

基于 GLCM-SDAE 的滚动轴承故障诊断方法

须颖^{1,2}, 李昊东³, 安冬⁴

(1. 沈阳建筑大学微纳检测与运动控制研究院, 辽宁 沈阳 110168; 2. 广东工业大学机电工程学院, 广东 广州 510006; 3. 沈阳建筑大学机械工程学院, 辽宁 沈阳 110168;
4. 沈阳建筑大学分析与检测技术研究中心, 辽宁 沈阳 110168)

摘要 目的 针对传统信号分析方法在滚动轴承故障特征提取和故障分类等方面的不足, 结合堆栈去噪自编码(Stacked De-noising Auto-Encoders, SDAE)算法在提取特征和特征分类等方面的优势, 提出一种基于灰度共生矩阵(Grey-Level Co-occurrence Matrix, GLCM)和 SDAE 的滚动轴承智能故障诊断方法. 方法 首先通过短时傅里叶变换(Short-Time Fourier Transform, STFT)将滚动轴承振动信号转化为灰度时频图, 然后利用灰度共生矩阵提取灰度时频图中的故障特征参数, 构建滚动轴承故障类别的特征向量空间, 最后将其输入到构建的 SDAE 网络模型中, 以实现滚动轴承的智能故障诊断. 结果 在轴承数据集上进行了故障特征提取和故障类型识别实验, 结果表明笔者所提方法在训练集和测试集上平均分类精度均达到了95%以上. 结论 相较于从原始信号中提取特征的支持向量机(Support Vector Machine, SVM)、深度信念网络(Deep Belief Network, DBN)等方法, 笔者所提出的方法能够提高故障识别率, 可有效地对滚动轴承故障状态进行智能诊断.

关键词 故障诊断; 短时傅里叶变换; 灰度共生矩阵; SDAE

中图分类号 TU391

文献标志码 A

Fault Diagnosis of Rolling Bearing Based on GLCM-SDAE

XU Ying^{1,2}, LI Haodong³, AN Dong⁴

(1. Research Institute for Micronano Detection and Motion Control, Shenyang Jianzhu University, Shenyang, China, 110168; 2. School of Electro-mechanical Engineering, Guangdong University of Technology, Guangzhou, China, 510006; 3. School of Mechanical Engineering, Shenyang Jianzhu University, Shenyang, China, 110168; 4. Research Center for Analysis and Detection Technology, Shenyang Jianzhu University, Shenyang, China, 110168)

Abstract: Aiming at the shortcomings of traditional signal analysis methods in rolling bearing fault

收稿日期: 2019-01-03

基金项目: 国家重点研发计划项目(2017YFC0703903); 辽宁省科学技术基金项目(20180550002); 辽宁省高等学校基本科研项目(LJZ2017035); 辽宁省重点研发计划项目(2017225016)

作者简介: 须颖(1959—), 男, 教授, 主要从事精密运动控制方面研究.

feature extraction and fault classification, combining the advantages of stack de-noising auto-encoders (SDAE) algorithm in feature extraction and feature classification, a rolling bearing intelligent fault diagnosis method based on grey-level co-occurrence matrix (GLCM) and stacked de-noising auto-encoders (SDAE) was proposed. Firstly, the gray-scale time-frequency diagram of the rolling bearing is obtained by short-time Fourier transform (STFT). Then, the gray scale co-occurrence matrix is used to extract the fault feature parameters in the gray scale time-frequency diagram, and the feature vector space of rolling bearing fault categories is constructed. Finally, it is input into the SDAE network model to realize intelligent fault diagnosis of rolling bearings. The fault feature extraction and fault type identification experiments were carried out on the bearing data set. Experimental results show that the method described in this paper achieves an average classification accuracy of more than 95% in both training set and test set, and is significantly superior to support vector machine (SVM) and deep belief network (DBN) in fault recognition rate. It is proved that the method proposed in this paper can effectively diagnose the fault state of rolling bearing intelligently.

Key words: fault diagnosis; short-time Fourier transform; gray scale symbiosis matrix; SDAE

滚动轴承作为机械系统中常用的零部件,用于在轴间传递能量,在机械传动系统中起着至关重要的作用。一旦轴承在工作过程中发生故障,可能引起机器系统的致命缺陷,从而导致重大的经济损失和人员伤亡,因此,对滚动轴承故障进行有效地诊断,尽早准确地发现这些故障的存在对机械系统的正常运转具有重要意义^[1-3]。故障诊断作为一种多方法融合的模式识别过程,其主要过程包括原始振动信号采集和信号预处理、故障信号特征提取和故障类型识别等步骤,其中故障特征提取是其中的一步关键步骤,故障特征的易识别程度将直接影响后续的认可精度。振动信号作为最能反映机械设备运转状态的信号源,基于振动信号的相关特征提取的故障诊断方法成为目前滚动轴承故障诊断的主要研究方向。H. H. Bafroui 等^[4]利用离散小波变换提取了转子故障特征。Wang Yanxue 等^[5]利用经验模态分解法和能量算子解调方法提取出轴承振动信号的特征,并使用模式识别方法对其进行诊断,使得故障识别率有了明显的提高;俞啸等^[6]建立了基于 HHT 和有监督稀疏编码 (Supervised Sparse Coding, SSC) 的振动信号特征提取模型,并将提取到的故障特征输入到支持向量基

(Support Vector Machine, SVM) 中,实验数据证明该方法故障识别率达到了 98% 以上。但是随着机械设备规模的不断扩大、机械内部结构变得极其复杂,上述传统信号处理技术在大规模数据中提取故障特征变得越来越困难,针对这一问题,如何在庞大的数据集中提取敏感的故障统计特征,为后续故障分析提供保障,得到了越来越多的研究者的重视和研究^[7]。

随着图像处理和深度学习技术的快速发展,学者们相继利用深度学习强大的数据挖掘能力在振动信号的图谱纹理和形状上提出一些基于图像视觉特征智能故障诊断方法。袁建虎等^[8]通过对振动信号进行连续小波变换得到时频图,并将压缩后的时频图输入到卷积神经网络 (CNN) 中,从而实现了滚动轴承的智能诊断;D. Verstraete 等^[9]将一种新颖的 CNN 结构应用于滚动轴承故障分类与诊断中原始振动信号的时频和图像表示,实验结果表明该方法对实验噪声具有较强的鲁棒性。尽管图像分析技术在故障诊断领域取得了一定成果,但仍存在稳定性差和识别效率低等问题,尤其是在面临大数据情况下,如何在高维图像中提取故障特征成为目前亟待解决的问题^[10]。

灰度共生矩阵是一种能够有效提取图像纹理特征的分析方法,被广泛应用到图像分析领域^[11],笔者在综合当前图像分析技术和深度学习技术在故障诊断领域的研究现状,提出一种基于 GLCM-SDAE 的滚动轴承智能故障诊断方法,通过短时傅里叶变换和灰度共生矩阵实现了原始振动信号二维时频图的构建和故障特征提取,进而构造出故障特征向量空间;最后,针对构造出的特征向量空间设计 SDAE 深度神经网络,从而实现滚动轴承的智能故障诊断。

1 滚动轴承智能故障诊断方法

基于 GLCM-SDAE 的滚动轴承智能故障诊断方法的研究思路如下:

(1)通过信号采集系统从滚动轴承试验台采集轴承在不同负载、不同转速下的实验数据,将采集到的数据进行样本分割从而构造出轴承状态样本集。

(2)对构造的轴承状态样本集中的信号样本进行 STFT 生成轴承信号时频图,并转化为合适大小的灰度图,从而组成轴承故障特征样本图集。

(3)按照 7/3 的分样比例将特征图样本集划分为训练集和测试集,利用灰度共生矩阵提取训练集和测试集的图像特征,将每张图片转化成一个 16 维的故障特征向量空间。

(4)构建 SDAE 网络模型,将训练集样本空间输入到网络模型中,采用反向传播算法更新网络参数,并采用“dropout”方法训练网络模型,防止出现过拟合。

(5)将测试集输入到步骤(4)中已经训练好的网络模型,从而实现滚动轴承故障的智能诊断识别。

笔者所提方法的技术路线如图 1 所示。

1.1 灰度共生矩阵

灰度共生矩阵是 20 世纪 70 年代初由 R. Haralick 等^[12]提出的一种图像分析方法,它反映了图像在方向、间隔和变化幅度快慢

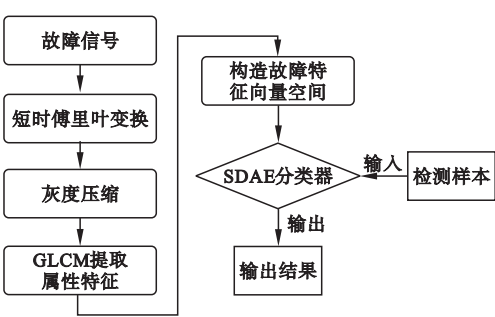


图 1 技术路线图

Fig. 1 Technical roadmap

的综合信息,具有较强的图像表征能力^[13]。

灰度共生矩阵可以定义为:一副大小为 $M \times N$ 的图像 $f(x,y)$ 中存在一组灰度值记为 (i,j) ,其中灰度值为 i 的像素点坐标记为 (x_0,y_0) ,灰度值为 j 的像素点坐标记为 $(x_0 + \Delta x,y_0 + \Delta y)$,当 $\Delta x,\Delta y$ 为确定值时,使点 (x_0,y_0) 依次遍历图像上的每一个位置,则灰度值对 (i,j) 就会有不同的组合,如果一副图像的灰度级为 H ,则可知这些灰度对组合有 H^2 种. 设定一个 $H \times H$ 方阵,灰度对 (i,j) 在图像中出现的次数作为方阵中每个元素坐标 (m,n) ,由此形成了能够刻画图像像素之间关系的进而表示图像纹理特征的灰度共矩阵 $P(i,j,d,\theta)$,其数学表达式可以定义为

$$P(i,j,d,\theta) = \{ (x_0,y_0), (x_0 + \Delta x, y_0 + \Delta y) \in M \times N | f(x_0,y_0) = i, f(x_0 + \Delta x,y_0 + \Delta y) = j \}. \tag{1}$$

其中, d 表示两灰度对之间的距离; θ 表示两灰度对之间所成的角度,常用的角度有 $0^\circ, 45^\circ, 90^\circ, 135^\circ$; P 表示两个距离为 d 的灰度值为 i 和灰度值为 j 的像素点出现的次数,例如: $P(1,2,5)$ 表示距离为 5 的两个灰度分别为 1 和 2 的像素点出现的次数。

由于灰度共生矩阵的数据量较大,直接计算起来过于困难,因此通常基于灰度共生矩阵建立一些统计量作为区分图像的分类特征. R. M. Haralick^[14] 曾经提出 14 种基于灰度共生矩阵的计算出来的统计量,但是在实际应用过程中,这些统计量并不都能反映图

像特征,因此笔者选取表征能力强且互不相关的对比度、相关性、能量、同质性作为灰度共生矩阵的特征集^[15]。

对比度可以用来描述图像的清晰度,能够反映图像中局部灰度变化总和,其表达式为

$$CON = \sum_i \sum_j (i - j)^2 p(i, j). \quad (2)$$

相关性能够反映图像中一个在其另一个方向的延伸情况,通常用来反映了图像中局部灰度相关性,其表达式为

$$CORRE = \frac{\sum_i \sum_j ij p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}. \quad (3)$$

其中, $\mu_x = \sum_i i \sum_j p(i, j)$;

$$\mu_y = \sum_j j \sum_i p(i, j);$$

$$\sigma_x = \sum_i (i - \mu_x)^2 \sum_j p(i, j);$$

$$\sigma_y = \sum_j (j - \mu_y)^2 \sum_i p(i, j).$$

能量用来描述图像中灰度值分布的均匀情况和图像中纹理粗细的变换情况,其表达式为

$$ASE = \sum_i \sum_j [p(i, j)]^2. \quad (4)$$

同质性反映图像纹理的局部变换情况,其表达式为

$$IDM = \sum_i \sum_j \frac{p(i, j)}{1 + (i - j)^2}. \quad (5)$$

选取上述4个特征在4个不同方向(0°, 45°, 90°, 135°)上的灰度共生矩阵组成反映故障时频图像特征的特征向量空间,即每个故障时频图包含16个特征向量,以此作为SDAE网络的输入数据。

1.2 堆栈去噪自编码网络

堆栈式去噪自编码网络是由VINCENT提出的一种深度神经网络^[16],它是由多个去噪自编码器(De-noising Auto-encoders, DAE)层层堆叠起来组成的一种网络模型,相比于堆栈自编码网络,SDAE不但能够有效的对输入数据进行重构,而且通过训练学习到的特征还具有非常强大的泛化能力,因此被越来越多的应用到图像识别、缺陷识别和故障诊断等领域^[17]。

SDAE网络结构如图2所示,每个DAE完成训练后,其输出层输出的数据将作为下一个DAE的输入,这样经过逐层的学习,完成了输入数据特征的表示。DAE的核心思想是令编码器的输入层节点按照给定的比例随机置为零。如图2中,黑色节点表示置零的神经元节点,这样将输入数据人工受损来训练网络,再从受损数据的基础上重构输出数据,从而整体提升编码器的鲁棒性能。利用逐层贪心算法训练每个DAE^[17],在将训练好的DAE堆叠起来就组成了SDAE网络,为了实现模型的故障分类功能,笔者在SDAE网络最后一层加上了Soft-max分类器。




图2 SDAE网络结构

Fig. 2 The network structure of SDAE

SDAE网络在完成预训练后,模型中各隐藏层之间和最后的分类层之间的权重作为网络的初始模型参数,训练过程采用反向传播法更新网络参数^[18],其过程可描述为:设输入的滚动轴承故障样本集为 $X = \{x^i | 1 \leq i \leq N\}$,隐藏层输出向量集为 $H = \{h^i | 1 \leq i \leq N\}$,输出层输出向量集合为 $\hat{X} = \{\hat{x}^i | 1 \leq i \leq N\}$. 其中, N 为故障样本总个数, x^i 为第 i 个故障样本, h^i 表示其所对应的特征向量, \hat{x}^i 表示第 i 个故障样本对应的输出,则每个DAE隐藏层的输出表示为

$$H = f_{(w,b)}(X) = \sigma(WX + b). \quad (6)$$

输出层的输出表示为

$$\hat{X} = g_{(w,b)} = \sigma(W'H + b'). \quad (7)$$

其中, W (输入层与隐藏层之间)、 W' (隐藏层与输出层之间)均表示网络层间的权重矩阵; b (输入层与隐藏层之间)、 b' (隐藏层与输出

层之间)均表示网络层之间的偏置矩阵;表示层间非线性激活函数(选取 sigmoid 函数作为激活函数). 每个 DAE 通过最小化输入向量与输出向量之间的损失函数来不断调整网络参数 $\boldsymbol{W}, \boldsymbol{b}$. 其损失函数可以描述为

$$L(\boldsymbol{x}^i, \hat{\boldsymbol{x}}^i) = \frac{\sum_{i=1}^N \|\boldsymbol{x}^i - \hat{\boldsymbol{x}}^i\|^2}{N}. \tag{8}$$

则网络参数更新公式为

$$\boldsymbol{W} = \boldsymbol{W} - \alpha \frac{\partial L(\boldsymbol{x}^i, \hat{\boldsymbol{x}}^i)}{\partial \boldsymbol{W}}. \tag{9}$$

$$\boldsymbol{b} = \boldsymbol{b} - \alpha \frac{\partial L(\boldsymbol{x}^i, \hat{\boldsymbol{x}}^i)}{\partial \boldsymbol{b}}. \tag{10}$$

式中: α 为网络学习率; $\frac{\partial L(\boldsymbol{x}^i, \hat{\boldsymbol{x}}^i)}{\partial \boldsymbol{b}}$ 表示损失函数对参数 \boldsymbol{W} 求偏导; $\frac{\partial L(\boldsymbol{x}^i, \hat{\boldsymbol{x}}^i)}{\partial \boldsymbol{W}}$ 表示损失函数对 \boldsymbol{b} 求偏导.

2 应用实例

2.1 数据集的构造及描述

为了验证所提出的方法的有效性,笔者

准备了大量样本进行了故障诊断实验. 笔者所采用的数据集来自美国西储大学轴承数据库^[19]. 实验装置如图 3 所示, 主要部件包括主轴电机、扭矩传感器、测功机和负载电机. 采用电火花加工的加工方式对试验轴承进行单点故障处理, 分别在轴承外圈(OR)、轴承内圈(IR)和滚动体(RE)的测试驱动端轴承上制造 0.007 mm、0.014 mm 和 0.021 mm 的单点故障. 数据采样频率为 12 kHz. 实验采集到的原始时域信号图像如图 4 所示. 由图可知, 不同状态下的滚动轴承时域波形有一定区别, 但对于非专业人士来说, 难以实现对轴承故障状态的完全识别.




图3 美国西储大学轴承数据库实验台
Fig. 3 Bearing database test bench of western reserve university




图4 原始信号时域信号图

Fig. 4 Original signal diagrams in time domain

笔者将原始数据集划分为 A、B 和 C 三个数据集, 分别对应 0HP、1HP 和 2HP 三种负载状态, 在 A、B、C 三个数据集中各包含

种故障类别, 每个故障类别包含 100 个样本, 每个样本中数据点个数为 1 024 个. 表 1 是所使用的数据样本列表.

表 1 滚动轴承实验数据集列表

Table 1 Experimental data set of rolling bearing			
故障类别	故障深度/mm	数据集(A/B/C)	故障对应标签
正常	0	100	1
外圈故障 1	0.007	100	2
外圈故障 2	0.014	100	3
外圈故障 3	0.021	100	4
内圈故障 1	0.007	100	5
内圈故障 2	0.014	100	6
内圈故障 3	0.021	100	7
滚动体故障 1	0.007	100	8
滚动体故障 2	0.014	100	9
滚动体故障 3	0.021	100	10

笔者首先对滚动轴承实验数据集中的样本集中进行了STFT并对其进行灰度压缩，

以表 1 中的正常状态、外圈故障状态 1、内圈故障状态 1 和滚动体故障状态 1 中的各自一个样本为例,其压缩后的灰度时频图见图 5.

由于原始振动信号存在周期性,所以其时频图像同样存在一定的周期性规律,这种规律在空间上呈现一种重复性,这种特性与纹理特性极其接近,所以选择提取纹理特征较强的灰度共生矩阵提取图像特征. 其中对比度能够反映振动信号时频图像中局部灰度变化总和;相关性能够反映图像中局部灰度相关性;能量能够反映图像中灰度值分布的均匀情况和图像中纹理粗细的变换情况;同质性反映图像纹理的局部变换情况.

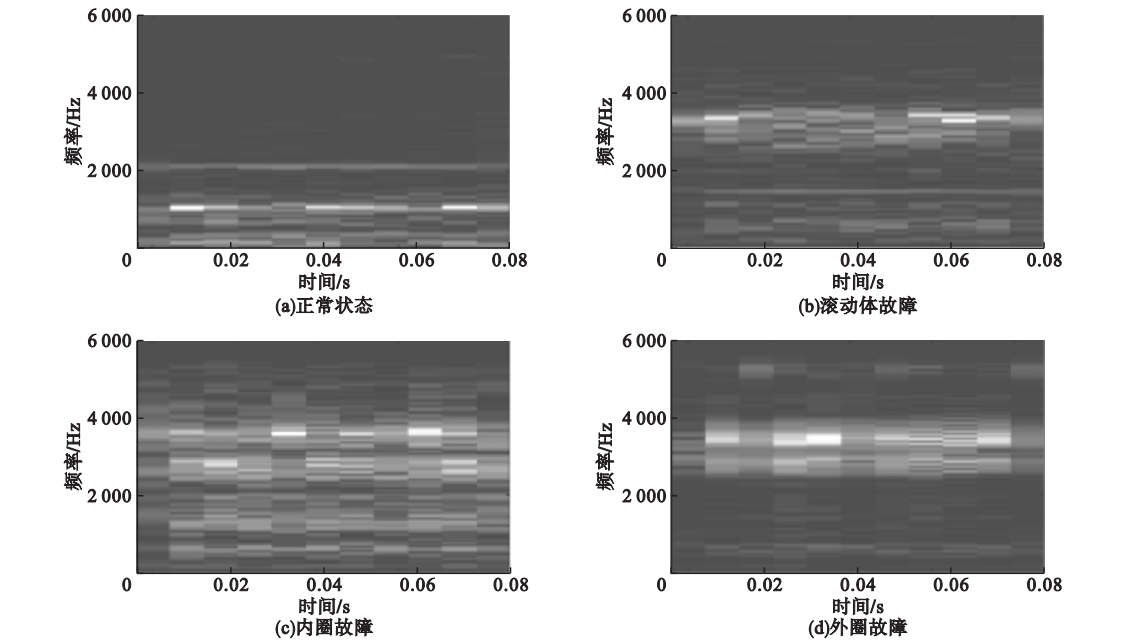


图 5 轴承样本集灰度时频图

Fig. 5 Time-frequency diagrams of gray scale extract from the bearing sample set

经过 STFT 变换后得到三个轴承不同状态下的特征图样本各 1 000 张,按照 7/3 的分样比选取每个数据集中前 700 个样本作为训练样本集,余下的 300 个样本作为测试样本集. 根据式(1)~式(5)对训练集和测试集的灰度时频图像求取灰度共生矩阵属性值,仍以上述样本为例,其属性值列表如表 2~表 5 所示.

表 2 正常状态灰度共生矩阵属性值

Table 2 Attribute values of grayscale symbiosis matrix in normal state				
角度/(°)	矩阵属性值			
	对比度	相关性	能量	同质性
0	9.909 2	0.048 4	0.708 4	0.898 8
45	10.473 5	0.046 7	0.706 5	0.895 0
90	5.822 5	0.059 4	0.729 4	0.929 3
135	10.874 7	0.045 3	0.703 4	0.892 7

表3 滚动体灰度共生矩阵属性值

Table 3 Attribute values of gray scale symbiosis matrix of scroll body

角度/(°)	矩阵属性值			
	对比度	相关性	能量	同质性
0	7.010 2	0.056 5	0.833 9	0.923 4
45	7.877 4	0.040 2	0.822 5	0.916 0
90	0.833 9	0.074 8	0.842 3	0.929 3
135	0.923 4	0.040 1	0.821 5	0.915 9

表4 内圈灰度共生矩阵属性值

Table 4 Attribute values of inner ring gray scale symbiosis matrix

角度/(°)	矩阵属性值			
	对比度	相关性	能量	同质性
0	6.927 3	0.057 6	0.839 3	0.925 3
45	7.632 9	0.041 3	0.829 4	0.918 9
90	5.827 4	0.079 0	0.849 2	0.932 2
135	7.674 5	0.041 4	0.828 7	0.918 9

表5 外圈灰度共生矩阵属性值

Table 5 Attribute values of gray scale symbiosis matrix of outer ring

角度/(°)	矩阵属性值			
	对比度	相关性	能量	同质性
0	7.222 9	0.052 7	0.839 3	0.923 4
45	7.809 8	0.041 3	0.829 4	0.916 4
90	6.633 1	0.060 9	0.849 2	0.927 0
135	7.835 0	0.042 1	0.828 7	0.916 1

从表2~表5中可以看出在不同角度上各属性值之间的差异较大,不同故障类型之间属性值具有明显的差异性,说明不同故障类型的灰度时频图像有着明显的纹理差别变化.对每个样本依次采集16维灰度共生矩阵属性值作为特征向量,从而组成了A、B、C三组滚动轴承故障样本特征空间,所组成的特征样本空间将作为后续SDAE网络的输入参数.

2.2 网络的构建以及训练和测试

笔者构建的网络结构与图2类似,针对设置的输入向量维数设置网络输入层节点数为16个,针对滚动轴承故障状态类型设置输

出层节点为10个,采用三层隐藏层结构,隐藏层节点设置为240-160-80,权值参数更新的学习率设置为 $\alpha=0.1$,每个DAE网络和Soft-max分类层参数更新时设置最大迭代次数为100次,网络运行环境为Matlab2016b.将A、B、C三类数据集训练样本输入到构建的SDAE网络中,引入“dropout”方法防止网络产生过拟合^[20].图6表示训练过程中网络模型的迭代误差收敛曲线,其中横坐标表示网络训练过程中所有样本集迭代过程,纵坐标表示每次迭代过程的误差值,从图中可以看出当迭代100次时,误差趋于稳定值0.010 16,说明此时网络已收敛.




图6 网络训练过程中迭代误差曲线

Fig. 6 Iterative error curve during network training process

网络训练完成后,输入测试样本数据集对网络进行测试,表6是三个不同的数据集平均故障识别率.

表6 不同数据集平均故障识别率

Table 6 Average fault identification rate of different data sets

数据集类型	识别率/%
A	96.7
B	94.2
C	95.8

图7表示数据集A故障识别的混淆矩阵,其中横坐标表示目标故障类别,纵坐标表示实际故障类别,浅色对角线区域表示SDAE网络在每一种故障类别样本中的识别

率,红色非对角线区域表示网络对每一种故障类别错误的识别率,例如:第三行第二列的数值为 0.9%,这表示实际故障类型为第三类,而笔者方法把它错分到第二类的比例为 0.9%.

1	95.2%	1.2%	0.0%	0.0%	0.0%	2.3%	0.0%	1.3%	0.0%	0.0%
2	0.0%	98.7%	0.0%	0.0%	0.8%	0.0%	0.0%	0.0%	0.5%	0.0%
3	0.0%	.9%	97.5%	0.0%	.0%	0.0%	1.6%	0.0%	0.0%	0.0%
4	0.0%	0.0%	1.5%	94.3%	0.0%	2.8%	0.0%	0.0%	0.0%	1.4%
5	0.5%	1.2%	0.0%	0.0%	97.3%	0.0%	0.0%	1.0%	0.0%	0.0%
6	0.0%	0.0%	0.0%	0.9%	0.0%	99.1%	0.0%	0.0%	0.0%	0.0%
7	0.0%	0.0%	0.0%	0.0%	0.0%	1.8%	98.2%	0.0%	0.0%	0.0%
8	0.0%	2.3%	0.0%	1.7%	0.5%	0.0%	0.0%	93.7%	0.0%	1.8%
9	1.4%	0.0%	0.2%	0.0%	0.0%	1.9%	0.0%	0.0%	95.6%	0.9%
10	0.0%	0.0%	0.0%	1.3%	0.0%	0.0%	0.0%	1.6%	0.0%	97.1%
	1	2	3	4	5	6	7	8	9	10

图7 数据集 A 的故障识别混淆矩阵

Fig.7 Fault identification confusion matrix of data A

由图7可知,笔者所提方法对数据集A中10种故障类型的分类精度均在90%以上,整个数据集A中测试集的平均分类精度为96.7%.说明笔者方法能够有效识别故障类型,并对多种故障类型做出有效分类.

为了验证笔者提出方法的有效性,参考了文献[2]中SVM分类器和DBN分类器的网络结构,实验数据仍采用笔者制作的三类数据集,不同的是对比算法SVM和DBN直接从原始信号中提取特征做故障识别,其实验结果与笔者所提算法做了对比,其结果如表7所示.

表7 不同算法的实验结果对比

Table 7 Comparison results of different algorithms				
算法	训练正	测试正	训练	测试
	准确率/%	准确率/%	时间/s	时间/s
SVM	84.36	79.28	50.57	32.23
DBN	93.17	90.43	39.48	25.44
笔者算法	96.25	95.57	30.24	21.16

从表7中可以看出,笔者所提算法无论在平均识别正确率还是运行时间上均优于其

他两种算法,尤其在运行时间上,能够有效减少输入数据维数,同时在网络训练过程中引入“dropout”方法,从而有效减少了运行时间,增加了故障识别效率.

3 结 论

- (1)通过对原始大批量振动信号进行STFT变换,得到时频图且具有可分性,同时保留了较多的原始故障信息,解决了传统方法故障信息丢失问题.
- (2)灰度共生矩阵图像分析方法能够有效提取时频图像中的故障特征信息,同时减小了数据规模,从而能够提高故障诊断效率.
- (3)笔者构建了SDAE深度神经网络,实现了滚动轴承故障的智能诊断与识别,极大减少了因人为参与而造成的识别精度不足和识别效率低等问题,同时引入了“dropout”方法,提升了网络故障识别效率.文中相关结论为现有故障诊断方法提供了新的思路,所提方法对轴承故障的诊断与识别有着积极意义.

参考文献

[1] GAN Meng, WANG Cong, ZHU Changan. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings[J]. Mechanical systems and signal processing, 2016, 2016(5): 92-104.

[2] 侯文擎,叶鸣,李巍华. 基于改进堆叠降噪自编码的滚动轴承故障分类[J]. 机械工程学报, 2018, 54(7): 87-96.
(HOU Wenqing, YE Ming, LI Weihua. Fault classification of rolling bearing based on improved self-coding for stack noise reduction[J]. Journal of mechanical engineering, 2018, 54(7): 87-96.)

[3] FARZIN P J K. Bearing fault diagnosis by a robust higher-order super-twisting sliding mode observe[J]. Sensors, 2018, 18(4): 1128-1150.

[4] BAFROUI H H, OHADI A. Application of wavelet energy and Shannon entropy for feature extraction in gearbox fault detection under varying speed conditions[J]. Neurocomputing, 2014, 133(8): 437-445.

[5] WANG Yanxue, LIANG Ming. An adaptive SK technique and its application for fault detection of rolling element bearings [J]. Mechanical systems and signal processing,

- 2011,25(5):1750-1764.
- [6] 俞啸,丁恩杰,陈春旭,等.基于HHT和有监督稀疏编码的滚动轴承故障状态识别方法[J].煤炭学报,2015,40(11):2587-2595.
(YU Xiao,DING Enjie,CHEN Chunxu,et al. Fault status identification method of rolling bearing based on HHT and supervised sparse coding [J]. Journal of coal, 2015, 40 (11): 2587-2595.)
 - [7] 王维刚.基于时频图像识别的旋转机械多特征融合故障诊断方法研究[D].哈尔滨:哈尔滨工业大学,2016.
(WANG Weigang. Research on multi-feature fusion fault diagnosis method of rotating machinery based on time-frequency image recognition [D]. Harbin: Harbin Institute of Technology, 2016.)
 - [8] 袁建虎,韩涛,唐建,等.基于小波时频图和CNN的滚动轴承智能故障诊断方法[J].机械设计与研究,2017(2):101-105.
(YUAN Jianhu,HAN Tao,TANG Jian,et al. Intelligent fault diagnosis method of rolling bearing based on wavelet time-frequency diagram and CNN [J]. Mechanical design and research, 2017(2):101-105.)
 - [9] VERSTRAETE D,FERRADA A,DROGUETT E L, et al. Deep learning enabled fault diagnosis using time-frequency image analysis of rolling element bearings [J]. Shock and vibration, 2017(2017):1-17.
 - [10] WANG Weigang, LIU Zhansheng. A novel fault diagnosis method based on time-frequency image recognition [J]. Applied mechanics & materials, 2014(687-691):3569-3573.
 - [11] VARISH N,PAL A K. A novel image retrieval scheme using gray level co-occurrence matrix descriptors of discrete cosine transform based residual image [J]. Applied intelligence, 2018 (12):1-24.
 - [12] HARALICK R M, SHANMUGAM K, DINSTEN I. Textural features for image classification [J]. IEEE transactions on systems man & cybernetics, 2011, SMC-3(6):610-621.
 - [13] 巩萍,王阿明.基于灰度共生矩阵和人工神经网络的肺癌CT图像的分类研究[J].生物医学工程与临床,2013,8(6):552-556.
(GONG Ping,WANG Aming. Classification of CT images of lung cancer based on gray scale symbiosis matrix and artificial neural network [J]. Biomedical engineering and clinical, 2013, 8(6):552-556.)
 - [14] RAHMAN T Y, MAHANTA L B, CHAKRABORTY C, et al. Textural pattern classification for oral squamous cell carcinoma [J]. Journal of microscopy, 2017, 269(6):85-93.
 - [15] 黄雪梅.基于IMF投影图像分析的滚动轴承故障诊断方法研究[J].机械传动,2017,37(4):19-23.
(HUANG Xuemei. Research on rolling bearing fault diagnosis method based on IMF projection image analysis [J]. Mechanical transmission, 2017, 37(4):19-23.)
 - [16] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion [J]. Journal of machine learning research, 2010, 11(12):3371-3408.
 - [17] 何文韬,邵诚.工业大数据分析技术的发展及其面临的挑战[J].信息与控制,2018,47(4):18-30.
(HE Wentao,SHAO Cheng. The development and challenges of industrial big data analysis technology [J]. Information and control, 2018, 47(4):18-30.)
 - [18] SCHÖLKOPF B, PLATT J, HOFMANN T. Greedy layer-wise training of deep networks [J]. Advances in neural information processing systems, 2010, 19(8):153-160.
 - [19] 蒋爱国,符培伦,谷明,等.基于多模态堆叠自动编码器的感应电机故障诊断[J].电子测量与仪器学报,2018,16(8):17-23.
(JIANG Aiguo,FU Peilun,GU Ming,et al. Fault diagnosis of induction motor based on multi-mode stacked automatic encoder [J]. Journal of electronic measurement and instrumentation, 2018, 16(8):17-23)
 - [20] 张西宁,向宙,夏心锐,等.堆叠自编码网络性能优化及其在滚动轴承故障诊断中的应用[J].西安交通大学学报,2018,52(10):55-62.
(ZHANG Xining,XIANG Zhou,XIA Xinrui,et al. Performance optimization of stacking self-coding network and its application in rolling bearing fault diagnosis [J]. Journal of Xi'an jiaotong university, 2018, 52(10):55-62.)
 - [21] HINTON G E, SRIVASTAVA N, KRIZHEVSKY A, et al. Improving neural networks by preventing co-adaptation of feature detectors [J]. Computer science, 2012, 3(4):212-223.

(责任编辑:刘春光 英文审校:范丽婷)