

基于卷积自编码神经网络的航空发动机轴承故障诊断方法研究

肖娜, 周孟申

(中航西安飞机工业集团股份有限公司, 西安 710089)

摘要: 航空发动机轴承早期故障多是由于裂纹、疲劳剥落和保持架损坏造成的, 这类型的故障在发动机振动信号中均会产生瞬时的冲击; 但是, 在早期故障中, 振动信号由于夹杂过多部件耦合激励, 缺陷冲击信号很难辨识, 早期故障诊断十分困难; 采用了基于卷积自编码网络的航空发动机轴承早期冲击故障特征提取方法, 通过分析信号中冲击成分的周期性, 利用卷积自编码网络的平移不变学习特性, 自动捕获信号中的周期成分, 将信号分解为由卷积核重构的多个特征分量, 实现信号特征分量的自学习, 考虑到峭度指标对信号冲击成分描述的特点, 使用峭度指标作为最优特征分量的选取指标, 进而实现早期冲击故障特征的提取; 最后利用仿真数据和轴承数据验证了该方法的有效性。

关键词: 航空发动机; 轴承; 卷积自编码; 早期故障; 特征提取

Research on Aero-engine Bearing Fault Diagnosis Method Based on Convolutional Auto-encoding Neural Network

XIAO Na, ZHOU Mengshen

(AVIC Xi'an Aircraft Industry Group Co., Ltd., Xi'an 710089, China)

Abstract: Early failures of aero-engine bearings are mostly caused by cracks, fatigue spalling and cage damage. These types of failures will produce instantaneous shocks in engine vibration signals. However, in the early faults, the vibration signal is excited by the coupling of too many components, and the defect impact signal is difficult to identify, and the early fault diagnosis is very difficult. This paper proposes a feature extraction method for early impact faults of aero-engine bearings based on convolutional self-encoding networks. By analyzing the periodicity of the impact components in the signal, using the translation invariant learning characteristics of the convolutional autoencoding network, the periodic components in the signal are automatically captured, and the signal is decomposed into multiple characteristic components reconstructed by the convolution kernel to realize the signal characteristics. The self-learning of the components takes into account the characteristics of the kurtosis index describing the impact components of the signal, and the kurtosis index is used as the selection index of the optimal feature components to realize the extraction of early impact fault features. Finally, simulation data and bearing data are used to verify the effectiveness of the method.

Keywords: aero-engine; bearing; convolutional autoencoding; early failure; feature extraction

0 引言

在现代飞行器中, 以航空发动机为中心构成的能源动力系统是飞行器的“心脏”, 航空发动机运行状态直接影响整个飞行器的安全和经济效益^[1]。其中, 航空发动机主要由进气风扇、压气机、涡轮等高速旋转机构组成, 各个机构间又通过主轴连接^[2], 高速主轴和低速主轴主要通过轴承进行支撑^[3]。作为传动部件的航空发动机轴承运行转速高, 一旦发生故障将会直接影响主轴运行平稳, 进而损坏叶片造成严重事故^[4]。据美军报道, 轴承失效是引发美军军用和商用发动机空中停车和非计划内换发的主导因素之一, 高速滚动轴承(滚子或滚珠)占到了故障失效原因的近90%^[5]。主轴振动监测及故障诊断技术是先进高性能

发动机健康管理技术的关键技术之一^[6], 轴承的寿命受环境影响巨大, 疲劳延伸程度受载荷、速度、材料、状态、接触区域活动、接触集合形状以及润滑剂的类型和状态等的影响^[7]。轴承在出现早期故障时往往对发动机整机性能影响不大, 但是轴承早期故障劣化速度非常快, 将会引发发动机其它部件受损进而严重影响发动机性能, 造成空中停车的严重故障^[8]。因此研究航空发动机轴承早期故障诊断技术, 阻止故障进一步劣化, 是保证航空发动机健康运行, 保证飞行安全的有效途径。

由于航空发动机的复杂程度不断提高, 加上目前缺乏直接测量航空发动机轴承振动信号的手段, 多采集发动机机匣振动信号进行分析^[9], 导致得到的发动机振动信号中

收稿日期: 2021-08-06; 修回日期: 2021-09-06。

作者简介: 肖娜(1991-), 女, 河南开封人, 硕士, 工程师, 主要从事飞机动力装置设计及故障诊断技术方向的研究。

引用格式: 肖娜, 周孟申. 基于卷积自编码神经网络的航空发动机轴承故障诊断方法研究[J]. 计算机测量与控制, 2021, 29(12): 84-88, 119.

含有较多激励成分, 信号信噪比低^[10]。而航空发动机轴承早期故障引起的冲击信号幅值分量很小, 极易淹没在背景噪声当中^[11]。提取出故障特征是航空发动机轴承故障诊断的关键所在, 而故障特征往往会被噪声等干扰信息所淹没, 导致其难以被人们及时发现。因此, 早期故障特征的有效提取具有重大的现实意义^[12]。随着故障诊断技术的发展, 目前已有的故障特征提取方法不能满足航空发动机轴承故障诊断特征提取的需求, 例如, 傅里叶变换本质上是在时间内的平均, 因此无法描述非平稳信息^[13]; 小波变换增加了时域信息, 但小波基的不同直接影响了提取效果, 并且缺乏几何上的直观解释^[14]; 等等。因此, 需要发展新的特征提取方法, 以提高故障诊断的可靠性。

近几年来, 深度学习理论在图像识别、语音处理等领域得到了成功的应用, 其为基于数据本身的特征学习提供了一种新的研究途径, 深度学习的基本思想是通过构造多层神经网络使得输入数据的特征能够被逐层提取出来, 从而在高层神经元处得到数据的抽象特征, 实现数据中本质特征的提取。这就意味着深度学习理论具有对数据本质信息的高度表征和提取能力, 且具有很好的自适应性, 同时也为基础部件的故障诊断提供了新的途径^[15]。比如 Ciresan 使用卷积神经网络实现了 0.27% 的低错误率; 在自然图像的研究应用中, Krizhevsky 在 ImageNet 数据集上通过采用深度卷积网络实现了识别率的提高^[16]。Y. G. Lei 等人提出基于深度学习理论的机械装备大数据健康监测方法, 利用机械频域信号训练深度神经网络, 实现了故障特征的自适应提取与健康状况的智能诊断^[17]。

为了解决航空发动机轴承早期故障特征不明显以及故障诊断困难的问题, 本文提出了基于卷积自编码神经网络的航空发动机轴承故障特征提取方法, 从而为航空发动机轴承进一步进行故障诊断提供有力支持。

1 卷积自编码神经网络

1.1 卷积神经网络模型

卷积神经网络 (CNN, convolutional neural network) 目前在图像处理方面得到了广泛的应用, 通过对其训练学习, 卷积神经网络能够从二维图像中自动提取出图像特征^[18]。

分许卷积神经网络的架构可知, 该网络由三部分组成: 卷积层、池化层和分类层。图 1 以图像“3”为例来具体说明卷积神经网络的工作过程: 其中, 图像“3”是网络的输入层, 输入维度为 32×32 ; 中间部分为特征提取层, 该层的目的是通过不断地卷积和池化来提取出图像不同的特征, 需要注意的是, 这些提取出来的特征都具有局部性, 即反映输入图像的某些局部特征, 而池化层的作用在于降维, 在保留有用特征的同时剔除出图像的重复性特征^[19]; 分类层的作用是输出图像的类型标签, 该层利用中间层提取出的特征向量辨别出输入图像的所属类别。

综上所述, 卷积神经网络通过对输入图像经过一系列的卷积和池化操作, 提取出图像的特征向量, 并最终实现

分类。

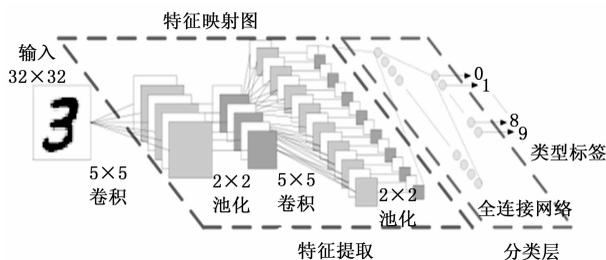


图 1 卷积神经网络架构示意图

1.2 卷积自编码网络模型

由卷积神经网络的组成架构可知, 卷积层可以提取出输入图像的局部特征, 而自编码神经网络能够通过编码层和解码层重构输出数据。卷积自编码神经网络 (CAE, convolutional auto-encoder) 则是综合了卷积神经网络和自编码神经网络两者的特点, 其通过卷积层和反卷积层可以重构出输入图像^[20], 架构示意图见图 2。其中, 卷积层的作用是提取输入图像的特征, 而反卷积层则利用提取出的特征重构出输入图像。

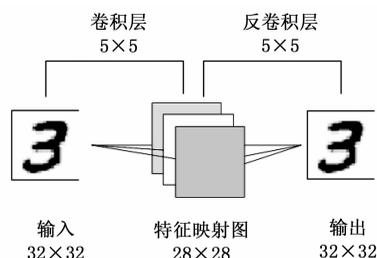


图 2 卷积自编码神经网络架构示意图

由图 2 可以看出, 卷积层和反卷积层的维度均为 5×5 , 即卷积自编码神经网络的训练目的在于使输出等于输入, 故卷积自编码神经网络的训练不具有类型标签, 是一种无监督训练^[21]。

1.3 卷积自编码网络的学习特性

由 2.2 节对卷积自编码网络的架构分析可知, 卷积层维度小于输入层维度, 且卷积层的神经元与输入层的神经元并不是全连接的, 具有局部连接的特点, 如图 3 所示, 神经元 S_2 并不是与 X_1, X_2, X_3, X_4, X_5 五个神经元都相连, 而是与部分输入神经元相连。卷积自编码网络的这种连接方式决定了卷积层主要用来学习输入数据的局部特征。

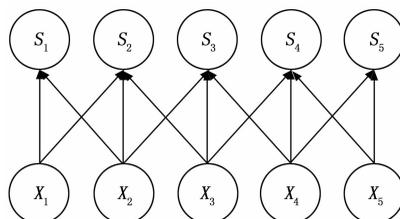


图 3 局部连接结构示意图

同时, 卷积自编码网络的卷积层与输入层不同位置的

神经元都会进行卷积操作，以图 4 为例，卷积层神经元（卷积核）会与输入层不同处 5×5 区域内的神经元进行卷积操作，卷积操作具有共享权值的特点，即卷积操作对应的卷积核权值参数均相同。这可以理解为卷积核在输入数据中移动，以此提取出输入数据的不同特征，获得一系列的特征向量。而共享权值的特性使得卷积自编码网络有利于提取出输入数据的重复性特征，这种重复性特征具有平移不变的特点。

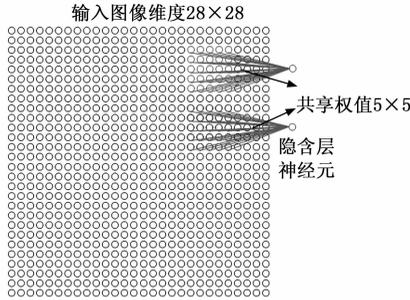


图 4 权值共享示意图

2 航空发动机轴承振动信号故障特征提取方法

2.1 发动机轴承振动信号的故障特性分析

由理论分析可知，当滚动轴承表面出现局部缺陷时，如剥落、点蚀等，在运行时，会以一定的通过频率产生脉冲激励，将激发机械系统的固有振动，产生一系列的冲击衰减响应。这些冲击成分中含有大量的振动信息，如冲击力的大小、冲击脉冲出现的频率等参数，是故障性质及程度判断的重要依据。

通常机械系统的冲击响应可表示为负指数函数与正弦函数的乘积，其表达式为：

$$\xi = A(t) \sin(\omega t + \varphi) \quad (1)$$

式中， $A(t) = \xi_0 e^{-\delta t}$ 为冲击信号的振幅。

图 5 为模拟冲击响应信号，图 5 (a) 中 $\delta_1 = 10$ ，图 5 (b) 中 $\delta_2 = 15$ ，其他参数相同： $\xi_0 = 1, \omega = 100, \varphi = 0$ 。图 5 可以看出，冲击信号具有振动衰减的特点，其振幅随时间指数衰减，且衰减系数 δ 越大，振幅衰减地越快。

2.2 轴承振动信号故障特征的提取

航空发动机轴承故障主要体现在振动信号的冲击成分上，冲击成分在轴承振动信号上具有周期重复性的特点，同时，在时域信号上，相邻较近的采样点之间的相关性比相距较远的采样点之间的相关性强。因此卷积自编码网络的平移不变学习特性为冲击特征的提取提供了一个解决方向：轴承振动信号中的冲击成分具有周期性重复出现的规律，而卷积自编码网络具有平移不变学习特性，因此可以利用振动信号训练卷积自编码网络，使其自动捕捉信号中的周期性成分，从而实现冲击故障特征的提取。

图 6 显示了卷积自编码网络对故障信号的特征学习过程，通过设置卷积核的维度，使卷积自编码网络在信号的局部数据点上特征学习与挖掘，从而提取出信号中的

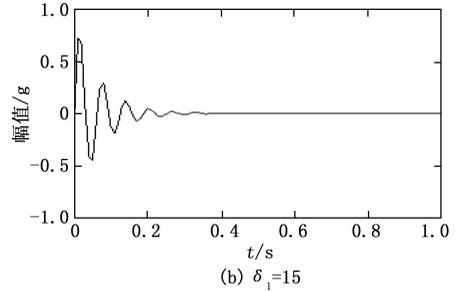
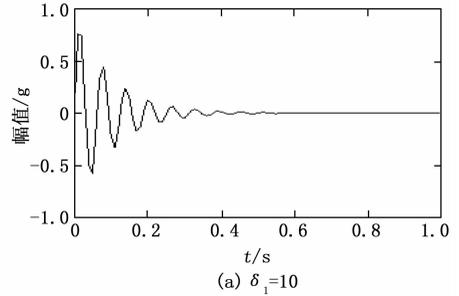


图 5 模拟冲击信号

瞬态冲击成分。

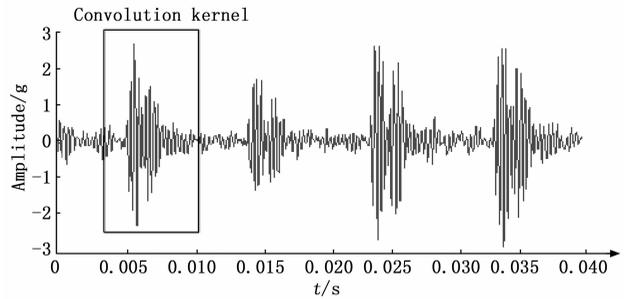


图 6 冲击故障特征的提取过程表示

2.3 信号特征分量的自学习过程

利用卷积自编码神经网络的学习特性来处理信号，即为通过对卷积自编码神经网络的训练，使得其提取出输入信号的一系列特征分量。具体来说，就是利用不同的卷积核输入信号进行卷积操作和反卷积操作，从而在输出层获得一系列重构出的信号分量，这些重构出的信号分量即为提取出的特征分量。

由于机械信号不同于二维图像，卷积自编码网络不能直接用来处理机械信号，需要对卷积自编码网络的卷积操作及反卷积操作进行一定的变换处理。以图 7 的振动信号为例，需要对原始信号进行截断，即构造出维度为 1000×1 的输入信号。卷积自编码网络对输入信号的自学习过程为：通过维度为 100×1 的卷积核与输入信号进行卷积操作，获得特征映射向量；再通过维度为 100×1 的反卷积核，在输出层获得重构出的信号分量。其中，图中@3 表示卷积自编码网络共有 3 个卷积核。

在图 7 所示的网络架构中，对于给定的输入向量 x ，当采用的激活函数为 \tanh 时，网络的输出表达式为：

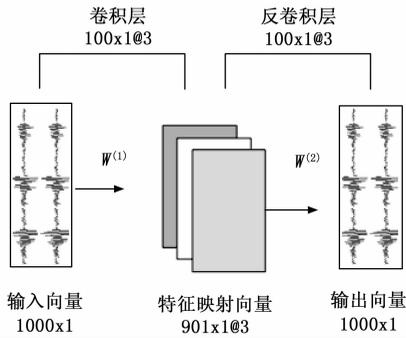


图 7 面向振动信号的卷积自编码网络架构示意图

$$\hat{x} = \tanh\left(\sum_{k=1}^2 h_k * W_k^{(2)} + b^{(2)}\right) \quad (2)$$

式中, $W^{(2)}$ 为卷积核的参数, 即为共享的权值参数; h_k 为隐含层神经元的激活值; $b^{(2)}$ 为卷积核对应的偏置。由 \tanh 的性质和分块矩阵运算法则可推导:

$$\hat{x} = \tanh\left(\sum_{k=1}^2 h_k * W_k^{(2)} + b^{(2)}\right) \approx \tanh(h_1 * W_1^{(2)} + h_2 * W_2^{(2)}) \quad (3)$$

式中, $W_i^{(2)} = [W_{1i}^{(2)} W_{2i}^{(2)} W_{3i}^{(2)}]^T$ 每个卷积核与输出层神经元之间的连接权值。由激活函数满足:

$$\tanh(a + b) = \frac{\tanh(a) + \tanh(b)}{1 + \tanh(ab)} \quad (4)$$

当 $|ab| < 1$ 有:

$$\hat{x} \approx \tanh(h_1 * W_1^{(2)}) + \tanh(h_2 * W_2^{(2)}) + \tanh(h_3 * W_3^{(2)}) = I_1 + I_2 + I_3 \quad (5)$$

式中, $I_i = \tanh(h_i * W_i^{(2)})$ 由式(5)可以看出, 卷积自编码网络的输出可以看作不同分量 I_i 的叠加。故针对输入信号, 卷积自编码网络能够通过训练学习, 获得原始信号的不同特征分量, 这些特征分量实质上都是卷积核 $W_i^{(2)}$ 与激活值向量 h_i 的卷积。即卷积自编码网络通过对输入信号的不断重构, 实现了对输入信号的不断学习, 并在不断学习的过程中对信号进行了分解, 获得了包含信号特征信息的不同的特征分量。

2.4 最优特征分量的选择

经过卷积自编码网络的自学习过程, 可以通过式 5 得到一组信号特征分量 I_i , 每组特征分量都包含着原始信号的某种特征信息。在故障诊断中, 故障特征的有效提取是诊断分析的前提, 因此需要从特征分量集合中筛选出最优特征分量, 以达到故障特征提取的目的。由于每组特征分量的数据长度与原始信号的数据长度相同, 因此可以利用特征分量之间统计指标差异性进行最优特征分量的定量选取。

当轴承在运行过程中发生故障时, 其运行状态的变化会对采集的机械信号产生影响, 对于轴承和齿轮的振动信号来说, 冲击成分是主要的故障特征, 而峭度指标是四阶中心矩和标准差的四次方的比值, 能够反映信号波形中冲击分量的大小, 它表示信号概率密度函数峰顶的陡峭程度。正常运行阶段下轴承的峭度指标值约为 3, 随着故障的出现及加重, 信号的峭度指标值呈现出增大的趋势。因此, 对

于包含冲击故障特征的特征分量, 其峭度指标往往具有较大的值, 而其他特征分量则没有, 故针对最优特征分量的选取问题, 这里选择峭度指标作为选择指标, 其计算公式如下:

$$K = \frac{\beta}{\sigma_x^4} \quad (6)$$

式中, K 为峭度, $\beta = \frac{1}{T} \int_0^T [x(t) - u_x]^4$, σ_x 为标准差。

2.5 基于卷积自编码网络的冲击故障特征提取方法

结合瞬态冲击成分的特性及卷积自编码网络的学习特性, 本文提出基于卷积自编码网络的航空发动机轴承故障特征提取方法。该方法的基本思想是通过设置多个局部化的卷积核, 利用卷积自编码网络的平移不变学习特性, 自动捕捉信号中的周期性成分, 将信号分解为由卷积核重构的多个特征分量, 并利用峭度指标选取最优特征分量, 进而实现冲击故障特征的提取。

本方法的流程如图 8 所示。该方法首先对原始信号进行数据预处理, 以构造足够的训练数据集, 提高网络的训练效果; 然后设置卷积核的维度和个数, 将训练数据输入到卷积自编码网络模型中进行训练, 获得信号的多个特征分量; 最后计算每个特征分量的峭度指标值, 选取峭度指标值最大的特征分量, 完成最优特征分量的选取, 进而提取出冲击故障特征。

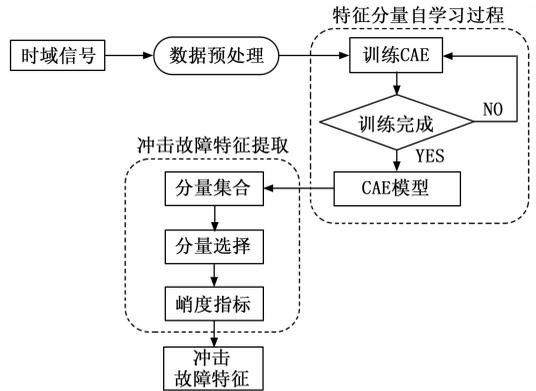


图 8 冲击故障特征提取方法

3 实验分析

3.1 实验数据来源及说明

为了进一步验证本文所提方法对冲击故障提取的有效性, 本节采用航空发动机滚动轴承的滚动体故障数据进行分析。选取数据的轴承故障尺寸为 0.007 英寸, 转速为 1 732 rpm, 其中采样频率为 12 000 Hz。选取轴承的结构参数和故障频率参数如表 1、表 2 所示, 其中, f_c 为保持架故障频率, f_o 为外圈故障频率, fI 为内圈故障频率, fB 为滚动体故障频率。

表 1 选取轴承的结构参数

结构参数	滚珠个数	轴承外径/cm	轴承内径/cm	内外环厚度/cm	滚珠直径/cm	节圆直径/cm
	9	5.2	7.15	1.5	0.84	3.9

表 2 选取轴承的故障频率参数运行频

运行频率参数	f_c/Hz	f_o/Hz	f_l/Hz	f_B/Hz
	11	88	142	115

图 9 为故障轴承原始信号的时域波形图，由图中可以看出，由于滚动体故障信号往往调制了转速信息，使得信号成分更为复杂，导致原始信号中的冲击成分不是很明显，需要对其进行处理才能辨识其故障类型，下面采用本文所提方法对原始信号进行冲击信息的提取。

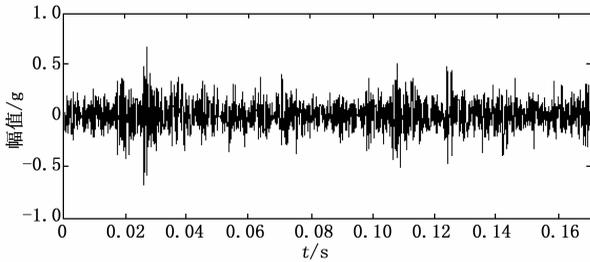


图 9 原始信号时域波形图

3.2 实验结果与分析

构造维度为 2048×1 的训练样本，并设置卷积核的个数为 5，维度为 75×1 ，然后将训练样本输入到网络模型中进行训练，训练结束后可得到网络权值参数（即卷积核）及提取的特征分量，如图 10、图 11 所示。

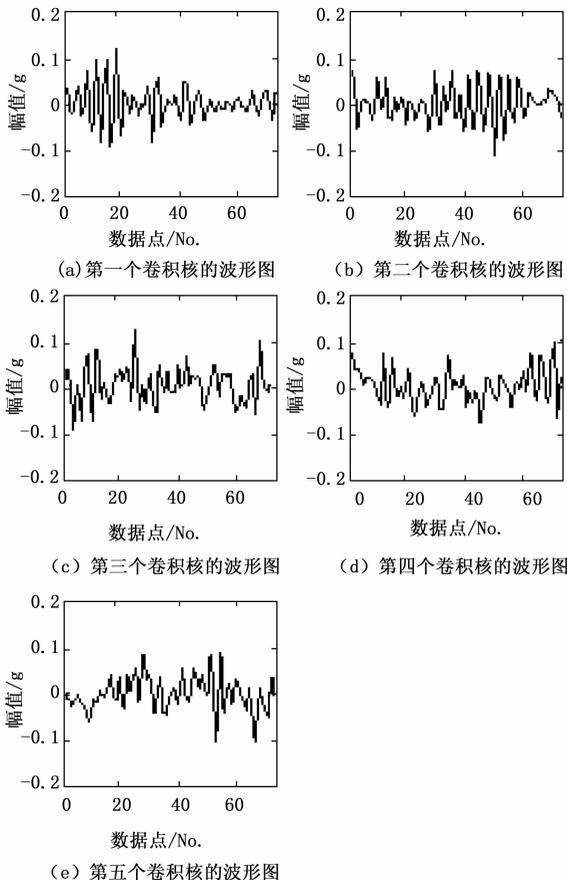


图 10 卷积核波形图

从图 10 可以发现，与其他卷积核相比，第一个卷积核的波形与瞬态冲击波形较为相似。为了分析该卷积核是否捕捉到了冲击故障特征，按照式 5 计算得到每个卷积核对应的特征分量，如图 11 所示。

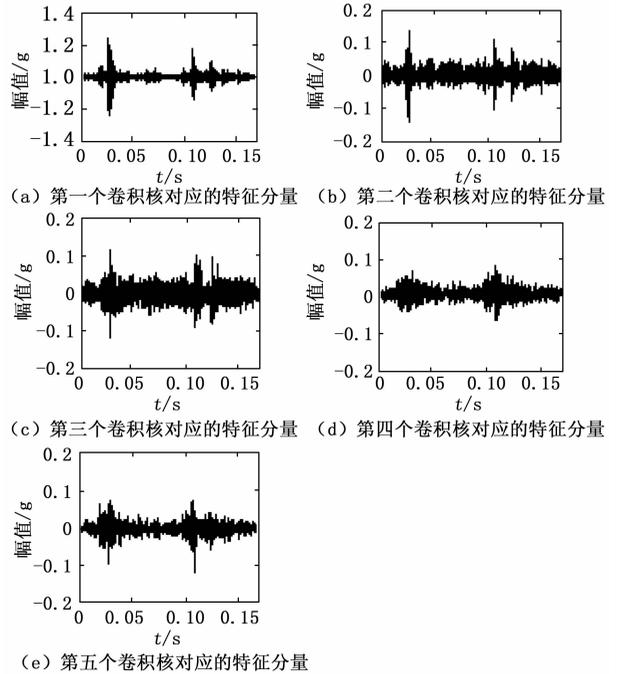


图 11 卷积核对应特征分量的波形图

从图 11 可以看出，第一个、第二个、第三个卷积核对应的特征分量均呈现出一定的冲击特征，其中第一个卷积核对应的特征分量尤为明显。

为了定量选出最优特征分量，按照公式 (6) 计算出每个特征分量的峭度指标值，如表 3 所示。

表 3 峭度指标统计表

特征分量	分量 1	分量 2	分量 3	分量 4	分量 5
峭度指标值	18.47	6.60	4.32	4.48	7.86

从表 3 的结果可知，第一个卷积核对应的特征分量具有最大的峭度指标值，此特征分量波形图中的瞬态冲击成分也较为明显，因此第一个卷积核对应的特征分量为最优特征分量。

为判定最优特征分量中冲击成分的来源，并以此确定故障源，对其进行包络谱分析，如图 12 所示，从图中可以看出，谱峰较高的频率分量为选取轴承的保持架频率 f_c 和滚动体故障特征频率 f_B ，据此可判定轴承存在滚动体故障。

4 结束语

针对航空发动机轴承故障特征提取的问题，在研究卷积自编码网络的基础上，构建了面向振动信号的卷积自编码网络模型，利用卷积自编码网络的平移不变学习特性，提出了基于卷积自编码网络的冲击故障特征提取方法，实现

(下转第 119 页)