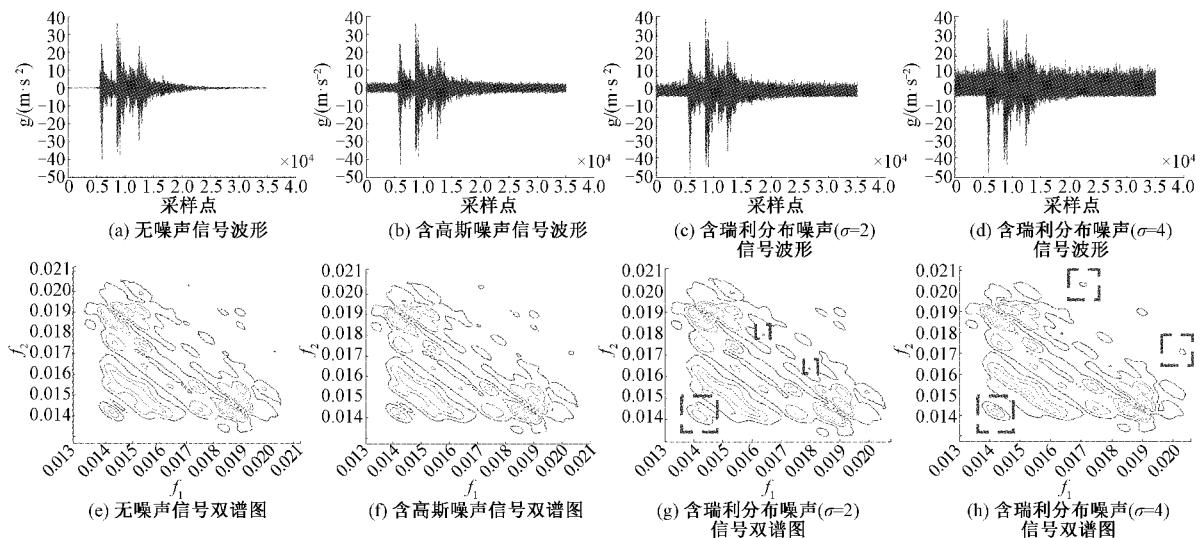


图4 分闸线圈烧毁工况下的振动信号加噪前后双谱分析

双谱图的双谱等高线和相位一致,说明双谱分析具有抑制振动信号高斯噪声的能力。图4(g)和(h)为含不同 $\sigma$ 程度的瑞利分布噪声双谱图,图中虚线方框处相比图4(e)无噪声信号双谱图在双谱等高线出现了额外峰值,解释了双谱分析对含非高斯噪声的振动信号抑制能力的缺陷。但是,无论振动信号是否含高斯噪声或者瑞利分布噪声,图4(e)~(h)的4个图的整体等高线形态与相位保持一定相似度。

在一定程度的非高斯噪声干扰下的振动信号双谱等高线峰值会发生轻微变化,但峰值的整体形态和相位模式依旧被保留,具有较强的提取特征鲁棒性能,为简化后续CNN的特征学习和分类过程提供了便利。在其他4种工况下做同样的验证,可以得到同样的双谱性质。

### 3.3 基于小波分解的振动信号特征预处理与分析

根据1.3节方法,将振动信号通过4层小波分解,得到1个低频小波系数A1和4个高频小波系数D1、D2、D3、D4,将5个小波系数平方求和,再进行归一化得E1、E2、E3、E4、E5作为振动信号特征参数。计算的小波频带能量参数如表1所示。

表1 小波频带能量参数(一组为例) %

状态	E1	E2	E3	E4	E5
正常	83.471	0.172	1.730	4.493	10.119
一合就分	76.985	0.094	2.443	8.066	19.411
弹跳	78.393	0.167	2.585	6.892	12.193
分闸线圈烧毁	36.837	1.151	8.872	17.872	32.897
线圈卡涩	25.054	1.714	16.660	35.428	22.313

## 4 基于双流卷积的故障诊断分析

### 4.1 双流卷积神经网络参数配置

如图1所示双流CNN采用双通道输入,具体参数配置如下。

1)1D输入通道将一维振动信号通过1.3节小波频带能量方法转换为 $5 \times 1$ 的一维特征输入。采用大小为 $2 \times 1$ ,步长为1的3个不同卷积核运算,池化卷积核大小同样为 $2 \times 1$ ,步长为1。

2)2D输入通道将一维振动信号通过1.2节和3.2节

中振动信号双谱特征预处理方法处理成  $256 \times 256 \times 1$  的二维特征输入。采用大小为  $10 \times 10$ , 步长为 10 的 6 个不同卷积核运算, 池化卷积核大小为  $5 \times 5$ , 步长为 5。

3) 输出分类器采用的是 Softmax 分类器, 共设计 5 种分类类别。

## 4.2 实验结果与分析

### 1) 样本配置

将每种工况的 200 组模拟实验数据按 7 : 3 划分为训练集和测试集, 配置情况如表 2 所示。

表 2 数据、标签配置

工况类型	训练样本数	测试(验证)样本数	状态标签
正常	140	60	$[1\ 0\ 0\ 0\ 0]^T$
一合就分	140	60	$[0\ 1\ 0\ 0\ 0]^T$
弹跳	140	60	$[0\ 0\ 1\ 0\ 0]^T$
分闸线圈烧毁	140	60	$[0\ 0\ 0\ 1\ 0]^T$
线圈卡涩	140	60	$[0\ 0\ 0\ 0\ 1]^T$
总数	700	300	

表 3 4 种故障诊断模型结构

模型	通道数	输入特征	模型主框架	批尺寸	学习率	交叉验证次数	损失函数	优化器	层间激活函数	分类器
本文所提	通道 1	小波频带能量	1DCNN							
	通道 2	双谱矩阵	2DCNN							
模型 1	单通道	小波频带能量	Dense	15	0.1	5	交叉熵	Adam	ReLU	Softmax
模型 2	单通道	小波频带能量	1DCNN(同通道 1)							
模型 3	单通道	双谱矩阵	2DCNN(同通道 2)							

### (1) 训练能力评估

模型预测值与实际值的差距可由交叉熵对其进行度量, 熵值越小, 训练效果越佳。4 种模型的训练损失函数曲线(loss)如图 6 所示, loss 曲线都能够达到较好的收敛效果。模型 1 和模型 2 的 loss 值曲线迭代 80 次之后趋向收敛, 收敛速度都较慢。但模型 2 的训练初始 loss 值为 12 小于模型 1 的 24, 说明 1DCNN 在特征提取性能上优于 Dense 结构。模型 3 在第 4 次迭代时就趋向收敛, 验证了振动信号双谱特征能够简化 2DCNN 的训练, 加速收敛。

### (2) 训练精度评估

训练精确度曲线(accuracy)反映模型的泛化能力, 精度越高, 模型训练精度性能越好。如图 6 所示, 4 个模型的 accuracy 曲线都能收敛。模型 1 迭代 50 次后趋向收敛, 模型 2 迭代 60 次之后趋向收敛。本文所提方法收敛速度最快, 迭代 5 次后即趋向收敛, 验证了双通道特征融合的优势。

### 2) 参数优化配置

神经网络诊断模型的网络超参数需优化确定, 以提高分类精度。批尺寸 batch\_size 将影响内存利用率, 学习率  $l_r$  将影响最优权重选取。本文采用网格寻优法对超参数进行优化。以所提模型的 batch\_size 和  $l_r$  为例进行寻优, 结果如图 5 所示。

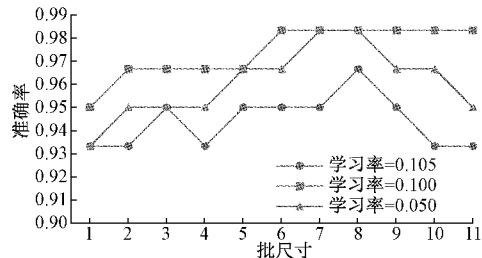


图 5 网格寻优结果

由图 5 可知, 当  $l_r$  为 0.1, batch\_size 大于 14 时, 所提模型的精度能达到最高, 且性能较为稳定。

### 3) 多种模型性能对比

为了验证所提方法的有效性, 与前人研究的 3 种故障诊断模型进行对比。模型 1 为小波分解与 BP 神经网络模型<sup>[17]</sup>, 模型 2 为小波分解与 1DCNN 神经网络模型<sup>[18]</sup>, 模型 3 为 2DCNN 模型<sup>[19]</sup>。参数配置如表 3 所示。

### (3) 分类泛化能力评估

泛化能力可表征模型对不同故障模式诊断的通用性, 可用混淆矩阵直观解释每个故障类别的错误分类。将测试集输入到训练好的模型中可获得预测状态标签。预测标签与真实标签形成的混淆矩阵如图 7 所示。

由图 7 可知, 模型 1 和模型 2 都可达到 95% 的分类准确率, 说明小波分解的振动信号频带能量反映的时域和频域特征有利于模型分类; 模型 3 达到 96.67% 的分类准确率, 说明将振动信号进行双谱分析能够保留振动信号峰值形态特征以及相位特征, 同样有利于模型分类; 本文所提方法将振动信号同时进行小波频带能量分解以及双谱分析汇聚成融合特征, 能够达到 98.33% 最高的分类准确率, 验证了融合特征的优越性。

### (4) 训练与测试运行时长评估

模型的训练和测试都需要运行时间的开销, 以 4 种模型收敛为截止点, 其余配置如表 2 和 3 所示, 训练与测试时

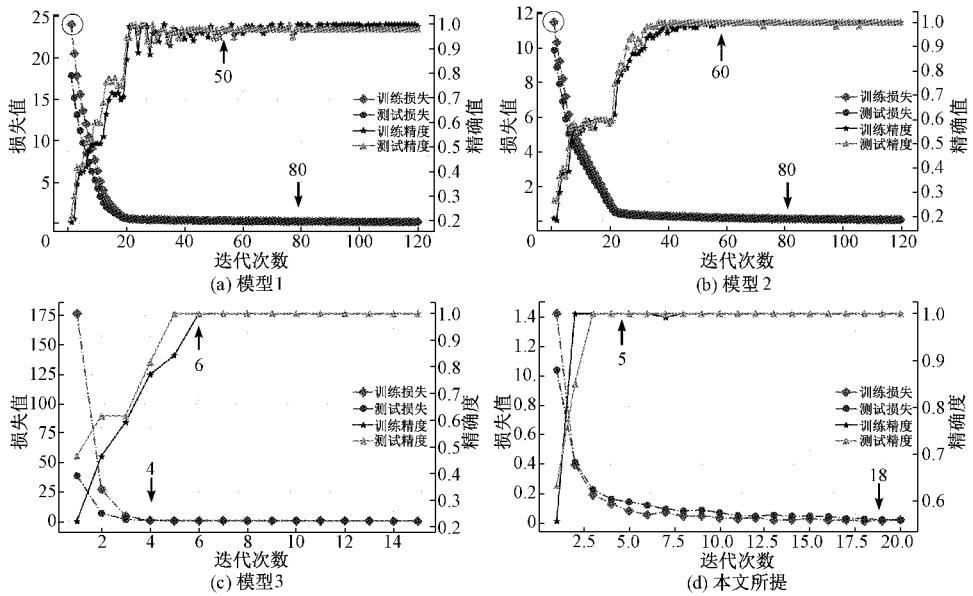


图 6 损失曲线和精确度曲线

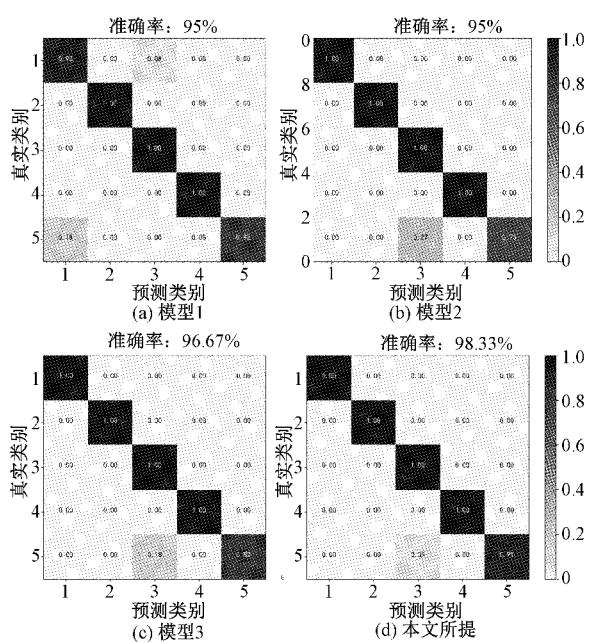


图 7 混淆矩阵

长结果对比如图 8 所示。

由于模型 1 采用全连接层结构,因此训练运行时间最长;模型 2 的输入特征维度为一维特征且采用 1DCNN 结构,训练时间最短。本文所提方法故障分类精度最高,但训练运行时长介于上述 4 种模型之间,属于毫秒级别的运行速度。在保证精度的前提下,同为毫秒级别的情况下,本文所提方法的时间成本是可以接受的。另外,所提方法更主要的优点在于:文献[12]和文献[20]中的多种深度学习故障诊断方法的训练与测试的时长为分钟级别,而本文所提方法是毫秒级别的,可大大缩短开销时长。

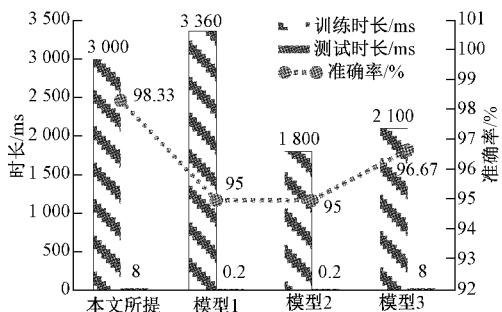


图 8 运行开销时长与精确度

## 5 结 论

为了高效且高精度地识别高压断路器操动机构故障类型,提出了一种基于双谱分析、小波分析和双流卷积神经网络相结合的断路器故障诊断方法。将振动信号的小波频带能量特征与双谱矩阵特征分别输入本文所构造的双通道流卷积神经网络中进行特征融合提取。通过与 BP 神经网络模型,1DCNN 神经网络模型和 2DCNN 模型对比,从模型训练能力、训练精度、泛化能力、运行开销 4 个角度分析了所提方法具有较强映射表达性能、高识别精度、少迭代次数以及短运行时长的优点。本文所提方法训练迭代 5 次即可达到 98.33% 的高识别精度,对高压断路器故障的精准检测、精准检修、保证电力系统的稳定运行具有重要意义。

## 参考文献

- [1] 孙曙光,张伟,王景芹,等.基于动作过程振动检测的低压断路器机械寿命预测[J].仪器仪表学报,2020,41(12):146-157.
- [2] 万书亭,豆龙江,刘荣海,等.基于 EWT 和多尺度熵的

- 高压断路器故障诊断[J].振动.测试与诊断,2018,38(4):672-678,867.
- [3] 田书,康智慧.基于改进变分模态分解和SVM的断路器机械故障振动分析[J].振动与冲击,2019,38(23):90-95.
- [4] 肖洁,黎敬涛,邓超,等.基于ITD与LLTSA的轴承故障诊断方法[J].电子测量技术,2020,43(8):183-188.
- [5] JI T, YI L, TANG W, et al. Multi-mapping fault diagnosis of high voltage circuit breaker based on mathematical morphology and wavelet entropy [J]. CSEE Journal of Powerand Energy Systems, 2019, 5(1): 130-138.
- [6] 赵书涛,马莉,朱继鹏,等.基于CEEMDAN样本熵与FWA-SVM的高压断路器机械故障诊断[J].电力自动化设备,2020,40(3):181-186.
- [7] CAO C, LIU M, LI B, et al. Mechanical fault diagnosis of high voltage circuit breakers utilizing VMD based on improved time segment energy entropy and a new hybrid classifier[J]. IEEE Access, 2020, 8: 177767-177781.
- [8] 孟晓承,韩学山,许易经,等.SF<sub>6</sub>高压断路器机械故障概率的非精确条件估计[J].电工技术学报,2019,34(4):693-702.
- [9] ZHAO S, WANG E. Fault diagnosis of circuit breaker energy storage mechanism based on current-vibration entropy weight characteristic and grey wolf optimization-support vector machine [J]. IEEE Access, 2019, 7: 86798-86809.
- [10] 万书亭,马晓棣,陈磊,等.基于振动信号短时能熵比与DTW的高压断路器状态评估及故障诊断[J].高电压技术,2020,46(12):4249-4257.
- [11] MA S, CHEN M, WU J, et al. High-voltage circuit breaker fault diagnosis using a hybrid feature transformation approachbased on random forest and stacked autoencoder [J]. IEEE Transactions on Industrial Electronics, 2018, 66(12): 9777-9788.
- [12] 鄢仁武,林穿,高硕勋,等.基于小波时频图和卷积神经网络的断路器故障诊断分析[J].振动与冲击,2020,39(10): 198-205.
- [13] 曹宇鹏,罗林,王乔,等.基于卷积深度网络的高压真空断路器机械故障诊断方法[J].电力系统保护与控制,2021,49(3):39-47.
- [14] JIANG Y, TANG C, ZHANG X, et al. A novel rolling bearingdefect detection method based on bispectrum analysis andcloud model-improved EEMD [J]. IEEE Access, 2020, 8: 24323-24333.
- [15] RAWAT W, WANG Z. Deep convolutional neural networks forimage classification: A comprehensive review[J]. Neuralcomputation, 2017, 29(9): 2352-2449.
- [16] CHEN H, HU G, LEI Z, et al. Attention-based two-stream convolutional networks for face spoofing detection [J]. IEEE Transactions on Information Forensics and Security, 2019, 15: 578-593.
- [17] CHEN S, WU N, XIAO J, et al. Expulsion identification in resistance spot welding by electrode force sensing based on wavelet decomposition with multi-indexes and BP neural networks [J]. Applied Sciences, 2019, 9(19): 4028.
- [18] HUANG S, TANG J, DAI J, et al. Signal status recognition based on 1DCNN and its feature extraction mechanism analysis[J]. Sensors, 2019, 19(9): 2018.
- [19] PENG X, ZHANG B, GAO D. Research on fault diagnosis method of rolling bearing based on 2DCNN [C]. 2020 Chinese Control And Decision Conference (CCDC), IEEE, 2020: 693-697.
- [20] XUE F, ZHANG W, XUE F, et al. A novel intelligent fault diagnosis method of rolling bearing based on two-stream feature fusion convolutional neural network[J]. Measurement, 2021, 176: 109226.

### 作者简介

林穿,博士研究生,主要研究方向为电力设备故障诊断、人工智能与电力大数据分析。

E-mail:492456598@qq.com

徐启峰(通信作者),教授,博士研究生导师,主要研究方向为电力系统测量新技术。

E-mail:ranger123098@163.com